

BANCO CENTRAL DE RESERVA DEL PERÚ



HACIA UNA META EXPLÍCITA DE INFLACIÓN: ANTICIPANDO LA INFLACIÓN EN PERÚ¹

AUTOR

Diego Winkelried Quezada.²
dwinkelried@bcrp.gob.pe

ENERO 2002

¹ Trabajo presentado en el XVIII Encuentro de Economistas del Banco Central de Reserva del Perú (Lima, enero 2002).

² Los autores se desempeñan como economista en el Departamento de Análisis Macroeconómico del Banco Central de Reserva del Perú. Las opiniones vertidas en este artículo no representan necesariamente la opinión del BCRP.

HACIA UNA META EXPLÍCITA DE INFLACIÓN: ANTICIPANDO LA INFLACIÓN EN PERÚ

Resumen

Un elemento central para la implementación del Esquema de Meta de Inflación es contar con proyecciones precisas de la inflación, aspecto exhaustivamente tratado en este documento.

De una base de datos mensuales de 268 variables macroeconómicas se estima una serie de modelos VAR bivariados y se obtienen pronósticos de la inflación. Luego, se efectúa una evaluación basada en criterios de bondad predictiva y se elabora un ranking de los indicadores que presentan mayor contenido informativo en predecir la inflación. A continuación se realizan dos enfoques multivariados que buscan aumentar la precisión de los pronósticos. El primero consiste en combinar predicciones individuales y permite obtener una mejora de cerca del 15% en términos del error de predicción, con respecto a las proyecciones bivariadas. El segundo consiste en combinar la información observada, generando índices adelantados (factores) de la inflación. Para ello, se contemplan dos técnicas alternativas: (i) análisis de componentes principales y (ii) estimación de índices en sistemas de estado-espacio. El primer enfoque tiene la capacidad de sintetizar una gran cantidad de información en pocas variables y mejora en 20% las predicciones bivariadas, mientras que el segundo impone una estructura dinámica al índice compuesto y arroja pronósticos 25% superiores.

La evaluación del poder predictivo de los indicadores individuales y de las técnicas multivariadas se realizan mediante un ejercicio recursivo, donde la inflación es predicha h períodos en adelante. El sistema planteado es funcional para horizontes de hasta 18 meses y es válido, incluso, con el uso de información en tiempo real.

Abstract

A key aspect to implement an Inflation Targeting regime is to count with accurate inflation forecasts. This paper analyse exhaustively this point.

From a large database, a number of bivariate VAR models are estimated and their inflation forecasts are evaluated. Then, a ranking is set up based on the forecasting performance of each economic indicator. Next, two multivariate approaches are applied to increase the projections accuracy. The first one consists in combining individual forecasts into a compounded projection that, empirically, improves in 15% the average individual (reduces the mean squared error in 15%). The second one uses data reduction techniques to generate composite leading indices or factors. Two techniques are considered: (i) Principal Components Analysis that improves the forecasts in almost 20% and (ii) Unobservable Variables estimation through State-Space models that performs 25% better.

The predictive evaluation of each economic indicator and multivariate approach is based on a recursive exercise where h -period ahead out-of-the-sample forecasts are analyzed. The proposed system is useful with forecast horizons up to 18 months and works well with real time data as well.

Hacia una Meta Explícita de Inflación: Anticipando la Inflación en el Perú

Diego Winkelried Q.

Quite simple, good forecasts lead to good decisions
Diebold & López (1996)

1. Introducción

La idea de que un banco central fundamente sus acciones de política en estimaciones de la futura evolución de la economía no sólo ha sido discutida y desplegada en foros académicos, sino que ha despertado el interés de los diseñadores de política³, tanto en economías industrializadas como en mercados emergentes. El comportamiento anticipado y preventivo de las autoridades monetarias es cada vez más común, siendo una de sus expresiones mejor lograda la puesta en marcha de esquemas de metas de inflación, *Inflation Targeting*, donde los pronósticos de inflación de los bancos centrales adoptan el rol de metas intermedias.

El Banco Central de Reserva del Perú (BCRP) no es la excepción a esta corriente. Desde 1994 viene anunciando rangos objetivos anuales y proyecciones multianuales de la inflación y ha mostrado una gran efectividad en cumplir con los propósitos trazados. Si bien actualmente el régimen monetario del BCRP se cataloga como *control de cantidades* por considerar a la tasa de crecimiento de la emisión primaria como meta intermedia, existen una serie de elementos del esquema de metas de inflación que se han venido practicando y desarrollando, siendo el más notable el mencionado anuncio de metas⁴. A inicios del año 2001, el BCRP puso en manifiesto la posibilidad de adoptar este esquema totalmente⁵, a fin de consolidar los éxitos obtenidos en la década de los noventa y de ser partícipe de una mayor comunicación con el público y operar con mayor transparencia.

En este documento se indaga y se discute una serie de aspectos vinculados con uno de los componentes más importantes del esquema de metas inflacionarias: la predicción de la inflación. Tomando como antecedentes las investigaciones de Barrera (1997, 1999), se desarrolla un sistema de predicción de la inflación de corto y mediano plazo con modelos bivariados lineales. Asimismo, se construyen índices adelantados de la inflación, a partir de sus indicadores anticipados individuales más importantes. La principal motivación detrás de ello no sólo se encuentra en obtener pronósticos puntuales de la inflación, sino en determinar aquellos conjuntos de información que adelanten con la suficiente anticipación (cualitativamente) el comportamiento del objetivo del BCRP, de modo que se tenga el suficiente margen de maniobra para modificar oportunamente la posición de la política monetaria.

La literatura concerniente con predicciones es amplia y creciente⁶. Este documento recopila un conjunto considerable de criterios de evaluación y los consolida con el fin de encontrar los principales indicadores adelantados de la inflación en Perú y establecer *rankings* de desempeño.

³ Svensson (1996, 1997) da racionalidad y describe las principales ventajas de que este tipo de comportamientos por parte de las autoridades monetarias. Véase, además, Mishkin (2000).

⁴ Otros elementos relacionados tienen que ver con prácticas hacia una mayor transparencia operativa y una mejor comunicación con el público, como la publicación del Programa Monetario desde el año 2000 y el anuncio de metas mensuales para la meta operativa desde el año 2001. Véase Armas et. al. (2001).

⁵ El 15 y 16 de marzo se llevó a cabo en la sede institucional del BCRP el seminario internacional de *Metas de Inflación en el Perú*, organizado conjuntamente por el BCRP y el FMI (consultar el portal del BCRP, www.bcrp.gob.pe).

⁶ Una buena recopilación bibliográfica se encuentra en Diebold & López (1996).

