



# Pronósticos de agregados a partir de desagregados<sup>1</sup>

## Caso empírico: Inflación de alimentos en Colombia

**Eliana Rocío González Molano\***  
**Febrero 2008**

### *Resumen*

*Pronosticar la inflación de alimentos es uno de los grandes retos del Banco central, debido a la alta ponderación de los alimentos dentro del IPC y puesto que los rubros que conforman este grupo obedecen principalmente a factores de oferta que no son fácilmente predecibles ni reaccionan a la política monetaria. En este trabajo se construyen pronósticos para la inflación de alimentos a partir de desagregados, utilizando diferentes clasificaciones de la canasta de alimentos del IPC. Se evalúan y comparan modelos tanto univariados como multivariados según su capacidad de pronóstico. Los resultados muestran, que los pronósticos construidos a partir de pronósticos de subgrupos de alimentos generados por modelos multivariados (VARX y VEC) producen menor error de pronóstico que los generados por un modelo univariado (ARX). De otro lado, para el corto y mediano plazo, los pronósticos para el agregado construidos agregando pronósticos de subgrupos de alimentos producen menor error de pronóstico que los pronósticos para la inflación de alimentos generados por un modelo que contiene tanto rezagos del agregado como rezagos de los subgrupos. Sin embargo, para horizontes más lejanos los segundos parecen mejores que los primeros.*

*Palabras clave:* Inflación de alimentos, desagregación, métodos de clasificación de variables, pronósticos.

*Clasificación JEL:* C53, C81, E31, E37.

## **I. Introducción**

La inflación de alimentos es muy volátil y obedece a factores exógenos que afectan de manera diferente a los diferentes ítems que componen la canasta de alimentos, lo cual hace que pronosticar la inflación total de alimentos sea una tarea difícil. Hay varios ejemplos de tales factores, uno de ellos es el clima, que afecta de manera directa a productos como hortalizas y frutas e indirectamente a productos procesados y almuerzos cuyo precio depende del precio de las materias primas utilizadas para su

---

<sup>1</sup> Los resultados y opiniones son responsabilidad exclusiva de los autores y su contenido no compromete al Banco de la República ni a su junta directiva.

\* Banco de la República. [egonzamo@banrep.gov.co](mailto:egonzamo@banrep.gov.co).

producción. Otro caso, son los precios internacionales de commodities como aceites y cereales cuyos precios se transmiten a través de los precios de importaciones.

El objetivo de este trabajo es analizar empíricamente si pronósticos para la inflación agregada de alimentos pueden ser mejorados, en términos de reducir el error de pronóstico, agregando pronósticos de inflación de grupos de alimentos o utilizando un modelo de pronóstico para la inflación agregada que dependa no solo de rezagos de esta sino también de información rezagada de grupos o componentes de la canasta de alimentos en comparación con pronósticos obtenidos directamente de modelos de pronóstico para el agregado, siguiendo el trabajo de Hendry y Hudrich (2006).

La literatura sobre predicción (Lütkepohl 1984a, 1987b; Hendry, 2005; Hendry y Hubrich, 2006) a mostrado que información desagregada del agregado para el cual se desean obtener pronósticos, bien sean subcomponentes, regiones o información con frecuencias más altas, pueden tener capacidad predictiva sobre el agregado. En este respecto, varios trabajos empíricos en los que se generan pronósticos para un agregado a partir de agregación de pronósticos de desagregados o componentes del agregado se han hecho. En particular Hudrich, (2002, 2003) pronostica la inflación anual del IPC armonizado para el área del Euro agregando pronósticos de componentes de este indicador utilizando diferentes modelos de pronóstico tanto univariados como multivariados, encontrando que no necesariamente se reduce el error de pronóstico agregando componentes en comparación con el pronóstico obtenido directamente para el agregado y la principal razón es que los errores de pronóstico de las componentes no se cancelan, sino que van en la misma dirección debido a la presencia de choques que afectan algunos o todas las componentes, los cuales no son tenidos en cuenta en la especificación del modelo.

Benhal et al, (2004) de nuevo analizan los pronósticos de inflación total y básica (excluyendo energía y alimentos no procesados) basados en el IPC armonizado para la zona del euro obtenidos agregando pronósticos de componentes y adicionalmente agregan pronósticos de las inflaciones de los cuatro países más grandes del área del euro como proxy de la inflación agregada del área del euro. En este trabajo también se usan diferentes modelos univariados y multivariados. Algunas contribuciones de este trabajo son el uso de modelos VAR bayesianos (BVAR), el método de selección del modelo se basa en escoger el modelo con menor raíz del error cuadrático medio (RECM) de los pronósticos fuera de muestra obtenidos de manera recursiva y adicionalmente evalúan si las variables y los signos de los

coeficientes incluidos en el modelo seleccionado satisfacen la teoría económica. Los autores encuentran que para el largo plazo pronosticar directamente el agregado produce mejores resultados que agregar pronósticos de desagregados. Por su parte, para el corto plazo, los resultados no son contundentes sobre cual metodología produce mejores pronósticos. Para la inflación básica, los resultados son más prometedores, debido especialmente a que las componentes no presentan choques importantes, y por lo tanto hay menor volatilidad que para el caso de la inflación total. Por otro lado, agregar pronósticos de las inflaciones de los países como pronóstico de la inflación total sintética<sup>2</sup> de la zona euro no supera el pronóstico directo de la inflación sintética agregada para ningún horizonte de pronóstico, aunque las diferencias en los errores de pronóstico son pequeñas.

Por su parte, Hendry y Hudrick, (2006) generan diferentes pronósticos para el IPC de la zona euro y de los Estados Unidos a partir de modelos de pronóstico que incluyen no solo información rezagada del agregado sino también de las componentes del IPC. Ellos encuentran que este modelo de pronóstico produce menor error de pronóstico que el obtenido al pronosticar directamente el agregado y/o agregar pronósticos de las componentes o subgrupos del IPC para el caso de los Estados Unidos y en algunas situaciones para la zona euro. Según los mismos autores, el beneficio en incluir desagregados para pronosticar el agregado depende de la variable particular que se esté analizando, de la muestra, del modelo de pronóstico utilizado y del horizonte de pronóstico.

En Colombia se han realizado ejercicios de generación de pronósticos agregando pronósticos de componentes para la inflación total, sin alimentos y alimentos. Los resultados han sido variados. En particular, para la inflación total se han agregado pronósticos de los grupos de alimentos, vivienda, vestuario y misceláneo. Estos pronósticos no superan a otros obtenidos con diferentes metodologías y modelos univariados para la inflación total. Para el caso de la inflación sin alimentos, se obtiene el pronóstico como el agregado de los pronósticos de los grupos de transables, no transables y regulados. En este caso, los resultados son más prometedores. Este pronóstico produce menor error cuadrático medio comparado con los demás pronósticos obtenidos de modelos univariados para la inflación sin alimentos utilizados por el Banco. Finalmente, para la inflación de alimentos en el Banco se han hecho ejercicios de pronóstico agregando pronósticos de diferentes grupos predefinidos de alimentos, como el G6 (papa, leche, carne de res, frutas, hortalizas y resto de alimentos), el G10 (carnes, lácteos, aceites,

---

<sup>2</sup> Construida como el promedio ponderado de las inflaciones de los cuatro países más grandes de la zona euro.

comidas fuera del hogar, papa, tubérculos, frutas, hortalizas, cereales, alimentos procesados) y el G3 (alimentos perecederos, procesados y comidas fuera del hogar). De los pronósticos obtenidos a partir de estas tres agregaciones, el que históricamente produce menor error de pronóstico es el construido a partir del G3. Sin embargo, este pronóstico no supera el obtenido por un modelo ARIMAX para el agregado de alimentos en el mediano y largo plazo.

Los diferentes grupos de alimentos utilizados para la construcción de los pronósticos han sido definidos ad hoc por las similares características de los ítems dentro de cada agrupación o por tratarse del mismo tipo de producto. Por otro lado, en los tres casos, los pronósticos para cada subgrupo de alimentos son obtenidos a partir de modelos uniecuacionales donde las variables explicativas son rezagos de la inflación del mismo grupo y algunas variables exógenas. En ningún caso se han analizado posibles relaciones entre los grupos considerados, teniendo en cuenta que algunos de ellos son sustitutos o que los precios de un grupo puedan afectar directa o indirectamente los precios de otro o que las variables exógenas incluidas puedan explicar la dinámica de la inflación de más de un grupo simultáneamente. Por las razones expuestas anteriormente, parece conveniente estimar un modelo multivariado en el cual se tengan en cuenta las interrelaciones entre los diferentes subgrupos de alimentos, para lo cual en este documento se propone un modelo VAR o VEC en caso de existir cointegración entre los grupos.

Los ejercicios empíricos de pronósticos de agregado a partir de desagregados hechos en el Banco han llevado a varias conclusiones, dentro de las que se destacan las siguientes (Gómez et al ,2006): (i) entre más subgrupos se consideren para construir el pronóstico del agregado, mayor es el error de pronóstico, debido a la acumulación de errores de los pronósticos de los diferentes grupos. (ii) entre más homogéneos sean los ítems que conforman cada grupo y mayor heterogeneidad haya entre grupos, se obtienen mejores pronósticos para el agregado. (iii) el pronóstico para el agregado a partir de desagregados, produce menor errores de pronóstico que los pronósticos generados a partir de un modelo para el agregado para horizontes de pronóstico de muy corto plazo. Sin embargo, para mediano y largo plazo es mejor pronosticar directamente el agregado. (iv) una ventaja de tener pronósticos de desagregados es que permite identificar los grupos de alimentos que presentan variaciones de precios, la dirección de estos cambios y explorar algunas causas de este comportamiento.