Además, se estudia la posibilidad de mejorar, en términos de precisión y horizonte predictivo, los pronósticos conseguidos con indicadores individuales, a través de la combinación de predicciones y de la composición de índices adelantados. Para tales efectos, se realiza una simulación sobre el poder predictivo de modelos VAR bivariados, basada en evaluaciones fuera de la muestra. Este aspecto es fundamental ya que es conocido que las conclusiones obtenidas en el análisis dentro de la muestra rara vez son coincidentes con aquéllas deducidas fuera de la ella⁷, que son las relevantes en una dimensión práctica. Asimismo, este fenómeno tiene que ver con la denominada *sobrestimación* de datos: una especificación que estima y explica de forma poco realista los datos observados, en el sentido de capturar hechos históricos que difícilmente serán repetidos en el mediano plazo, normalmente contradice el fin de obtener buenas predicciones fuera de la muestra⁸. Por este motivo, junto con la reducida muestra con la que se cuenta⁹, la parsimonia es una de las piedras angulares en el diseño del sistema explicado posteriormente.

En este trabajo se pretende alcanzar dos objetivos puntuales. En primer lugar, brindar evidencia, alternativa a la ya conocida, sobre aquellos indicadores adelantados que ayuden a pronosticar la inflación en períodos de un año y más, dada la necesidad de plantear un esquema multianual en el diseño de la política monetaria, obedeciendo a criterios que resaltan las propiedades “deseables” de un pronóstico. Ello no sólo permite obtener una trayectoria incondicionalmente estimada de la inflación futura, sino que puede ser de gran utilidad para investigaciones posteriores que incluyan el planteamiento de relaciones estructurales y permitan un mayor conocimiento de los mecanismos de transmisión de la política monetaria. Con la misma perspectiva, las proyecciones generadas por el sistema presentado podrían servir como base de predicciones basadas en modelos estructurales y en simulaciones de política.

En muchos países, sobre todo industrializados, la toma de decisiones de los agentes económicos se basan en el seguimiento de algún *índice compuesto adelantado* típicamente del producto y la inflación. Este tipo de índices son calculados por agencias gubernamentales o privadas y son una manera efectiva de guiar las expectativas tanto de agentes privados como de las autoridades. En países como Perú, esta cultura es inexistente, básicamente por falta de experiencia en la construcción de estos indicadores, que implica juicios de valor del personal de la mencionada agencia, y el aparente desinterés en promulgarlo. A partir de criterios estadísticos (y no necesariamente teóricos o intuitivos) este trabajo construye un gran número de índices adelantados de la inflación y muestra su buen desempeño, con respecto a pronósticos convencionales. Así pues, el segundo objetivo planteado es exponer esta práctica en el manejo de la información y trata de rescatar algunos aspectos particularmente útiles de los índices compuestos como indicadores en el monitoreo y seguimiento de la política monetaria.

El documento se organiza de la siguiente manera. En la segunda sección se presentan los aspectos metodológicos empleados en las predicciones realizadas. Se exponen los criterios de evaluación utilizados, así como la forma de combinar proyecciones y componer índices. En la tercera sección, se describe el funcionamiento de las simulaciones llevadas a cabo y algunas particularidades saltantes de los datos empleados. La sección cuatro presenta los resultados más importantes en términos del perfil de los indicadores individuales *vis-a-vis* las proyecciones combinadas y los índices compuestos, horizontes predictivos y predicción en tiempo real, mientras que la quinta sección concluye. Los resultados más relevantes (cuadros estadísticos) son presentados al final del documento. Resultados intermedios están disponibles bajo pedido al autor.

⁷ Véase Chauvet (2000).

⁸ Por ello, junto con criterios estadísticos provenientes de los datos, la única “variable” exógena contemplada en los modelos estimados es un intercepto (se probaron especificaciones con tendencias, *dummies* de corrección por un supuesto quiebre en tendencia de la inflación hacia fines de 1994, tendencia cuadrática y *dummies* de estacionalidad). Mayor detalle en Zha (1998).

⁹ Algo más de 100 observaciones. No es conveniente incluir observaciones anteriores a 1991 – 1992 ya que en los primeros años de esa década se aplicaron una serie de medidas de estabilización y reformas estructurales, para corregir el exagerado desorden macroeconómico del Perú originado a fines de los ochenta (pasando por un proceso hiperinflacionario).

2. Aspectos Metodológicos

En adelante, se utilizará la siguiente notación: la inflación en el período t es denotada por p_t y con el regresor x_{it} se desea obtener un pronóstico de h períodos en adelante, siendo la última observación realizada la del período T . Asimismo, i es el subíndice que indica cuál de las m variables disponibles es utilizada ($i = 1, 2, \dots, m$) mientras que el subíndice j se refiere a algún período pronosticado ($j = 1, 2, \dots, h$).

2.1 Enfoque Bivariado y Criterios de Evaluación

Como punto de partida en el análisis de las características y bondades de los potenciales predictores o indicadores adelantados de la inflación, se plantea el sistema bivariado

$$\begin{aligned} p_t &= a_p + b_p(L)x_{i,t-1} + r_p(L)p_{t-1} + m_{p,t} \\ x_{i,t} &= a_x + b_x(L)x_{i,t-1} + r_x(L)p_{t-1} + m_{x,t} \end{aligned} \quad \dots(1)$$

donde los órdenes de los polinomios b_p , b_x , r_p y r_x son establecidos por separado con el propósito de minimizar el criterio de información de Schwarz de cada ecuación, para así obtener especificaciones parsimoniosas y evitar las limitaciones de sobreestimación comentadas en la sección anterior. Ya que este procedimiento no asegura la coincidencia del número de regresores en ambas ecuaciones, la estimación de (1) vía MCO puede ser ineficiente por lo que el sistema es estimado vía SUR¹⁰, como lo sugieren estudios desde Zellner & Palm (1962)¹¹.

Con la especificación (1) es posible lograr la predicción condicional de la inflación con información disponible en T , definida como la extrapolación lineal de (1),

$$\hat{p}_{i,T+j/T} = \hat{a}_p + \hat{b}_p(L)\hat{x}_{i,T+j-1/T} + \hat{r}_p(L)\hat{p}_{T+j-1/T} \quad \dots(2)$$

donde $\hat{z}_{t/T} = z_t$ si $t \leq T$. A partir de ella, se computa el *Error de Predicción*

$$e_{i,j} = p_{T+j} - \hat{p}_{i,T+j/T} \quad \dots(3)$$

La raíz del promedio de los cuadrados de (3), la *Raíz del Error Cuadrático Medio*, resulta ser uno de los indicadores de bondad predictiva más divulgado y usualmente el único criterio de evaluación utilizado. Sin embargo y por razones expuestas en la sección 3, el uso de medidas alternativas resulta ventajoso. A continuación éstas son descritas.

En primer lugar, a partir del error cuadrático medio, el tradicional coeficiente de desigualdad de Theil (1961), conocido como *U de Theil*, puede ser determinado según

$$U = \frac{\sqrt{\sum_{j=1}^h (p_{T+j} - \hat{p}_{T+j/T})^2}}{\sqrt{\sum_{j=1}^h p_{T+j}^2 + \sum_{j=1}^h \hat{p}_{T+j/T}^2}} \quad \dots(4)$$

¹⁰ La forma de especificar y estimar cada modelo bivariado puede ser considerada como un caso intermedio entre la práctica tradicional de elegir el mismo orden para los polinomios de ambas ecuaciones a través de la minimización de criterios de información del sistema en conjunto y la identificación de submodelos (modelos con restricciones de exclusión) presentada en Barrera (1997). El primer procedimiento no es funcional en muestras pequeñas y típicamente sobreestima los datos por lo que su perfil predictivo es limitado; por su parte, si bien la estimación por MCG de los submodelos restringidos parsimoniosos de Barrera (1997) genera proyecciones altamente satisfactorias al mejorar la precisión de los parámetros estimados, su superioridad no es clara con respecto al presente planteamiento SUR.

¹¹ Puntualmente, se adaptó el algoritmo de estimación *stepwise* expuesto en Neumaier & Schneider (2000) de modo que las principales características del método SUR fueron rescatadas.

La U de Theil es una medida acotada entre cero y uno, de modo que la proyección perfecta está asociada con un valor nulo de U ¹².

En segundo lugar, como requisito indispensable de bondad, una predicción debe ser insesgada. Típicamente el criterio utilizado para ello es la proporción de sesgo deducida a partir del error cuadrático medio. No obstante, con el fin de verificar esta característica se ejecuta la denominada *Prueba de Racionalidad*¹³. La idea fundamental detrás de este contraste es que el error de predicción sea centrado en cero y que la predicción haya sido efectuada racionalmente, es decir que este error no se encuentre correlacionado con cualquier información disponible en el período T . Dado que la evaluación se realiza sobre sistemas bivariados, el segundo requisito no se cumplirá necesariamente. Asimismo, su implementación implica el uso de sondeos heurísticos de información, que pueden resultar ociosos. Por esta razón solo se analiza el primer aspecto de racionalidad mencionado. La hipótesis de que la proyección sea insesgada es equivalente a afirmar que en la regresión

$$p_{T+j} = a_0 + a_1 \hat{p}_{i,T+j/T} + v_{T+j} \quad \dots(5)$$

se cumple simultáneamente que $a_0 = 0$ y $a_1 = 1$, por lo que una prueba conjunta es planteada¹⁴.

La tercera medida de bondad predictiva trata de responder cuán efectivo es un modelo en predecir la *dirección de cambio* del nivel de la inflación, sin reparar en consideraciones de sesgo (cuán lejos se encuentra el valor puntual predicho del observado). Para tales efectos se calcula una *matriz de confusión*¹⁵,

$$P = \begin{bmatrix} (\Delta p_{T+j} > 0)(\Delta \hat{p}_{i,T+j/T} > 0) & (\Delta p_{T+j} > 0)(\Delta \hat{p}_{i,T+j/T} \leq 0) \\ (\Delta p_{T+j} \leq 0)(\Delta \hat{p}_{i,T+j/T} > 0) & (\Delta p_{T+j} \leq 0)(\Delta \hat{p}_{i,T+j/T} \leq 0) \end{bmatrix} \quad \dots(6)$$

Las columnas de P corresponden a los movimientos de la serie observada mientras que las filas de P corresponden a los movimientos de la serie predicha. Por ejemplo, el elemento P_{11} muestra el número de veces que tanto la proyección como la inflación observada se incrementaron entre tanto P_{12} indica el número de veces en que mientras la inflación observada aumenta, su predicción disminuye (o permanece constante). En este sentido, la diagonal de P indica acertadas predicciones direccionales mientras que los elementos fuera de la diagonal constituyen un conteo de predicciones incorrectas. El perfil agregado de esta matriz es medido a través de la *Tasa de Confusión*,

$$CR = 100 \cdot \frac{P_{11} + P_{22}}{P_{11} + P_{22} + P_{12} + P_{21}} \quad \dots(7)$$

que no es más que el porcentaje de veces que los movimientos predichos coincidieron con los observados¹⁶.

¹² Mediante simulaciones de Monte Carlo, Granger & Newbold (1986) encuentran que (4) no es una buena medida de predicción en modelos autorregresivos. Este resultado no es necesariamente válido en un contexto VAR por lo que el estadístico (4) es empleado. Véase Armstrong & Fildes (1995).

¹³ Véase Theil (1961), Keane & Runkle (1989), Webb (1991) y Joutz & Stekler (2000).

¹⁴ Si fuera posible disponer de toda la información relevante en predecir p_t , esta hipótesis equivale a afirmar que v_t es caracterizado por un proceso $MA(h-1)$. Véase Cumby & Huiznaga (1992).

¹⁵ La matriz de confusión (6) puede ser definida, alternativamente, en términos del rango objetivo de inflación preanunciado por el BCRP. Es decir, se trata de un conteo de cuántas veces la inflación y su pronóstico cayeron por encima o debajo del punto medio del rango o dentro (o fuera) las bandas inflacionarias.

¹⁶ Existe una considerable batería de pruebas estadísticas más formales que la simple observación de una Tasa de Confusión, como el contraste Peseran & Timmerman (1994). Para mayor detalle, consúltese Swanson & White (1995) y Diebold & López (1996).

En muchas ocasiones, pronósticos de dos regresores pueden contener la misma información estadística (a pesar de que ambos difieran). A partir de este hecho y basados en pruebas previas¹⁷, Diebold & Mariano (1996), desarrollan un enfoque general de comparación de predicciones. Si

$$d_t = e_{r,t}^2 - e_{s,t}^2$$

es la diferencia de los valores de dos funciones de pérdida cuadráticas (para dos modelos r y s), se tiene el estadístico

$$DM_{rs} = \frac{\bar{d}}{\sqrt{\hat{\text{var}}(d_t)}} = \frac{\sqrt{h} \sum_{j=1}^h d_j}{h \sqrt{\mathbf{g}_0 + 2 \sum_{j=1}^{h-1} \mathbf{g}_j}} \quad \dots(9)$$

que es asintóticamente normal estándar bajo la hipótesis nula de igualdad de bondad predictiva ($E[d_t] = 0$), donde \mathbf{g} es la función de autocovarianza de d_t . Así, si DM_{rs} es positivo y significativo se puede rechazar la hipótesis de que los errores de dos predicciones no son significativamente distintos, es decir, la predicción de un modelo es superior.

Finalmente, la estabilidad del comportamiento de la inflación modelado en (1) es una propiedad económica y estadísticamente deseable ya que es conocido que la falta de estabilidad de un modelo está coligada con fracasos en sus predicciones¹⁸. Bajo esta motivación, una *Prueba de Orden de Wilcoxon*, cuya hipótesis nula puede resumirse en que dos muestras provienen de la misma distribución poblacional, es adecuada. Así, si esta hipótesis es aceptada al comprar la proyección de \mathbf{p}_t con sus valores observados, puede concluirse estabilidad de (1). Por su parte, convencionalmente, el término “estabilidad” se entiende como sinónimo de “constancia de parámetros”. Por ello, se aplica la prueba *F-secuencial promedio*, *AveF*, según Hansen (2000) a la primera ecuación de (1).