En este trabajo se evaluarán diferentes metodologías de pronóstico de variables agregadas teniendo en cuenta como variables explicativas componentes o desagregaciones de la variable dependiente,

siguiendo el trabajo de Hendry y Hubrich (2006). En particular se evaluarán pronósticos de la inflación total de alimentos en Colombia generados a partir de pronósticos de desagregados o subgrupos de alimentos que por su homogeneidad son menos difícil de pronosticar que el agregado de alimentos. La principal contribución de este trabajo es el uso de metodologías de clasificación de variables para determinar los grupos o componentes de la inflación de alimentos que se consideran en la construcción del pronóstico para el agregado, con el fin de evaluar empíricamente el resultado sugerido por Lutkepohl (1984a, 1987b) de que entre menos correlacionados sean las componentes, mayor el beneficio de agregar pronósticos de las componentes como pronóstico del agregado. Se evaluarán los siguientes casos: (i) Pronóstico de la inflación total de alimentos, agregando pronósticos de grupos predefinidos de alimentos según sus ponderaciones en la canasta del IPC. (ii) Pronóstico de la inflación total de alimentos, agregando pronósticos de grupos de alimentos obtenidos siguiendo una metodología de clasificación de variables, siguiendo el trabajo de Maldonado, 2007 para la inflación en Ecuador, pero utilizando otra metodología de clasificación de variables (Kalpakis, 2001). Las ponderaciones de cada grupo o cluster se construyen como la suma de los pesos de los ítems que integran cada cluster. (iii) Pronóstico de la inflación total de alimentos considerando como variables explicativas no solo rezagos de esta sino también de la inflación de los grupos predefinidos o los clusters descritos en los numerales anteriores.

Este documento está organizado como sigue. En la sección 2, se describe brevemente la teoría que respalda la posible mejoría en la capacidad de predicción de una variable cuando se adiciona información rezagada de componentes de esta en el modelo de pronóstico en el caso poblacional. Sin embargo, al trabajar con una muestra, esto no necesariamente implica una mejoría en la capacidad de pronóstico debido a la incertidumbre asociada con el modelo de pronóstico y la estimación de este. En la sección 3, se describen los datos; sección 4 se describen los modelos de pronóstico utilizados. En la sección 5, se describen las metodologías de clasificación de variables utilizadas para determinar los grupos o componentes de la variable agregada que se tienen en cuenta para generar el pronóstico. En la sección 6, se presentan los resultados de evaluación de los diferentes pronósticos y en la sección 7 se concluye.

## **II. Marco Teórico**

La literatura ha mostrado que cuando se conoce el proceso generador de los datos (PGD), agregar pronósticos de componentes produce menor error de pronóstico sobre el agregado, que pronosticar directamente el agregado. Esto debido principalmente a que el conjunto de información para el agregado es más amplio cuando se consideran componentes de este (Lutkepohl (1984a, 1987b), Hubrich, 2003). Sin embargo, en la práctica se trabaja con una muestra finita y no necesariamente se conoce el PGD y por lo tanto una mejora en la capacidad de predicción de un modelo basado en el conjunto de información poblacional, no necesariamente se dará en igual medida en la capacidad de pronóstico de un modelo basado en el conjunto de información contenido en una muestra. Así, debido a la incertidumbre<sup>3</sup> asociada al estimar procesos para las componentes y agregar estas en lugar de estimar un proceso para el agregado, puede producir mayor error de pronóstico, inclusive para muestras grandes (Lütkepohl, 1987). Este autor presentó simulaciones de Monte Carlo para evaluar los pronósticos obtenidos agregando pronósticos de desagregados en comparación con aquellos obtenidos directamente de un modelo de pronóstico para el agregado. Los resultados sugieren que no necesariamente se reduce el error de pronóstico agregando pronósticos de componentes. Esto sucede en algunas situaciones y para algunos PGD. En particular, cuando las componentes no son altamente correlacionadas y para horizontes de pronóstico de corto plazo.

De acuerdo a Hendry y Hubrich (2006), quienes estudian el concepto de predicción de una variable basada en diferentes conjuntos de información, muestran analíticamente el beneficio de incluir información desagregada en la construcción del pronóstico para el agregado, tanto cuando se conoce el PGD como cuando no. Puesto que para este trabajo se desconoce el proceso generador de los datos tanto del agregado como de las componentes, aquí presentamos solamente la derivación analítica del pronóstico para el agregado para tal situación, la cual puede ser revisada en Hendry y Hubrich (2006). Con tal fin, primero será revisado el concepto de predictibilidad de una variable aleatoria y sus propiedades.

Así, una variable aleatoria es predecible con respecto a un conjunto de información, si la distribución condicional de la variable dado el conjunto de información es diferente de la distribución no condicional de dicha variable.

---

<sup>3</sup> debido a la especificación del modelo, estimación de los parámetros del modelo, errores de medición de los datos, etc.

En particular una variable aleatoria es predecible en media si el valor esperado condicionado en el conjunto de información es diferente del valor esperado no condicionado. Así, sea  $Y_t = f(\mathfrak{I}_{t-1}) + \varepsilon_t$ ; donde  $\mathfrak{I}_{t-1}$  es el conjunto de información disponible y  $\varepsilon_t$  es un término de error no predecible, entonces  $Y_t$  es predecible si  $E_t(Y_t/\mathfrak{I}_{t-1}) = f(\mathfrak{I}_{t-1}) \neq E_t(Y_t)$ . Si se cuenta con un conjunto de información más pequeño  $\wp_{t-1}$ , subconjunto de  $\mathfrak{I}_{t-1}$ , entonces  $Y_t$  es predecible respecto a este nuevo conjunto de información, sin embargo, la predicción es menos precisa en el sentido de que se produce una mayor varianza del error de pronóstico, aunque el pronóstico sigue siendo insesgado. Así, si  $Y_t = g(\wp_{t-1}) + \eta_t$ ; el error de pronóstico  $\eta_t$  satisface  $E_t(\eta_t/\wp_{t-1}) = 0$ ; es decir es no predecible, sin embargo, respecto al conjunto de información completo,  $\mathfrak{I}_{t-1}$ , el error  $\eta_t$  no satisface la no predictibilidad, puesto que  $\eta_t = Y_t - g(\wp_{t-1}) = f(\mathfrak{I}_{t-1}) - g(\wp_{t-1}) + \varepsilon_t$ ; entonces  $E_t(\eta_t/\mathfrak{I}_{t-1}) = f(\mathfrak{I}_{t-1}) - E_t(g(\wp_{t-1})/\mathfrak{I}_{t-1}) = f(\mathfrak{I}_{t-1}) - g(\wp_{t-1}) = \nu_t \neq 0$ , lo cual implica que el error  $\eta_t$  tenga una varianza mayor al error  $\varepsilon_t$ .

### Agregar pronósticos de componentes

Suponga que  $Y$  es construido como el promedio ponderado de dos componentes  $y_1$  y  $y_2$ , tal que  $Y_t = \omega_1 y_{1t} + \omega_2 y_{2t}$ , con  $\omega_2 = 1 - \omega_1$ . Suponga además que el conjunto de información  $\wp_{t-1}$  contiene solamente información rezagada de  $Y_t$  y que el conjunto de información se puede ampliar para aproximarnos a  $\mathfrak{I}_{t-1}$ , adicionando información rezagada de las componentes de  $Y$ . Así, el pronóstico de  $Y_{T+1}$  obtenido agregando pronósticos de sus componentes, los cuales son dados por  $E[y_{i,T+1}/\mathfrak{I}_T] = \delta'_{i,T+1} \mathfrak{I}_T$ , sería de la siguiente forma:

$$E[Y_{T+1}/\mathfrak{I}_T] = \sum \omega_{i,T+1} \delta'_{i,T+1} \mathfrak{I}_T = \lambda_{T+1} \mathfrak{I}_T,$$

donde  $\omega_{i,T+1}$  es la ponderación de la  $i$ -ésima componente de  $Y$ , la cual puede variar en el tiempo.

Por otro lado, suponga que se obtiene el pronóstico de  $Y_{T+1}$  directamente de un modelo para el agregado, tal que  $E[Y_{T+1}/\mathfrak{I}_T] = \phi'_{T+1} \mathfrak{I}_T$ , de tal manera que el error de pronóstico obtenido agregando pronósticos de las componentes, será mayor que el del pronóstico directo en la medida en que las

ponderaciones y/o los parámetros de los modelos para cada componente varíen más en el tiempo que los parámetros del modelo directo, en cuyo caso, pronosticar el agregado directamente sería más apropiado que agregar pronósticos de componentes. Este resultado sugiere, entonces que incluir información desagregada en el conjunto de información para obtener un pronóstico directo del agregado,  $E_{T+1}[Y_{T+1}/\mathfrak{I}_T] = \phi'_{T+1}\mathfrak{I}_T$ , podría producir menor error cuadrado medio de pronóstico que agregar pronósticos de desagregados basados en el mismo conjunto de información. Sin embargo, no se puede concluir lo mismo si el conjunto de información con respecto al cual se obtiene el pronóstico directo del agregado es el reducido  $\mathfrak{I}_{t-1}$ , en cuyo caso, aunque el pronóstico sería insesgado, tendría mayor MSE que el pronóstico basado en el conjunto de información más completo  $\mathfrak{I}_{t-1}$ , el cual incluye información desagregada.

### **Modelo de pronóstico del agregado, cuando se desconoce el proceso generador de las componentes**

Suponga de nuevo que  $Y$  se obtiene de agregar dos componentes  $y_1$  y  $y_2$ , los cuales son generados por el modelo  $VAR(1,1)$

$$y_t = \Gamma y_{t-1} + v_t$$

$$\begin{pmatrix} y_{1,t} \\ y_{2,t} \end{pmatrix} = \begin{pmatrix} \pi_{11} & \pi_{12} \\ \pi_{21} & \pi_{22} \end{pmatrix} \begin{pmatrix} y_{1,t-1} \\ y_{2,t-1} \end{pmatrix} + \begin{pmatrix} v_{1,t} \\ v_{2,t} \end{pmatrix}$$

de tal manera que el agregado

$$Y_t = \omega_{1,t} [(\pi_{11} - \pi_{21})y_{1,t-1} + (\pi_{12} - \pi_{22})y_{2,t-1}] + \pi_{21}y_{1,t-1} + \pi_{22}y_{2,t-1} + \omega_{1,t}v_{1,t} + (1 - \omega_{1,t})v_{2,t}$$

Suponga que no se conoce el proceso generador de datos y que se estima  $Y_t$  mediante un modelo AR(1)  $Y_t = \phi Y_{t-1} + \varepsilon_t$ . El pronóstico de  $Y$  un periodo adelante y el correspondiente error de pronóstico estarían dados por:

$$\begin{aligned} \hat{Y}_{T+1/T} &= \hat{\phi} Y_T \\ \hat{\varepsilon}_{T+1/T} &= Y_{T+1} - \hat{Y}_{T+1/T} \\ \hat{\varepsilon}_{T+1/T} &= \omega_{1,T+1} [(\pi_{11} - \pi_{21}) - \hat{\phi}] y_{1,T} + \left[ \omega_{1,T+1} (\pi_{12} - \pi_{22} + \hat{\phi}) + (\pi_{22} - \hat{\phi}) \right] y_{2,T} + \omega_{1,T+1} v_{1,T+1} + (1 - \omega_{1,T+1}) v_{2,T+1} \end{aligned}$$

Los dos primeros términos del error de pronóstico son predecibles, puesto que difícilmente se satisfacen simultáneamente las dos restricciones.

$$\begin{aligned} & \left[ (\pi_{11} - \pi_{21}) - \hat{\phi} \right] = 0 \\ & \left[ \omega_{1,T+1} (\pi_{12} - \pi_{22} + \hat{\phi}) + (\pi_{22} - \hat{\phi}) \right] = 0 \end{aligned}$$

Este resultado sugiere una vez más que incluir información desagregada en el modelo de pronóstico del agregado puede reducir el error de pronóstico del agregado.

Más aún, teniendo en cuenta que  $y_t$  es el vector que contiene las componentes de  $Y_t$  y suponga por ejemplo que  $y_t = \Gamma y_{t-1} + \nu_t$  el proceso generador de las componentes, el proceso para agregado  $Y_t$  se puede descomponer como

$$\begin{aligned} Y_t &= \omega'_t y_t \\ &= \omega'_t \Gamma y_{t-1} + \omega'_t \nu_t \\ &= \kappa \omega'_{t-1} y_{t-1} + (\omega'_t \Gamma - \kappa \omega'_{t-1}) y_{t-1} + \omega'_t \nu_t \\ &= \kappa Y_{t-1} + (\varphi_t - \kappa \omega'_{t-1}) y_{t-1} + \varepsilon_t; \quad \text{donde } \varphi_t = \omega'_t \Gamma \text{ y } \varepsilon_t = \omega'_t \nu_t \end{aligned}$$

De tal manera que el proceso para el agregado  $Y_t$  incluye tanto rezagos de este como de las componentes (vector  $y_t$ ) y la importancia de la componente  $i$  en el modelo se da en la medida que  $\varphi_{i,t} - \kappa \omega'_{i,t-1} \neq 0$ . Sin embargo, hay varios aspectos a tener en cuenta sobre los parámetros de este modelo que pueden afectar la precisión de los pronósticos: i) cambios en las ponderaciones de las componentes. Para el caso Colombia estas son constantes y solo cada diez años se revisan, lo cual reduce la incertidumbre en la estimación del modelo; ii) cambios en la estructura de correlación de las componentes a través del tiempo; iii) cambios en los parámetros de las componentes  $\varphi_{i,t}$  y iv) cambios en los parámetros autoregresivos  $\kappa$ . La decisión de incluir o no rezagos de las componentes en el modelo de pronóstico del agregado es un problema empírico y depende de que al menos los tres primeros aspectos no se presenten en mayor extensión.

### III. Datos

La variable agregada para la cual se desea obtener pronósticos es la inflación total de alimentos en Colombia. Para esto, se utiliza la serie mensual del IPC de alimentos para el periodo enero/1989 a noviembre/2007 y las series de los 47 rubros que conforman la canasta de alimentos dentro del IPC. Estos rubros están clasificados en el IPC en 9 subgrupos: cereales y productos de panadería, tubérculos y plátanos, hortalizas y legumbres, frutas, carne y derivados, pescado y otras comidas de mar, leche, huevos y grasas, alimentos varios y comidas fuera del hogar. Sin embargo, debido al gran número de subgrupos, en este trabajo se consideran otras desagregaciones para la construcción del pronóstico del agregado. Según la principal causa de movimientos en los precios de estos productos, los alimentos son clasificados en: efecto lluvias, efecto demanda, efecto precios internacionales y efecto ciclo ganadero. Otra clasificación es según el tipo de producto: alimentos perecederos, procesados y comidas fuera del hogar. Todas las series fueron transformadas usando logaritmos y tomando primera diferencia para obtener estacionariedad. Adicionalmente se consideran algunas variables exógenas que afectan los precios de algunos de los alimentos: devaluación promedio mensual, IPC sin alimentos, índice de precios internacionales de alimentos<sup>4</sup>, índice de sacrificio de ganado, déficit de lluvias<sup>5</sup>, brecha de la producción industrial<sup>6</sup>. Los índices de precios y de sacrificio de ganado también son transformados tomando logaritmos y primera diferencia. Los datos no son desestacionalizados, ya que los datos de inflación oficialmente publicados no son ajustados estacionalmente y por lo tanto los pronósticos que deseamos son para la inflación de alimentos sin desestacionalizar. Para modelar la componente estacional, en algunos casos se incluyen variables dicotómicas estacionales o se incluye el rezago de orden doce en el modelo de pronóstico.

#### **IV. Modelos de pronóstico**

Con el fin de obtener pronósticos de la inflación total de alimentos, se utilizaron dos tipos de modelos: un modelo univariado ARX que contiene rezagos de la variable dependiente y otras variables exógenas que pueden afectar la variable dependiente de manera contemporánea o rezagada. Se consideran dos

---

<sup>4</sup> Construido agregando según las ponderaciones en el IPC de alimentos en Colombia, considerando precios en dólares americanos de algunos productos como trigo, aceites, maíz, arroz y azúcar. Fuente: Datastream.

<sup>5</sup> Medido como las desviaciones respecto al promedio histórico mensual.

<sup>6</sup> Estimada usando el filtro de Hodrick y Prescott sobre la serie desestacionalizada del índice de producción industrial.

formas de pronosticar la inflación total de alimentos. En la primera, un modelo de pronóstico ARX para cada una de los subgrupos de alimentos es estimado y el pronóstico de la inflación total de alimentos se construye agregando los pronósticos de los subgrupos usando las ponderaciones de estos dentro del agregado en el IPC, este pronóstico se notará como AG. En la segunda, se estima un modelo ARX en el que se considera como variable dependiente el agregado de alimentos, y como variables explicativas, no solo rezagos de la variable dependiente sino también rezagos de la inflación de los subgrupos y otras variables exógenas, este pronóstico se notará AD. Para determinar la estructura del modelo, se utilizó el procedimiento top-down (Brüggemann y Lütkepohl, 2001) de selección de rezagos, que consiste en eliminar secuencialmente la variable explicativa (o rezago) menos significativa en un modelo general (en términos del menor estadístico t) hasta que todas las variables (o rezagos) que quedan en el modelo sean significativas, es decir hasta que el estadístico t sea mayor que cierto umbral para todas las variables que quedan en el modelo. El umbral esta dado por:

$$\gamma = \sqrt{\left(e^{(ct/T)} - 1\right) * (T - K + j - 1)}$$

Donde  $ct$  depende del criterio de selección escogido (AIC, BIC o HQC). En este caso se utilizó el criterio BIC y  $ct = \log(T)$ , donde  $T$  es el tamaño de la muestra y  $K$  es el número de parámetros en el modelo. El modelo inicial considera 12 rezagos para cada variable incluida en el modelo.