2.2 Enfoque Multivariado

La principal crítica al enfoque bivariado de la sección anterior es que modelos como (1) son muy restrictivos. Ciertamente, éstos pueden ser concebidos como una abstracción intencional del verdadero proceso generador de datos de la inflación. Del mismo modo, basar acciones de política en el pronóstico de un único indicador, aunque sea bueno y estable, conlleva al riesgo de caer en considerables errores de predicción como resultado de características y cambios idiosincrásicos, no modelados, del mencionado indicador¹⁹. No obstante, el desarrollo de modelos bivariados puede entenderse como el punto de partida en la selección de los conjuntos de información de mayor capacidad predictiva de la inflación. Sin abandonar el carácter lineal adoptado en este trabajo, la solución natural a las limitantes mencionadas se centra en plantear sistemas multivariados. Sin embargo, la pérdida acelerada de grados de libertad ante la inclusión de variables adicionales en (1) es costosa en términos de sobreestimación y de deficiente desempeño predictivo, dado el reducido tamaño del espacio muestral con el que se cuenta.

En esta investigación, se opta por dos enfoques alternativos que mantienen la parsimonia de modelos como (1). El primer enfoque, de larga data²⁰, consiste en tratar a las proyecciones de los modelos bivariados como datos y combinarlas. El segundo enfoque radica en construir índices compuestos de un gran conjunto de indicadores individuales y tratarlos como una nueva variable, dentro del contexto bivariado desarrollado. En la medida en que ambas opciones

¹⁷ Pruebas como la de Morgan, Granger & Newbold o la de Messe & Rogoff, todas ellas citadas en Diebold & Mariano (1996), brindaron resultados similares.

¹⁸ Véase Ericsson (1992) para una buena recopilación bibliográfica al respecto.

¹⁹ Véase Dion (1999).

²⁰ Véase Clemen (1989). Para el caso peruano una buena aproximación se encuentra en Barrera (1999).

incluyen una mayor cantidad de información potencialmente *relevante* al proyectar la inflación, se espera que el perfil de las mismas supere a los resultados de los modelos bivariados.

2.2.1 Combinación de Predicciones

Diebold & López (1996) señalan que combinar predicciones puede entenderse como el importante vínculo entre el corto plazo, en donde existen limitaciones de tiempo, información e incluso de correctas especificaciones dinámicas de las variables, y el largo plazo, donde se asume como concluido el desarrollo de modelos econométricos completos de buen desempeño predictivo. A pesar de que desde una perspectiva teórica es óptimo combinar conjuntos de información y no proyecciones, el pragmatismo y la sencillez de esta práctica la vuelven sumamente atractiva. Combinar predicciones es motivado por encontrar mejores indicadores de bondad ya que se trata de rescatar las virtudes de distintos pronósticos y sintetizarlos en una predicción compuesta.

Recordando que (2) define a la proyección de \mathbf{p}_t del modelo i con información disponible hasta el período T , puede pensarse en un pronóstico combinado (de $n \leq m$ modelos) de la forma

$$\hat{\mathbf{p}}_{c,T+j/T} = \sum_{i=1}^n w_i \hat{\mathbf{p}}_{i,T+j/T} \quad \dots(10)$$

La práctica común de las proyecciones denominadas “de consenso”²¹ se reduce en evaluar la mediana de los pronósticos individuales o su promedio (esto es, $w_i = 1/n$). Esta perspectiva puede ser limitada: considere por ejemplo un pronóstico r ($\leq n$) sesgado; si n no es lo suficientemente grande, (10) puede recoger las fuentes de este sesgo y ser sesgado, problema que es superado si $w_r = 0$. Bajo esta lógica, es conveniente determinar las ponderaciones w con información dentro de la muestra, a partir de la regresión

$$\mathbf{p}_{T+j} = \sum_{i=1}^n w_i \hat{\mathbf{p}}_{i,T+j/T} + \mathbf{x}_{T+j} \quad \dots(11)$$

Dadas las magnitudes de n y T (incluso es probable que $n > T$), la estimación de (11) (de ser posible) tendrá en el mejor de los casos, un número reducido de grados de libertad por lo que el uso de MCO es ineficiente y descartado. Ante ello, Stock & Waston (1999) proponen el estimador de *Regresión por Cordillera*

$$\hat{w}_T = (cI_n + \sum_{t=1}^T \hat{\mathbf{p}}_t \hat{\mathbf{p}}_t')^{-1} (\sum_{t=1}^T \hat{\mathbf{p}}_t \mathbf{p}_{t+j} + c/n) \quad \dots(12)$$

donde $\hat{w}_T = (\hat{w}_{1,T}, \dots, \hat{w}_{n,T})'$, $\hat{\mathbf{p}}_t = (\hat{\mathbf{p}}_{1,t+j/T}, \dots, \hat{\mathbf{p}}_{n,t+j/T})'$ y $c = k \cdot \text{tr}(n^{-1} \sum_{t=1}^T \hat{\mathbf{p}}_t \hat{\mathbf{p}}_t')$ ²².

El parámetro k es una constante de control. Puede apreciarse que si $k = 0$, la estimación de w es equivalente a la de MCO mientras que conforme $k \rightarrow \infty$, el estimado de $w \rightarrow 1/n$. Si bien es posible estimar k , se opta por elegirlo entre una gama arbitraria de valores de modo que la combinación obtenida sea precisa²³.

²¹ Véase, por ejemplo, Harvey & Newbold (2000).

²² Este estimador es similar a la técnica bayesiana (Diebold & Pauly, 1990 y Diebold & López, 1996)

$$\hat{w}^{post} = (Q + \sum_{t=1}^T \hat{\mathbf{p}}_t \hat{\mathbf{p}}_t')^{-1} (\sum_{t=1}^T \hat{\mathbf{p}}_t \hat{w}^{mco} + Q \hat{w}^{prior})$$

donde Q es la matriz de precisión *a priori* y w^{mco} es el estimador mínimo cuadrático de w . Note el estimador bayesiano es idéntico a (12) si $Q = cI_n$ y la distribución *a priori* de w es uniforme.

²³ En Barrera (1999) los ponderadores w son elegidos a partir de la maximización de una función de entropía basada en el supuesto de que éstos son uniformemente distribuidos, sujeta a condiciones de estabilidad de las proyecciones. Este planteamiento lleva a que $w_{i,T} = 1/n + a_{i,T}$, donde $a_{i,T}$ es inversamente proporcional a la varianza del error en predecir \mathbf{p}_{T+1} con \mathbf{x}_i con información a T . Aunque es difícil establecer comparaciones analíticas entre la propuesta de Barrera y la utilizada en este trabajo,

2.2.2 Extracción de Factores

Como enfoque alternativo a la combinación de predicciones existe la inquietud de determinar hasta qué punto composiciones de dos o más variables pueden generar una serie de datos que contenga información útil al predecir la inflación. En otras palabras, se trata de averiguar si la información relevante observada puede ser *resumida* en un (o varios) índice(s), denotado(s) por C_t . Una vez determinado C_t se estima el sistema bivariado

$$\begin{aligned} \mathbf{p}_t &= \mathbf{a}_p + \mathbf{d}_p(L)C_{t-1} + \mathbf{r}_p(L)\mathbf{p}_{t-1} + \mathbf{m}_{p_c,t} \\ C_t &= \mathbf{a}_c + \mathbf{d}_c(L)C_{t-1} + \mathbf{r}_c(L)\mathbf{p}_{t-1} + \mathbf{m}_{c,t} \end{aligned} \quad \dots(13)$$

y se aplican los criterios de evaluación expuestos en la sección anterior.