El segundo tipo de modelo es un modelo multivariado VARX que tiene en cuenta las posibles relaciones de causalidad que existen entre las variables. Nuevamente, el pronóstico de la inflación total de alimentos se construye de dos maneras. En la primera, se estima un modelo VARX donde se consideran como variables endógenas los subgrupos de alimentos y adicionalmente se incluyen algunas variables exógenas en el modelo. El pronóstico de la inflación total de alimentos de nuevo se construye como el promedio ponderado de los pronósticos de los subgrupos obtenidos del VARX, notado como de tipo AG. La segunda manera de obtener el pronóstico de la inflación agregada de alimentos es estimando un modelo VARX considerando como variables endógenas tanto la variable agregada como los subgrupos y de esta manera, el pronóstico del agregado se obtiene directamente del modelo, notado como de tipo AD. Adicionalmente, se hicieron pruebas de cointegración entre los grupos de alimentos y se encontró que no se rechaza la hipótesis nula de la existencia de un vector de cointegración. Así, teniendo en cuenta estos resultados, se estimaron modelos VEC para los diferentes grupos de alimentos

considerados y para determinar el número de rezagos los criterios AIC y BIC. Nuevamente se estimaron dos modelos, un VEC para los subgrupos de alimentos y un VEC que incluye tanto el agregado como los subgrupos.

## V. Metodologías de clasificación de variables

Adicional a los subgrupos de alimentos predeterminados, descritos anteriormente, se utilizan metodologías estadísticas de clasificación de variables, con el fin de obtener subgrupos de alimentos lo más homogéneos posible dentro de ellos y lo más heterogéneos entre ellos, que sean relativamente fáciles de pronosticar para construir el pronóstico de la inflación agregada de alimentos y así no incluir subgrupos definidos *ad hoc*. La calidad de una clasificación depende de la metodología utilizada para esto y de la medida de similaridad o distancia entre variables. En este caso, se consideran dos metodologías de clasificación de variables:

### ***Clasificación jerárquica de variables, o procedimiento VARCLUS***

Este método se basa en análisis de componentes principales. El objetivo es clasificar variables en grupos de manera que se maximice la proporción de varianza explicada por cada grupo o cluster. En principio todas las variables están en el mismo cluster y en cada iteración se divide el cluster que tiene el valor propio asociado a la segunda componente principal más grande, y así sucesivamente hasta obtener el número de clusters deseados o hasta satisfacer algunos criterios tales como la proporción de varianza explicada por cada cluster o hasta que ya no haya ningún cluster cuyo segundo valor propio más grande sea superior a cierto umbral. Este método utiliza como medida de similaridad el coeficiente de correlación de Spearman de las series de variaciones doce meses desestacionalizadas de los ítems del IPC de alimentos

### ***Método de Partición alrededor de medoides – PAM***

En este método, se decide *a priori* el número de grupos  $k$  que se quieren conformar y se escogen arbitrariamente  $k$  objetos llamados medoides, los cuales son los objetos (o variables) localizados más al centro de cada grupo. Cada objeto o variable es ubicado en el grupo con el medoide más cercano a éste, luego se evalúa si el medoide de cada grupo continúa siendo el adecuado, calculando el costo de cambiar el medoide actual por alguno de los otros miembros del grupo. Ese costo esta dado por

$$S = (E_{O'} - E_O); \quad E_{O'} = \sum_{i=1}^k \sum_{X_j \in G_i} d(X_j, O_i')^2, \quad \text{donde } O_i' \text{ es el medoide del } i\text{-ésimo grupo y } d(X_j, O_i') \text{ es la}$$

medida de distancia entre el objeto o variable  $X_j$  y el medoide  $O_i'$ . De tal manera, que si  $S < 0$  entonces es conveniente cambiar de medoide  $O_i'$  a  $O_i$ . El algoritmo se detiene cuando no haya mas beneficio por

cambiar de medoide y cada objeto esté ubicado en el grupo con medoide más cercano a éste. Este método de clasificación de variables es robusto a la presencia de datos atípicos.

En este caso, la medida de similaridad (o distancia) entre variables es la distancia Euclideana definida

por,  $d(X_i, X_j) = d_{i,j} = \sqrt{\frac{1}{T} \sum_{t=1}^T (X_{it} - X_{jt})^2}$ ;  $i, j = 1, \dots, 47$ , donde  $X_{it}$  corresponde al cepstro ( $X_{it} = c_{it}$ ),

siguiendo a Kalpakis et al (2001) quienes mostraron empíricamente que usando el cepstro en lugar de los datos originales<sup>7</sup> se obtiene una medida de distancia más apropiada para clasificar series de tiempo.

El Cepstro de una serie es definido como la transformación inversa de Fourier del logaritmo de la transformada de Fourier de la serie de tiempo. Así, para cada una de las 47 series de inflación de alimentos, se estimó el mejor modelo autoregresivo, siguiendo el procedimiento top-down de selección de rezagos, y teniendo en cuenta los parámetros del modelo se calcula el cepstro para cada periodo de tiempo en la muestra de la siguiente manera:

$$c_{it} = \begin{cases} -\phi_1 & t = 1 \\ -\phi_t - \sum_{m=1}^{t-1} \left(1 - \frac{m}{t}\right) \phi_m c_{t-m} & 1 < t \leq p \\ -\sum_{m=1}^p \left(1 - \frac{m}{t}\right) \phi_m c_{t-m} & p < t \end{cases}$$

donde  $\phi_m$  es el parámetro autoregresivo de orden  $m$  y  $p$  es el orden del modelo AR(p)<sup>8</sup>. Así la idea detrás de la medida de similaridad en este caso, es que los rubros de alimentos que tengan una dinámica de rezagos similar, serán clasificados en el mismo grupo.

Con las dos metodologías, los 47 ítems que componen la canasta de alimentos en el IPC fueron clasificados en cuatro grupos, para tener el mismo número de componentes que las clasificaciones ad hoc y tal que al comparar los pronóstico, el número de componentes no afecte los resultados, sino la capacidad predictiva de esas componentes sea lo que determine que un modelo de pronóstico sea mejor que otro, en términos de menor error de pronóstico. En el Gráfico 1 se exhibe la inflación observada de alimentos y sus componentes según cada una de las clasificaciones consideradas.

<sup>7</sup> o transformados para conseguir estacionariedad

<sup>8</sup> El máximo rezago significativo en el modelo.

## VI. Resultados empíricos

La Tabla 1 muestra las correlaciones del agregado de alimentos con las diferentes componentes y las correlaciones entre componentes de alimentos para cada una de las clasificaciones utilizadas. La matriz triangular superior muestra las correlaciones para la muestra 1999-2004 y la matriz triangular inferior muestra las correlaciones para la muestra completa 1999-2007. En general se observa que no hay cambios significativos en la estructura de correlaciones entre el agregado y las componentes ni entre las componentes para las dos muestras. De otro lado, se observan algunas altas correlaciones entre componentes especialmente en las clasificaciones predefinidas, sin embargo, las correlaciones entre los grupos obtenidos de las metodologías de clasificación de variables son bajas, como es de esperarse de acuerdo a su construcción, lo cual en principio favorece los modelos que consideran estas clasificaciones sobre los grupos predefinidos en cuanto a que la colinealidad es menor en el primer caso.

La Tabla 2 muestra la evaluación de pronósticos fuera de muestra, utilizando el criterio de la raíz del error cuadrático medio (RECM) para horizontes de uno a doce meses, utilizando los diferentes modelos de pronóstico descritos en la sección 3. El periodo fuera de muestra para evaluar los pronósticos es de enero/2005 – noviembre/2007. Los pronósticos son generados mediante un procedimiento recursivo, en el cual se adiciona a la muestra un periodo y se revisa nuevamente la especificación del modelo mediante el procedimiento top-down descrito anteriormente, para el caso de modelos univariados o usando los criterios de selección AIC y BIC para el caso de los modelos multivariados.<sup>9</sup> Puesto que la estructura de correlación no cambia significativamente con el tiempo (al ir ampliando la muestra), la estructura de rezagos en el modelo tampoco cambia considerablemente de un periodo a otro dentro de la muestra utilizada para evaluar pronósticos. En el Anexo 1 se encuentra una descripción de los modelos de pronóstico evaluados y la notación utilizada para referirnos a cada uno de ellos.

De la evaluación de pronósticos fuera de muestra, según criterio de la raíz del error cuadrático medio (RECM) se pueden destacar los siguientes resultados: En primer lugar, se observa que los pronósticos

---

<sup>9</sup> Para las variables exógenas se trabaja con información ya observada, ya que desafortunadamente no se cuenta con pronósticos o supuestos para el futuro de estas hechos en cada momento del tiempo.

para el agregado de la inflación de alimentos generados por modelos multivariados en general producen menor error de pronóstico que aquellos generados por modelos univariados, con algunas excepciones, como a 6 y 9 meses, que los modelos con RECM más pequeño son el AG\_ARX\_CL1 y el AG\_ARX\_CL2 respectivamente. En segundo lugar, para todos los horizontes de pronóstico de 1 a 12 meses, los pronósticos que consideran componentes del agregado son mejores que los obtenidos directamente de un modelo para el agregado en función solo de rezagos de este y otras variables exógenas. En tercer lugar, en general se destaca la mejor precisión de los pronósticos obtenidos agregando pronósticos de desagregados, notado como AG, que aquellos obtenidos incluyendo tanto rezagos del agregado como de los desagregados en el sistema (o ecuación) para generar el pronóstico del agregado, notado como AD, lo cual es observado para todos los modelos univariados y para la mayor parte de los multivariados al comparar los dos tipos de pronóstico AD y AG para cada especificación. Sin embargo, el modelo que produce menor error de pronóstico para cada horizonte si es uno del tipo AD, excepto a un mes que es uno del tipo AG (VEC\_AIC\_GR4). En cuarto lugar, no hay evidencia contundente en cuanto a cual clasificación de la canasta de alimentos produce mejores pronósticos, los resultados son mixtos entre los grupos predefinidos y aquellos obtenidos usando las metodologías de clasificación de variables, lo que indica que el hecho de reducir la multicolinealidad, no mejora significativamente la capacidad de pronóstico de la inflación agregada de alimentos.

Cuando se tiene en cuenta el mejor modelo por columna, es decir el mejor modelo de pronóstico tanto del tipo AG como AD para cada horizonte de pronóstico, los resultados parecen favorecer los modelos que consideran los grupos predefinidos. Para horizontes de 3, 6, 9 y 12 meses, el modelo que genera el menor error de pronóstico de aquellos obtenidos a partir de un modelo para el agregado que incluye tanto rezagos de este como de las componentes, es decir, de tipo AD, es uno que considera la clasificación de la canasta de alimentos según tipo de producto (G3). Solamente para el muy corto plazo, a 1 mes, un modelo basado en la clasificación a partir de la metodología VARCLUS se lleva el primer lugar, superando los modelos de grupos predefinidos.

Por su parte, para los pronósticos obtenidos agregando pronósticos de las componentes (AG), de los 5 horizontes analizados, para 3 de ellos (1, 3 y 12 meses), un modelo que considera los grupos según fuente de movimientos de precios (G4) es el que genera menor error de pronóstico. Para los restantes horizontes, 6 y 9 meses, el mejor modelo de pronóstico es uno basado en los grupos determinados a partir de las metodologías de clasificación de variables.

Analizando solamente los modelos univariados, se destaca que para horizontes a corto plazo, 1, 3 y 6 meses, el mejor pronóstico de la inflación de alimentos agregado es obtenido agregando pronósticos de tres componentes: alimentos procesados, perecederos y comidas fuera del hogar. Para horizontes de más largo plazo, el mejor pronóstico para el agregado es aquel obtenido agregando pronósticos de los grupos generados a partir de metodologías de clasificación de variables. A 6 meses, usando los grupos generados por el procedimiento VARCLUS y a 9 y 12 meses, los generados por la metodología PAM.

Analizando los modelos multivariados, parece que los modelos VEC son preferibles a los VARX. En particular, de 1 a 6 meses, los modelos VEC cuyo número de rezagos es determinado según criterio AIC, son los que producen pronósticos mas acertados para la inflación anual de alimentos. Sin embargo, a 9 y 12 meses se destaca el buen comportamiento del modelo VARX, cuyo número de rezagos es determinado según criterio BIC, y cuyas variables endógenas son la inflación agregada y las tres componentes: procesados, perecederos y comidas fuera del hogar.

La Tabla 3 muestra los resultados de las pruebas de reducción del error cuadrático medio de pronóstico. Para probar si hay una reducción significativa del error de pronóstico de un modelo respecto a otro, se utiliza la prueba de Diebold y Mariano modificada, DMM (Harvey, D. et al, 1997), en la que la hipótesis nula es que los dos modelos de pronóstico analizados producen el mismo ECM fuera de muestra y la alternativa es que un modelo (en este caso el de la fila) produce menor ECM que el otro modelo (el de la columna). La tabla exhibe los p-valores asociados al valor del estadístico de prueba DMM para cada par de modelos y cada horizonte de pronóstico. Los modelos que se evalúan con esta prueba son el modelo directo para el agregado, los tres mejores modelos multivariados y el mejor modelo univariado según el criterio RECM para cada horizonte de pronóstico. De estos resultados se destaca que el modelo univariado que incluye solamente rezagos de la inflación total y algunas variables exógenas (AGR-ARX) no produce menor error de pronóstico que ninguno de los otros modelos que tienen en cuenta componentes de la canasta de alimentos, excepto a 12 meses que ningún modelo sobresale. Varios de los modelos multivariados y para algunos horizontes el univariado si reducen significativamente el error de pronóstico al compararlos con el AGR-ARX. No hay diferencia entre los errores de pronóstico producido por los modelos multivariados en comparación con el univariado, excepto a 9 meses que el modelo AD\_VAR\_BIC\_GR3 supera al univariado que contiene los grupos determinados a partir de la metodología de clasificación de variables PAM.

Puesto que la prueba DMM aplica para modelos de pronóstico no anidados o modelos cuya capacidad predictiva esté contenida dentro de otro modelo, se realizaron pruebas de encompassing, utilizando el estadístico de prueba propuesto por Harvey, Leybourne y Newbold (1998), para probar la hipótesis si los pronósticos de un modelo encompassa a los de otro modelo, es decir si un modelo de pronóstico contiene toda la información relevante para el pronóstico y el otro modelo no aporta información adicional para generar un mejor pronóstico. Los resultados se exhiben en la Tabla 4 y muestran que en general no hay un modelo que encompassa a los demás, con algunas excepciones. En particular, a un mes, el modelo AG\_VEC\_AIC\_GR4 parece contener toda la información predictiva de los demás. Ignorando este caso, los resultados de las pruebas de reducción del error de pronóstico son válidos.

Por último, la Tabla 5, muestra la evaluación de algunos de los modelos de pronóstico de la inflación de alimentos usados por el banco central para la misma muestra de pronósticos fuera de muestra que los ejercicios presentados en este trabajo. Estos resultados son comparables con los de la Tabla 2 y de ahí se puede concluir que los pronósticos evaluados en este trabajo no superan a otras alternativas ya en uso. Es decir, no se presenta una reducción significativa en el error de pronóstico al incluir componentes en el modelo de pronóstico del agregado de alimentos o al agregar pronósticos de grupos de alimentos.

## **VII. Conclusiones**

Este estudio evalúa empíricamente diferentes alternativas o modelos de pronóstico para la inflación de alimentos basándose en información desagregada o de componentes de la canasta de alimentos en el IPC. Los resultados sugieren que pronósticos para el agregado obtenidos agregando pronósticos de subgrupos de alimentos o incluyendo rezagos de la inflación de las componentes en el modelo de pronóstico de la inflación total de alimentos, puede reducir el error de pronóstico del agregado en comparación con el pronóstico generado a partir de un modelo para el agregado que solo incluye rezagos del mismo.

Por otro lado, no hay evidencia que permita concluir si agregar pronósticos de componentes genera mejores pronósticos que los generados por un modelo para el agregado que incluye como variables

explicativas tanto rezagos del mismo como de las componentes. Los dos parecen ser buenas alternativas, con una ventaja comparativa de la segunda, de no requerir de la estimación de un modelo de pronóstico para las componentes.

Respecto a las componentes de alimentos consideradas en los modelos, si bien no se presentan cambios importantes en la colinealidad a través del tiempo en ninguna de las clasificaciones usadas, lo que reduciría la incertidumbre en los pronósticos del agregado, no es contundente que reducir la colinealidad al considerar subgrupos de alimentos menos correlacionados entre ellos, contribuya a reducir el error de pronóstico del agregado. Los grupos *ad hoc* tienen la ventaja de no cambiar en el tiempo su composición y adicionalmente cada componente tiene una interpretación o sentido económico, mientras que los grupos determinados por las metodologías de clasificación, pueden cambiar su composición, al pasar ítems de un grupo a otro al ampliar la muestra y las componentes no tienen interpretación económica sino estadística.

Por su parte, agregar pronósticos de componentes generados por un modelo multivariado para estas u obtener pronósticos para el agregado a partir de un modelo multivariado para éste y sus componentes, para casi todos los horizontes de pronóstico, produce menor error de pronóstico que agregar pronósticos de componentes generados por modelos univariados para cada componente. Lo cual es un indicio de que tener en cuenta las relaciones de causalidad entre componentes o entre estas y el agregado contribuye a mejorar el pronóstico del agregado.

Al comparar con los modelos de pronóstico de la inflación de alimentos actualmente en uso por el Banco central, no se presenta una reducción significativa en el error de pronóstico usando las metodologías presentadas en este trabajo. No obstante, se cuenta con otras alternativas de pronóstico que sirven de complemento al conjunto de pronósticos que ya se tiene y así contribuir al análisis de la inflación de alimentos y la toma de decisiones.

## **Bibliografía**

Benalal, N., Diaz, J., Landau, B., Roma, y M., Skudelny, F. (2004). To aggregate or not to aggregate?. Euro area inflation forecasting. Working paper No 374 July. European Central Bank.

Diebold, F., y Mariano, R. (1995). Comparing predictive accuracy. Journal of Business and Economic Statistics. Julio 1995, Vol. 13, No. 3.