Existen varios motivos por los que el uso de índices es atractivo en el contexto desarrollado, siendo los más importantes la parsimonia y simplicidad. Si cada de las n variables incluidas en C_t contiene información útil al predecir la inflación, es lógico concluir que C_t será un buen predictor de la misma²⁴. Del mismo modo, al encontrar un grupo de variables que prediga adecuadamente la inflación, el uso de índices permite cambiar el análisis individual de cada regresor por el de este grupo, lo que puede resultar sumamente conveniente al comunicar o explicar los orígenes de las proyecciones de inflación.

Si se define a

$$\mathbf{X}_T = [x_{1,T}, x_{2,T}, \dots, x_{n,T}]$$

como un (sub)conjunto de los datos disponibles en T , la manera más sencilla y automática de combinarlos resulta ser el promedio ponderado

$$C_t = \sum_{i=1}^n c_i x_{i,t} \quad \dots(14)$$

Bajo esta perspectiva, C_t es conocido como *índice compuesto*. Existe una larga tradición, sobre todo en países industrializados, en el uso y monitoreo de este tipo de indicadores, básicamente destinados a anticipar picos o valles del ciclo económico²⁵.

La elaboración de índices como (13) presenta la ventaja de que, al tratarse de una suma ponderada, elimina parte del ruido de cada indicador individual. Si el conjunto de indicadores x_i se adelanta a la variable por predecir (la inflación), presiones que generen movimientos simultáneos en la mayoría de ellas se verán reflejadas en el índice mientras que movimientos aislados de cada indicador no influenciarán significativamente su comportamiento. Los ponderadores c_i típicamente resultan ser una medida inversa de la variabilidad de x_i y son determinados sobre la base tanto de información cualitativa sobre x_i como por la experiencia de los departamentos de investigación que diseñan y publican los índices compuestos²⁶, al no existir elementos teóricos convencionalmente aceptados que respalden tal decisión²⁷.

experimentos de Monte Carlo (no reportados) sugieren que ambos procedimientos son similares (en términos de minimizar la norma del diferencial de los vectores w obtenidos con cada método) conforme aumenta n y k no es mayor a 0.75. Asimismo, una aparente limitación de la primera propuesta es la presencia usual de ponderadores negativos, que ocurre con el método de regresión por cordillera sólo con valores reducidos de k (aunque en este caso el problema es simple de afrontar).

²⁴ Determinar las n variables que forman C_t implica un algoritmo heurístico de búsqueda a partir de los resultados bivariados más relevantes.

²⁵ Aunque en estudios como Diebold & Rudebusch (1991) estos índices son utilizados como predictores del nivel de producción y no sólo de sus *turning points*.

²⁶ Como parte del diseño empírico de esta investigación, se construyeron una serie de índices compuestos y de difusión como (1) según The Conference Board (1997, p. 6 y 11). Lamentablemente los resultados obtenidos no fueron alentadores, incluso utilizando distintas medidas de variabilidad como la desviación estándar de las x_i y el desvío medio del valor absoluto de sus primeras diferencias.

²⁷ Excepciones son De Leeuw (1991) y Emerson & Hendry (1996).

En este trabajo se opta por el uso de métodos de *reducción de datos* o variables. Ello implica la aplicación de técnicas estadísticas o estimaciones condicionales en el cálculo de los ponderadores de (13). Seguidamente se exponen los dos enfoques utilizados. A fin de diferenciar la noción de un índice compuesto como (13) (donde c_i es “cualitativamente” determinado) de índices estimados, estos últimos serán denominados *factores*²⁸ por lo que la “construcción del índice compuesto” será llamada *Extracción de Factores*.

2.2.2.1 Factores Estáticos: Componentes Principales

El análisis de Componentes Principales es una práctica multivariada de evaluación ampliamente utilizada cuando se cuenta con grandes conjuntos de información y se desea expresar los patrones y correlaciones del espacio muestral en un conjunto de menor dimensión ($n \leq m$)²⁹.

La intuición detrás de la construcción de los Componentes Principales de un conjunto de datos es sencilla. Se trata de hallar combinaciones lineales de las columnas de X_T (cuya matriz de covarianzas es V) de modo que sus varianzas sean máximas, lo que garantiza haber extraído de X_T la mayor cantidad de información posible. En otras palabras, se trata de encontrar una matriz $Z_T = c'X_T$ tal que $\Lambda = c'Vc$ sea maximizada, sujeto a $c'c = 1$ ($\text{tr}(\Lambda) < \infty$). Este problema de optimización lineal cuadrático es equivalente a computar los valores y vectores propios de la matriz V . Así, el i -ésimo Componente Principal del conjunto de datos es $z_{i,T} = c_i'X_T$ donde c_i es el i -ésimo vector propio de norma unitaria de V y $Z_T = [z_{1,T}, z_{2,T}, \dots, z_{n,T}]$ y $c = [c_1, c_2, \dots, c_n]$.

Cada Componente Principal tiene la particularidad de extraer de los datos la máxima varianza posible que no ha sido extraída anteriormente. Ello implica que los valores propios de la matriz V (las varianzas de las columnas de Z_T) son ordenados de manera descendente de modo que la raíz asociada con c_1 es mayor a la asociada con c_2 y así sucesivamente. Si el conjunto de información es grande, es probable que $z_{m,T}$ tenga una varianza muy reducida y no sea útil en el análisis de datos. El número de componentes principales n (aunque arbitrario) es determinado de modo que recoja cerca de las dos terceras partes de la varianza de los datos originales³⁰.

Si bien este enfoque es muy popular en el análisis y extracción de factores, no existe sustento teórico incuestionable para determinar si efectivamente su uso mejora el poder predictivo de los datos en cuestión. En todo caso, si dentro de X_T se encuentran variables esenciales del proceso generador de datos de la inflación, un algoritmo de búsqueda heurística sobre la construcción de los Componentes Principales debería mejorar el potencial predictivo de los datos disponibles. Esta búsqueda implica la construcción de *millones* de componentes que respondan a todas las posibles combinaciones de las m variables disponibles. Lamentablemente, implementar este algoritmo es prohibitivamente costoso³¹ por lo que la construcción de factores debe ser restringida.

2.2.2.2 Factores Dinámicos

Una manera alternativa de reducir los datos, con mayor respaldo teórico e intuitivo, es propuesta por Stock & Watson (1990, 1991 y 1998)³². Para emplear este enfoque es necesario conjeturar que se conoce *a priori* un grupo de n variables, $X_t = [x_{1,t}, x_{2,t}, \dots, x_{n,t}]'$ (expresadas como desvíos de sus respectivas medias), que son indicadores adelantados de la inflación y que cada una de

²⁸ Stock & Watson (1992, 1998).

²⁹ Este análisis es estándar como solución puramente estadística al problema de colinealidad muestral. Por tal motivo, la exposición del método en este trabajo es breve.

³⁰ Formalmente, se elige n de tal forma que $\sum_{i=1}^n \text{var}(z_{i,T}) \approx \frac{2}{3} \sum_{i=1}^m \text{var}(x_{i,T})$.