Gomez, M., Melo, L., Gonzalez, E., y Torres, J. (2006). Forecasting Food Price Inflation in Developing Countries with Inflation Targeting Regimes: the Colombian Case. Borradores de Economía No 409. Banco de la República.

Harvey, D.; Leybourne S. and Newbold P. (1997). Testing the Equality of Mean Squared Errors. International Journal of Forecasting. 13, 281-291.

Harvey, D.; Leybourne S. and Newbold P. (1998). Tests for Forecast Encompassing. Journal of Business and Economic Statistics. Vol. 16, No 2, 254-259.

Hendry, D. (2005). Unpredictability and the foundations of economic forecasting. Working paper, Economics Department, Oxford University.

Hendry, D. and Hubrich, K (2006). Forecasting economic aggregates by disaggregates. Working paper No. 589, February. European Central Bank.

Hubrich, K. (2003). Forecasting Euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy?. International Journal of Forecasting 21(1): 119 -136.

Kalpakis, K., Gada, D., and Puttagunta, V. (2001). Distance measures for effective clustering of ARIMA time series. CSEE Department, UMBC.

Lütkepohl, H. (1987). Forecasting aggregated vector VARMA processes. Springer- Verlag.

Maldonado, D. (2007). Aplicación de modelos vectoriales autoregresivos para la proyección de la inflación en el Ecuador. Nota Técnica No 76. Dirección Investigaciones Económicas. Banco Central de Ecuador.

## Anexo 1: Modelos de Pronóstico

1. **AGREGADO**: Modelo univariado ARX para el agregado de inflación de alimentos, en función de rezagos de ella misma y otras variables exógenas.  $\Delta \ln(IPC_t) = f(\Delta \ln(IPC_{t-j}), EXO_{t-l})$
2. **AG\_ARX\_GR4**: Modelo ARX para cada uno de los 4 grupos predefinidos según causas de variación de precios. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 4 grupos.  $\Delta \ln(IPC\_G_{i,t}) = f(\Delta \ln(IPC\_G_{i,t-j}), EXO_{t-l})$
3. **AD\_ARX\_GR4**: Modelo ARX para el agregado como función de sus propios rezagos, rezagos de los grupos predefinidos según causas de variación de precios y otras variables exógenas. El pronóstico del agregado es generado por el mismo modelo.  $\Delta \ln(IPC_t) = f(\Delta \ln(IPC_{t-j}), \Delta \ln(IPC\_G_{i,t-k}), EXO_{t-l})$
4. **AG\_ARX\_GR3**: Modelo ARX para cada uno de los 3 grupos predefinidos según tipo de producto. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 3 grupos.  $\Delta \ln(IPC\_G_{i,t}) = f(\Delta \ln(IPC\_G_{i,t-j}), EXO_{t-l})$
5. **AD\_ARX\_GR3**: Modelo ARX para el agregado como función de sus propios rezagos, rezagos de los grupos predefinidos según tipo de producto y otras variables exógenas. El pronóstico del agregado es generado por el mismo modelo  $\Delta \ln(IPC_t) = f(\Delta \ln(IPC_{t-j}), \Delta \ln(IPC\_G_{i,t-k}), EXO_{t-l})$
6. **AG\_ARX\_CLI**: Modelo ARX para cada uno de los 4 grupos generados por el método de clasificación jerárquica. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 4 grupos.  $\Delta \ln(IPC\_C_{i,t}) = f(\Delta \ln(IPC\_C_{i,t-j}), EXO_{t-l})$
7. **AD\_ARX\_CLI**: Modelo ARX para el agregado como función de sus propios rezagos, rezagos de los 4 grupos generados por el método de clasificación jerárquica y otras variables exógenas. El pronóstico del agregado es generado por el mismo modelo.  $\Delta \ln(IPC_t) = f(\Delta \ln(IPC_{t-j}), \Delta \ln(IPC\_C_{i,t-k}), EXO_{t-l})$
8. **AG\_ARX\_CL2**: Modelo ARX para cada uno de los 4 grupos generados por el método de clasificación PAM. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 4 grupos.  $\Delta \ln(IPC\_C_{i,t}) = f(\Delta \ln(IPC\_C_{i,t-j}), EXO_{t-l})$

9. **AD\_ARX\_CL2**: Modelo ARX para el agregado como función de sus propios rezagos, rezagos de los 4 grupos generados por el método de clasificación PAM y otras variables exógenas. El pronóstico del agregado es generado por el mismo modelo.

$$\Delta \ln(IPC_t) = f\left(\Delta \ln(IPC_{t-j}), \Delta \ln(IPC - C_{i,t-k}), EXO_{t-l}\right)$$

10. **AG\_MUL\_GR4**: Modelo VARX donde las variables endógenas son los 4 grupos predefinidos según causas de variación de precios en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 4 grupos generados por el modelo.  $\Delta \ln(IPC - G_t) = f\left(\Delta \ln(IPC - G_{i,t-j}), EXO_{t-l}\right)$

11. **AD\_MUL\_GR4**: Modelo VARX donde las variables endógenas son el agregado de alimentos y los 4 grupos predefinidos según causas de variación de precios en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es generado por el modelo.

$$\begin{pmatrix} \Delta \ln(IPC_t) \\ \Delta \ln(IPC - G_t) \end{pmatrix} = f\left(\begin{pmatrix} \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - G_{i,t-k}), EXO_{t-l} \\ \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - G_{i,t-k}), EXO_{t-l} \end{pmatrix}\right)$$

12. **AG\_MUL\_GR3**: Modelo VARX donde las variables endógenas son los 3 grupos predefinidos según tipo de producto en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 3 grupos generados por el modelo.  $\Delta \ln(IPC - G_t) = f\left(\Delta \ln(IPC - G_{i,t-j}), EXO_{t-l}\right)$

13. **AD\_MUL\_GR3**: Modelo VARX donde las variables endógenas son el agregado de alimentos y los 3 grupos predefinidos según tipo de producto en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es generado por el modelo.

$$\begin{pmatrix} \Delta \ln(IPC_t) \\ \Delta \ln(IPC - G_t) \end{pmatrix} = f\left(\begin{pmatrix} \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - G_{i,t-k}), EXO_{t-l} \\ \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - G_{i,t-k}), EXO_{t-l} \end{pmatrix}\right)$$

14. **AG\_MUL\_CLI**: Modelo VARX donde las variables endógenas son los 4 grupos generados por el método de clasificación jerárquica en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 4 grupos generados por el modelo.  $\ln(IPC - C_t) = f\left(\Delta \ln(IPC - C_{i,t-j}), EXO_{t-l}\right)$

15. **AD\_MUL\_CLI**: Modelo VARX donde las variables endógenas son el agregado de alimentos y los 4 grupos generados por el método de clasificación jerárquica en función de sus propios

rezagos y otras variables exógenas. El pronóstico del agregado es generado por el modelo.

$$\begin{pmatrix} \ln(IPC_t) \\ \ln(IPC - C_t) \end{pmatrix} = f \left( \begin{pmatrix} \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - C_{i,t-k}), EXO_{t-l} \\ \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - C_{i,t-k}), EXO_{t-l} \end{pmatrix} \right)$$

16. **AG\_MUL\_CL2**: Modelo VARX donde las variables endógenas son los 4 grupos generados por el método de clasificación PAM en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es el promedio ponderado de los pronósticos de los 4 grupos generados por el modelo.  $\ln(IPC - C_t) = f(\Delta \ln(IPC - C_{i,t-j}), EXO_{t-l})$

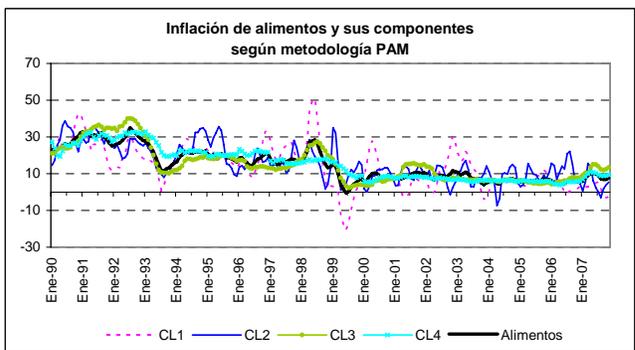
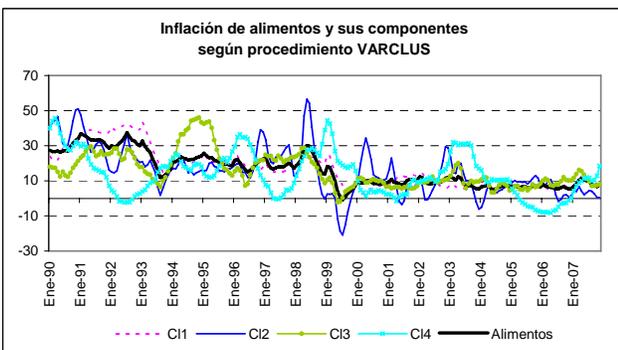
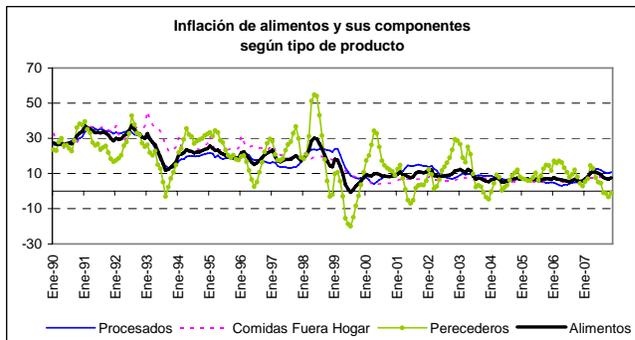
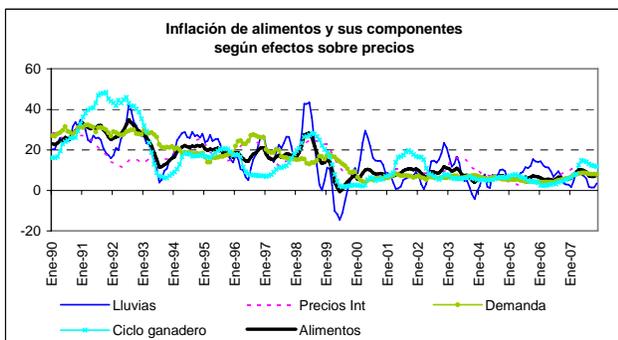
17. **AD\_MUL\_CL2**: Modelo VARX donde las variables endógenas son el agregado de alimentos y los 4 grupos generados por el método de clasificación PAM en función de sus propios rezagos y otras variables exógenas. El pronóstico del agregado es generado por el modelo.