³¹ Si se tiene un total de 10 [13] variables, el número de posibles combinaciones de las mismas es 1023 [8099]. Si se dispone de 100 variables, el número de combinaciones es de 1.27×10^7 . Con el conjunto de más de 250 series de datos disponible en este estudio, el número de combinaciones es inimaginable.

³² Véase también Kim & Nelson (1999, pp. 48 - 53) y Chauvet (2000).

ellas es la suma de un factor común³³ C_t y de un elemento idiosincrásico, propio. Este supuesto manifiesta la noción de que comovimientos de múltiples series de tiempos provienen de la misma fuente, C_t ; dado que precisamente, son estos comovimientos los que albergan el poder predictivo sobre la inflación de indicador adelantado, C_t puede ser concebido como un índice compuesto adelantado. La discusión anterior puede ser abreviada en el sistema

$$X_{i,t} = \mathbf{g}_i C_t + v_{i,t} \quad \dots(15)$$

$$C_t = \mathbf{f}_1 C_{t-1} + \mathbf{f}_2 C_{t-2} + \dots + \mathbf{f}_p C_{t-p} + \mathbf{h}_t \quad \mathbf{h}_t \sim iid(0, \mathbf{s}_h^2) \quad \dots(16)$$

$$v_{i,t} = \mathbf{y}_{i,1} v_{i,t-1} + \mathbf{y}_{i,2} v_{i,t-2} + \dots + \mathbf{y}_{i,q} v_{i,t-q} + \mathbf{e}_{i,t} \quad \mathbf{e}_{i,t} \sim iid(0, \mathbf{s}_i^2) \quad \dots(17)$$

donde ($i = 1, 2, \dots, n$). Debido a que $\mathbf{e}_{i,t}$ y \mathbf{h}_t son perturbaciones que se asumen mutuamente independientes, $v_{i,t}$ es el elemento idiosincrásico de cada variable de X_t . Además, suponiendo que $\mathbf{s}_h = 1$, el sistema estará plenamente identificado. Una vez determinado C_t , el VAR bivariado (13) es estimado y su perfil predictivo es evaluado.

Aunque la estimación de (13), (15), (16) y (17) puede ser simultánea, se opta por un procedimiento de dos etapas, por razones computacionales. En la primera etapa, las ecuaciones (15) – (17) son rescritas en su representación de Estado – Espacio,

$$X_t = [\mathbf{g}_{n \times 1} \quad \mathbf{0}_{n \times (p-1)} \quad I_n \quad \mathbf{0}_{n \times n(q-1)}] [\tilde{C}_t \quad \tilde{v}_t]'_{(nq+p) \times 1}$$

$$\begin{bmatrix} \tilde{C}_t \\ \tilde{v}_t \end{bmatrix} = \begin{bmatrix} \Phi_{p \times p} & \mathbf{0}_{p \times q} & \mathbf{0}_{p \times q} & \dots & \mathbf{0}_{p \times q} \\ \mathbf{0}_{q \times p} & \Psi^1_{q \times q} & \Psi^2_{q \times q} & \dots & \Psi^q_{q \times q} \\ \mathbf{0}_{q \times p} & I_q & \mathbf{0}_{q \times p} & \dots & \mathbf{0}_{q \times p} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \mathbf{0}_{q \times p} & \mathbf{0}_{q \times p} & \dots & I_q & \mathbf{0}_{q \times p} \end{bmatrix} \begin{bmatrix} \tilde{C}_{t-1} \\ \tilde{v}_{t-1} \end{bmatrix} + \begin{bmatrix} \mathbf{e}'_{1,p} & \mathbf{0}_{p \times n} \\ \mathbf{0}_{n \times 1} & I_n \\ \mathbf{0}_{n(q-1) \times 1} & \mathbf{0}_{n(q-1) \times n} \end{bmatrix} \begin{bmatrix} \mathbf{h}_t \\ \mathbf{e}_t \end{bmatrix} \quad \dots(18)$$

donde (en orden de aparición)

$$\mathbf{v}_t = [v_{1,t} \quad v_{2,t} \quad \dots \quad v_{n,t}]'$$

$$\tilde{C}_t = [C_t \quad C_{t-1} \quad \dots \quad C_{t-p+1}]'$$

$$\tilde{v}_t = [v_t \quad v_{t-1} \quad \dots \quad v_{t-q+1}]'$$

$$\mathbf{g} = [\mathbf{g}_1 \quad \mathbf{g}_2 \quad \dots \quad \mathbf{g}_n]'$$

$$\Phi = \begin{bmatrix} \mathbf{f} & \mathbf{f}_p \\ I_{p-1} & \mathbf{0}_{(p-1) \times 1} \end{bmatrix}, \quad \mathbf{f} = [\mathbf{f}_1 \quad \mathbf{f}_2 \quad \dots \quad \mathbf{f}_{p-1}]$$

$$\Psi^j = \text{diag}(\mathbf{y}_{1,j}, \mathbf{y}_{2,j}, \dots, \mathbf{y}_{n,j}) \quad j = 1, 2, \dots, q$$

$$\mathbf{e}_t = [\mathbf{e}_{1,t} \quad \mathbf{e}_{2,t} \quad \dots \quad \mathbf{e}_{n,t}]'$$

o, de manera más compacta³⁴,

$$X_t = \mathbf{Z} \mathbf{a}_t$$

$$\mathbf{a}_t = \mathbf{H} \mathbf{a}_{t-1} + \mathbf{R} \mathbf{x}_t \quad \dots(19)$$

³³ En el contexto de variables no estacionarias, C_t puede ser interpretado como una relación de cointegración (véase Emerson & Hendry, 1996). No obstante, las variables que conforman X_t son transformadas de modo que éstas sean estacionarias. Este enfoque difiere ligeramente de la propuesta original de Stock & Watson (1990, 1991) quienes consideran la estimación de un *índice coincidente*.

³⁴ Para todos los puntos concernientes a sistemas de Estado – Espacio véase Harvey (1989).

Los parámetros de (18) ó (19) pueden ser estimados mediante el uso del Filtro de Kalman, que construye recursivamente los estimados de mínimos errores cuadráticos del vector de estado \mathbf{a}_t a partir de los datos observados X_t , dentro de la maximización de la función de verosimilitud

$$\ell = -\frac{1}{2} \sum_{t=1}^T e_t' F_t^{-1} e_t + \log(\det(F_t))$$

donde $e_t = X_t - X_{t|t-1}$ y $F_t = E[e_t e_t']$.

Una vez determinado C_t , en la segunda etapa se calculan los órdenes de los polinomios de (13) y se estiman ambas ecuaciones por SUR, como ha sido expuesto anteriormente.

3. Diseño Empírico

Con el propósito de determinar aquellas variables que puedan ser consideradas como indicadores adelantados de la inflación, se analiza el universo de 268 variables mostrado en el Cuadro No. 1a. Por conveniencia, estas series han sido organizadas en cuatro grandes conjuntos (Sector Monetario, Sector Externo, Sector Real y Otros), que a su vez han sido subdivididos en 3, 3, 4 y 3 grupos, respectivamente (Agregados Monetarios, Crédito y Liquidez, Tasas de Interés y Empresas Bancarias, Balanza Comercial, Cotizaciones Internacionales de *Commodities* y Tipo de Cambio, Precios Externos y Otros, Indicadores de Producción, Volúmenes Producidos, Medidas de Utilización y Precios y Sector Público (Gobierno Central), Bolsa de Valores de Lima y Otros). La mayoría de las variables utilizadas son elaboradas en el BCRP por lo que en el Cuadro No. 1a se presenta una referencia respecto al cuadro del *Boletín Semanal del BCRP* donde cada una puede ser hallada. Por su parte, se cuentan con datos desde enero de 1991 hasta diciembre del 2001. Tomando en cuenta las condiciones iniciales y la posibilidad de calcular tasas de crecimiento anuales, la muestra empieza, efectivamente, en enero de 1992 por lo que se tiene un total de $W = 120$ observaciones.

La inflación es medida como la variación porcentual a 12 meses del Índice de Precios al Consumidor de Lima Metropolitana, disponible en el Cuadro 73 del Boletín Semanal. Por su parte, es conocido que un modelo VAR pierde su bondades de inferencia y predictivas si alguna de sus variables endógenas no es estacionaria³⁵. Por este motivo, junto con la aspiración de encontrar buenos predictores de la inflación, se aplican 8 posibles transformaciones a cada variable de modo que sea estacionaria, tras estudiar su estacionalidad y la posible presencia de *outliers*³⁶. La estacionariedad de las series es evaluada mediante la prueba de Kwiatkowski et. al (KPSS, 1992) junto con el contraste de raíz unitaria de Elliot et. al. (1996). Si estas pruebas revelan la estacionariedad de la serie se considera la misma en niveles o en logaritmos, en caso de contar sólo con elementos positivos. Si las pruebas indican que la serie es estacionaria en tendencia, ésta se removida tomando variaciones porcentuales a 12 meses o utilizando una tendencia de Hodrick – Prescott (HP) de un lado³⁷. Por otro lado, si la variable es no

³⁵ Antes de plantear un modelo VAR estacionario debería probarse un Modelo de Corrección de Errores (MEC) ya que es conocido que, de existir, tomar en cuenta la cointegración de un conjunto de variables mejora sus predicciones de corto plazo (Christoffersen & Diebold, 1997). Sin embargo, un MCE del IPC implicaría trabajar con la inflación mensual, cuya volatilidad dificulta el análisis.

³⁶ Un *outlier* es considerado como aquél valor de la serie que cae fuera de las bandas de 95% de confianza de su promedio móvil de 12 rezagos. De existir, el *outlier* es reemplazado por el valor mediano de los 12 datos anteriores.

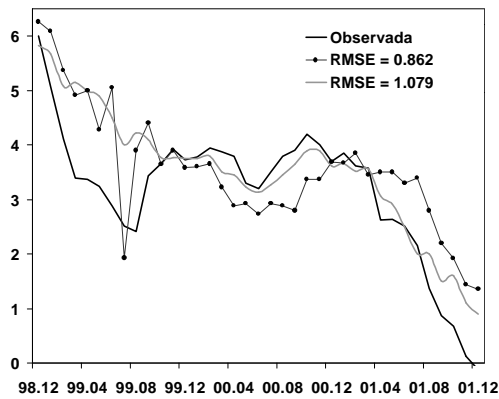
³⁷ La tendencia HP de un lado de y_t es definida como g_t en el sistema

$$y_t = g_t + x_t, \quad (1 - L)^2 g_t = n_t$$

donde x_t es el componente cíclico de y_t y n_t es un ruido blanco. A diferencia del filtro HP convencional (un promedio móvil entre dos rezagos y dos adelantos), la tendencia obtenida (mediante la aplicación del Filtro de Kalman) en el sistema anterior sólo contiene información pasada de y_t , lo cual es sumamente importante si se quiere simular situaciones de predicción en tiempo real. La aplicación de este filtro ha sido extendida, además, al logaritmo de la serie en cuestión y si ésta presenta una tendencia estocástica y no sólo determinística. Véase Reeves et. al. (1996).

estacionaria, se opta por sus primeras diferencias o las primeras diferencia de su logaritmo (esto es, su variación porcentual mensual). Finalmente, en caso de tratar con series I(2) se toman sus segundas diferencias o las segundas diferencias de su logaritmo. Luego, x_t en (1) representa la transformación de las series del Cuadro No. 1a vinculada con los mejores resultados predictivos. Dadas las características tanto de los datos como de la especificación empleada, inicialmente la evaluación se realiza considerando proyecciones un año en adelante, es decir $h = 12$. Para evaluar el poder predictivo de x_t se realiza una simulación recursiva *a la* Stock & Watson (1999), que implica cambios en T . La idea detrás de este ejercicio es conseguir una serie de N datos predichos a lo largo del tiempo y a partir de ella calcular los estadísticos mencionados en la sección anterior. Así, el primer paso de este ejercicio es restringir los datos hasta diciembre de 1997 ($N = 37$), obtener x_t y estimar (1), (2) y (3) con un horizonte de predicción de 12 meses (diciembre de 1998). En otras palabras, se analiza qué resultados se hubieran obtenido en diciembre de 1997 con la metodología aquí empleada. Tras evaluar *ex post* este primer pronóstico se agrega una observación adicional a la muestra y se consigue el pronóstico de la inflación de enero de 1999, con información hasta enero de 1998. Siguiendo este procedimiento hasta agotar los datos disponibles se genera una serie de valores de la inflación predicha, de diciembre de 1998 a diciembre de 2001, obtenida con información un año atrás.

Figura No. 1
¿Cuál es mejor?



La línea negra es la Inflación Observada. La línea gris es la proyección (recursiva) obtenida con la Liquidez Total Real, según (2). La línea marcada con círculos es la predicción correspondiente a las Exportaciones de Cobre.