$$\begin{pmatrix} \ln(IPC_t) \\ \ln(IPC - C_t) \end{pmatrix} = f \left( \begin{pmatrix} \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - C_{i,t-k}), EXO_{t-l} \\ \Delta \ln(IPC_{t-j}), \Delta \ln(IPC - C_{i,t-k}), EXO_{t-l} \end{pmatrix} \right)$$

Donde MUL puede hacer referencia a VAR o VEC, adicionalmente se consideran modelos cuya estructura de rezagos es seleccionada de acuerdo a los criterios AIC y BIC. EXO se refiere a una matriz de variables exógenas.

Gráfico 1.

### Inflación Alimentos y sus componentes



**Tabla 1.**  
**Correlaciones IPC alimentos y sus componentes**

Tabla 1.1 Grupos según efecto sobre precios

	DLIPC	DLGR1	DLGR2	DLGR3	DLGR4
DLIPC	1	0.89	0.59	0.66	0.70
DLGR1	0.89	1	0.40	0.39	0.44
DLGR2	0.60	0.39	1	0.61	0.43
DLGR3	0.65	0.38	0.63	1	0.58
DLGR4	0.69	0.42	0.47	0.58	1

Tabla 1.2 Grupos según tipo de producto

	DLIPC	DLGR1	DLGR2	DLGR3
DLIPC	1	0.79	0.65	0.85
DLGR1	0.78	1	0.70	0.43
DLGR2	0.65	0.71	1	0.32
DLGR3	0.85	0.42	0.32	1

Tabla 1.3 Grupos según metodología PAM

	DLIPC	DLCL1	DLCL2	DLCL3	DLCL4
DLIPC	1	0.76	0.47	0.79	0.65
DLCL1	0.77	1	0.18	0.43	0.22
DLCL2	0.49	0.19	1	0.32	0.29
DLCL3	0.78	0.44	0.30	1	0.54
DLCL4	0.65	0.24	0.27	0.51	1

Tabla 1.4 Grupos según procedimiento VARCLUS

	DLIPC	DLCL1	DLCL2	DLCL3	DLCL4
DLIPC	1	0.80	0.72	0.72	0.22
DLCL1	0.79	1	0.27	0.52	0.21
DLCL2	0.72	0.26	1	0.41	0.04
DLCL3	0.73	0.51	0.43	1	0.21
DLCL4	0.24	0.26	0.02	0.23	1

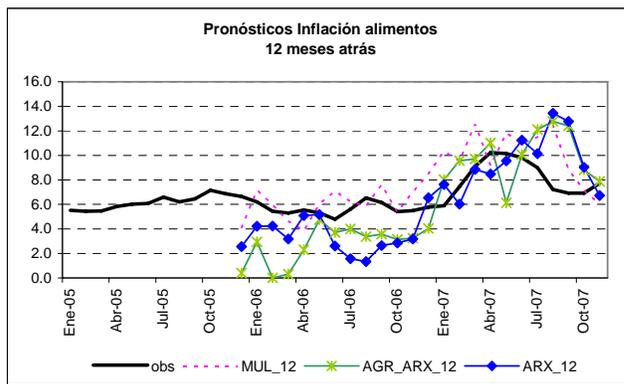
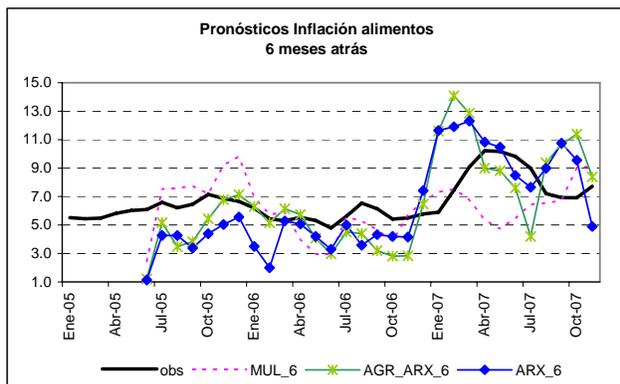
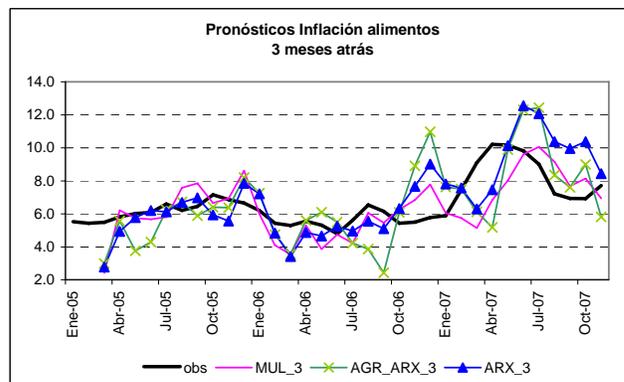
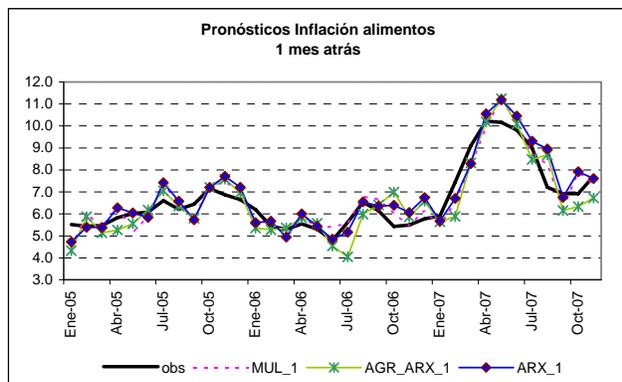
Matriz triangular superior corresponde a correlaciones para la muestra 1988-2004  
Matriz triangular inferior corresponde a correlaciones para la muestra 1988-2007

**Tabla 2.**  
**Evaluación pronósticos Inflación total de alimentos doce meses**  
**Criterio Raíz Error Cuadrático Medio (RECM)**  
**(Pronósticos fuera de muestra Enero/2005 - Octubre/2007)**

MODELO   CLASIFICACION		Horizonte de pronóstico - Meses									
		1		3		6		9		12	
		Tipo de Agregación									
		AG	AD	AG	AD	AG	AD	AG	AD	AG	AD
AGREGADO		0.814	-	2.371	-	2.854	-	2.370	-	3.018	-
UNIVARIADOS											
ARX											
	GR3	0.663	0.678	1.975	1.997	2.692	3.306	2.320	4.978	2.812	7.983
	GR4	0.705	0.818	2.017	2.861	2.653	5.597	2.227	7.681	2.749	10.801
	CL1	0.783	0.887	2.191	2.646	2.434	3.181	2.664	3.820	3.943	5.867
	CL2	0.716	0.957	2.122	2.529	2.810	3.938	2.088	32.821	2.740	60.337
MULTIVARIADOS											
VARX_AIC											
	GR3	0.952	1.061	2.803	2.891	4.043	4.670	4.303	5.641	5.832	6.565
	GR4	1.049	1.234	3.024	3.543	4.031	4.443	4.166	4.591	5.616	6.295
	CL1	1.256	1.349	3.413	3.874	3.855	4.451	4.569	5.454	6.996	7.897
	CL2	1.160	1.349	2.522	4.118	6.495	7.230	8.530	9.709	10.259	11.167
VARX_BIC											
	GR3	0.699	0.695	2.050	2.009	3.078	2.763	2.644	1.891	3.321	2.123
	GR4	0.707	0.719	1.976	1.979	2.891	2.729	2.771	2.228	3.462	2.319
	CL1	0.656	0.664	2.036	2.044	2.955	2.943	2.140	2.142	2.600	2.637
	CL2	0.707	0.691	1.923	1.839	2.568	2.554	2.272	2.158	2.938	2.784
VEC_AIC											
	GR3	0.623	0.686	1.855	1.610	2.799	2.256	3.181	2.218	3.961	2.607
	GR4	0.587	0.683	1.666	2.041	2.725	3.387	2.485	3.195	2.338	3.540
	CL1	0.594	0.600	1.835	1.821	2.887	2.880	2.933	3.049	2.369	2.418
	CL2	0.721	0.779	1.961	2.154	3.533	3.952	4.501	4.990	5.213	5.494
VEC_BIC											
	GR3	0.631	0.667	2.261	2.320	4.141	4.198	3.219	3.157	2.350	2.418
	GR4	0.630	0.741	2.402	2.711	4.812	5.459	4.750	5.816	5.083	6.586
	CL1	0.614	0.637	2.294	2.472	4.452	5.125	4.222	5.439	3.845	6.233
	CL2	0.661	0.655	2.098	2.046	3.263	3.259	3.609	3.453	3.916	3.691

## Grafico 2.

### Pronósticos Inflación Total de alimentos



Donde MUL hace referencia al mejor modelo multivariado, ARX se refiere al mejor modelo univariado y AGR\_ARX es el modelo para el agregado que solo incluye rezagos de éste.

**Tabla 3.**  
**Pruebas de Reducción de ECM de los pronósticos**  
**Prueba de Diebold y Mariano Modificada**

h=1

	AG_VEC_AIC_GR4	AG_VEC_AIC_CL1	AD_VEC_AIC_CL1	AGR_ARX	AG_ARX_GR3
AG_VEC_AIC_GR4		0.190	0.182	<b>0.042</b>	0.315
AG_VEC_AIC_CL1	0.810		0.223	0.130	0.579
AD_VEC_AIC_CL1	0.818	0.777		0.149	0.601
AGR_ARX	0.958	0.870	0.851		0.931
AG_ARX_GR3	0.685	0.421	0.399	<b>0.069</b>	

h=3

	AD_VEC_AIC_GR3	AG_VEC_AIC_GR4	AD_VEC_AIC_CL1	AGR_ARX	AG_ARX_GR3
AD_VEC_AIC_GR3		<b>0.013</b>	<b>0.002</b>	<b>0.025</b>	0.237
AG_VEC_AIC_GR4	0.987		<b>0.021</b>	<b>0.025</b>	0.282
AD_VEC_AIC_CL1	0.998	0.979		0.129	0.524
AGR_ARX	0.975	0.975	0.871		0.849
AG_ARX_GR3	0.763	0.718	0.476	0.151	

h=6

	AD_VEC_AIC_GR3	AD_VAR_BIC_CL2	AG_VAR_BIC_CL2	AGR_ARX	AG_ARX_CL1
AD_VEC_AIC_GR3		0.322	0.310	<b>0.009</b>	0.156
AD_VAR_BIC_CL2	0.678		0.477	<b>0.095</b>	0.372
AG_VAR_BIC_CL2	0.690	0.523		0.123	0.382
AGR_ARX	0.991	0.905	0.877		0.689
AG_ARX_CL1	0.844	0.628	0.618	0.311	

h=9

	AD_VAR_BIC_GR3	AG_VAR_BIC_CL1	AD_VAR_BIC_CL1	AGR_ARX	AG_ARX_CL2
AD_VAR_BIC_GR3		<b>0.000</b>	<b>0.000</b>	<b>0.008</b>	<b>0.023</b>
AG_VAR_BIC_CL1	1.000		0.284	<b>0.000</b>	0.542
AD_VAR_BIC_CL1	1.000	0.716		<b>0.001</b>	0.552
AGR_ARX	0.992	1.000	0.999		0.992
AG_ARX_CL2	0.977	0.458	0.448	<b>0.008</b>	

h=12

	AD_VAR_BIC_GR3	AD_VAR_BIC_GR4	AG_VEC_AIC_GR4	AGR_ARX	AG_ARX_CL2
AD_VAR_BIC_GR3		0.237	0.328	0.107	0.242
AD_VAR_BIC_GR4	0.763		0.521	0.192	0.282
AG_VEC_AIC_GR4	0.672	0.479		0.277	0.339
AGR_ARX	0.893	0.808	0.723		0.731
AG_ARX_CL2	0.758	0.718	0.661	0.269	

P-valores en negrilla, se rechaza la hipótesis nula: el ECM de pronóstico del modelo de la columna es igual al ECM de pronóstico del modelo de la columna, a favor de la alternativa que el ECM del modelo de la columna es mayor que el ECM del modelo de la fila

**Tabla 4.**  
**Pruebas de Encompasing de pares de modelos**  
**Prueba de Harvey, Leybourne y Newbold**

h=1

	AG_VEC_AIC_GR4	AG_VEC_AIC_CL1	AD_VEC_AIC_CL1	AGR_ARX	ARX_AG_GR3
AG_VEC_AIC_GR4		0.106	0.111	0.135	0.159
AG_VEC_AIC_CL1	<b>0.051</b>		0.619	<b>0.081</b>	<b>0.087</b>
AD_VEC_AIC_CL1	<b>0.048</b>	0.263		<b>0.085</b>	<b>0.078</b>
AGR_ARX	<b>0.005</b>	<b>0.005</b>	<b>0.006</b>		<b>0.007</b>
ARX_AG_GR3	<b>0.018</b>	<b>0.039</b>	<b>0.040</b>	0.113	

h=3

	AD_VEC_AIC_GR3	AG_VEC_AIC_GR4	AD_VEC_AIC_CL1	AGR_ARX	ARX_AG_GR3
AD_VEC_AIC_GR3		<b>0.029</b>	0.130	0.495	0.267
AG_VEC_AIC_GR4	<b>0.000</b>		<b>0.095</b>	<b>0.029</b>	0.116
AD_VEC_AIC_CL1	<b>0.000</b>	<b>0.000</b>		<b>0.045</b>	<b>0.027</b>
AGR_ARX	<b>0.003</b>	<b>0.007</b>	<b>0.005</b>		<b>0.017</b>
ARX_AG_GR3	<b>0.054</b>	<b>0.041</b>	<b>0.088</b>	0.477	

h=6

	AD_VEC_AIC_GR3	AD_VAR_BIC_CL2	AG_VAR_BIC_CL2	AGR_ARX	ARX_AG_CL1
AD_VEC_AIC_GR3		<b>0.000</b>	<b>0.000</b>	<b>0.015</b>	<b>0.010</b>
AD_VAR_BIC_CL2	<b>0.000</b>		0.430	<b>0.021</b>	<b>0.002</b>
AG_VAR_BIC_CL2	<b>0.001</b>	0.338		<b>0.000</b>	<b>0.000</b>
AGR_ARX	<b>0.004</b>	<b>0.014</b>	<b>0.015</b>		<b>0.068</b>
ARX_AG_CL1	<b>0.000</b>	<b>0.013</b>	<b>0.019</b>	0.436	

h=9

	AD_VAR_BIC_GR3	AG_VAR_BIC_CL1	AD_VAR_BIC_CL1	AGR_ARX	ARX_AG_CL2
AD_VAR_BIC_GR3		0.998	0.997	<b>0.001</b>	<b>0.000</b>
AG_VAR_BIC_CL1	<b>0.000</b>		0.674	<b>0.000</b>	<b>0.000</b>
AD_VAR_BIC_CL1	<b>0.001</b>	0.194			<b>0.000</b>
AGR_ARX	<b>0.000</b>	<b>0.000</b>	<b>0.000</b>		<b>0.004</b>
ARX_AG_CL2	<b>0.000</b>	<b>0.000</b>	<b>0.000</b>	<b>0.028</b>	

h=12

	AD_VAR_BIC_GR3	AD_VAR_BIC_GR4	AG_VEC_AIC_GR4	AGR_ARX	ARX_AG_CL2
AD_VAR_BIC_GR3		<b>0.048</b>	<b>0.019</b>	<b>0.000</b>	<b>0.000</b>
AD_VAR_BIC_GR4	<b>0.000</b>		<b>0.037</b>	<b>0.006</b>	<b>0.001</b>
AG_VEC_AIC_GR4	<b>0.035</b>	<b>0.038</b>		<b>0.033</b>	<b>0.035</b>
AGR_ARX	<b>0.000</b>	<b>0.000</b>	<b>0.000</b>		<b>0.001</b>
ARX_AG_CL2	<b>0.001</b>	<b>0.002</b>	<b>0.000</b>	<b>0.000</b>	

P-valores en negrilla, se rechaza la hipótesis nula: los pronósticos del modelo de la fila, encompasan los pronósticos del modelo de la columna

**Tabla 5.**  
**Evaluación pronósticos inflación alimentos usados por el Banco Central**  
**Raíz del Error Cuadrático Medio - RECM**

MODELO	Horizonte			
	1	3	6	9
G10	0.58	2.12	3.83	4.58
G3	0.79	1.90	2.28	2.11
G6	0.58	2.14	3.68	4.51
PONDER	0.73	1.66	2.37	2.79
REDN	0.65	1.54	2.13	2.28
TRANSF	0.69	1.49	1.80	2.09
PROMEDIO	0.59	1.56	2.41	2.90
COMBINACION	0.58	1.62	2.10	2.39