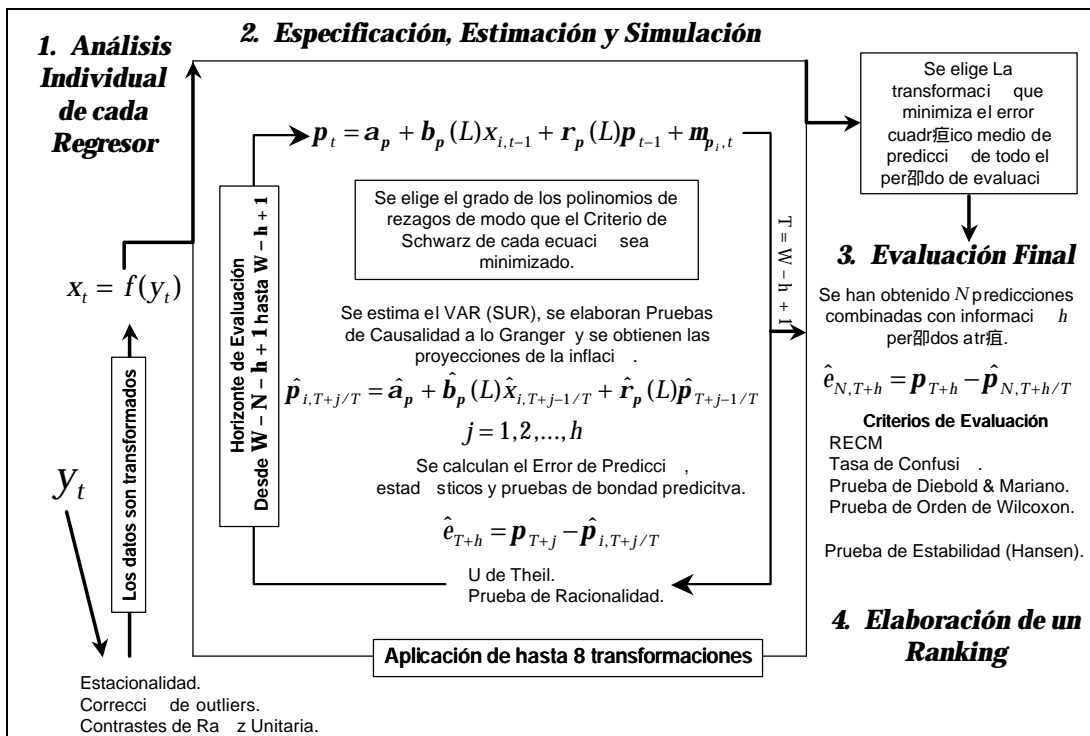
Como un hecho estilizado, el primer tramo del horizonte de evaluación, hasta agosto de 1999, está caracterizado por un *undershooting* en la inflación, producto del efecto estadístico generado por los bienes del IPC afectados por el Fenómeno del Niño en 1998. Ciertamente, este “impredecible” efecto de oferta genera un mal desempeño de los primeros pronósticos realizados. En la Figura No. 1 se muestra la inflación realizada en el período de evaluación junto con dos proyecciones, la obtenida con las Exportaciones de Cobre, cuya raíz del error cuadrático medio (RECM, en adelante) es 0.862 y la determinada a partir de la Liquidez Total Real (con RECM igual a 1.079). A juzgar por la información que brinda la RECM, la primera proyección es mejor que la primera. No obstante, al observar la Figura No. 1 puede deducirse que la superioridad de las Exportaciones de Cobre sobre la Liquidez Total Real se debe básicamente al pronóstico de julio de 1999. Excluyendo el mencionado período o tomando los resultados a partir de agosto de 1999, la segunda predicción es superior a la primera. Si bien el ejemplo presentado puede ser considerado como un caso extremo, es útil para ilustrar la necesidad de observar más allá de la RECM al evaluar las bondades de cada regresor. Por este motivo, en la sección precedente se han repasado una serie de criterios alternativos. Por ejemplo, la U de Theil promedio (el promedio de las U halladas en cada pronóstico) es 0.137 en el caso de las Exportaciones de Cobre y 0.116 en el caso de Liquidez Total Real. Asimismo, la tasa de confusión es en el primer caso 57.1% y en el segundo, 60.7%. Finalmente, según la prueba de estabilidad de Hansen, el modelo que genera la primera predicción no es estable mientras que el

asociado con la segunda sí lo es. Luego, sin restar importancia al RECM, utilizando una batería de criterios se pueden llegar a conclusiones diferentes y ciertamente más acertadas³⁸.

La discusión anterior resalta la necesidad de obedecer a más de un criterio y generar un *ranking* de desempeño con base a la información de todos los estadísticos de la sección 2.1. Bajo esta lógica, los resultados de cada regresor son catalogados según el orden establecido por (a) RECM y la U de Theil promedio, (b) la Tasa de Confusión de todo el período de evaluación y (c) las veces que un pronóstico fue calificado como insesgado según la Prueba de Racionalidad. Además, el regresor que no causa en el sentido de Granger a la inflación y no produce un modelo estable, según Wilcoxon y Hansen, es penalizado.

En resumen, se cuentan con W observaciones y desea evaluar las ventajas de algún regresor en predecir los N últimos puntos de la inflación con información h meses atrás. El ejercicio se inicia en $T = W - N - h + 1$. Dado este valor de T se determinan los órdenes de los polinomios de y (se estima) (1), se ejecuta la Prueba de Causalidad a lo Granger y se halla (2); luego se calcula el error de predicción en $T + h$, la U de Theil (4), se determina si la predicción es sesgada según (5) y si el modelo es estable según Hansen. En el siguiente paso, $T = W - N - h + 2$, (1) es reestimado y se procede de la misma manera hasta alcanzar $T = W - h + 1$. Finalmente, con la serie de N errores de predicción obtenida se procede a calcular la RECM, la Tasa de Confusión (7) y la Prueba de Orden de Wilcoxon. Del mismo modo, se computa el promedio de las N U de Theil generadas a lo largo de todo el proceso y, dado que el pronóstico con menor RECM no es necesariamente el mejor, el contraste de Diebold & Mariano (9) se aplica para comparar cada resultado con el de menor RECM³⁹. Este procedimiento es resumido en la Figura No. 2.

Figura No. 2
Diseño Empírico de Predicción y Evaluación de Modelos Bivariados



³⁸ Una lógica similar es utilizada en Swanson & White (1995).

³⁹ Dado el reducido tamaño de muestra y período de evaluación, toda la inferencia mencionada y el cálculo de los errores estándares de la RECM y U de Theil se basan en 2000 replicaciones *bootstrap*.

La implementación del enfoque multivariado es un ejercicio recursivo similar al expuesto. En cada momento del tiempo se combinan (se promedian o se calcula la mediana de) n pronósticos h períodos en adelante, lo que implica que para cada valor de T , los ponderadores de (10) son estimados por (11), con valores de k de 0.1 a 10 con incrementos de 0.1. Sólo se combinan las proyecciones vinculadas con la transformación x_t de mejores resultados. En cuanto a los Factores Estáticos, cada valor de T conlleva al recálculo de Componentes Principales. Así, conforme T va incrementándose, C_t es calculado, (13) es estimado y su pronóstico es evaluado. Como se mencionó, las posibles combinaciones de variables consideradas en el cálculo de un Componente Principal debe ser restringida. En el Cuadro No. 1b se muestran los 45 Factores Estáticos por evaluar, determinados mediante sentido común. El lector debe recordar que de un conjunto de m variables pueden construirse n Componentes Principales, según lo discutido en la sección 2.2.2.1. Además, para cada uno de los 45 conjuntos utilizados se elige aquél Componente Principal que presente el mejor perfil en todo el ejercicio (N pronósticos).


Finalmente, en lo concerniente a los Factores Dinámicos, el sistema (18) es planteado y estimado para cada valor de T , así como la proyección de su respectivo componente común. Debido a que la estimación por máxima verosimilitud de (18) demanda grandes cantidades de tiempo y superfluos requerimientos computacionales, el sistema de Estado – Espacio es planteado con 3, 4 y 5 variables, combinadas a partir del 20% superior de cada grupo del Cuadro No. 1a. Del mismo modo, se restringe el análisis a modelos con $p = q = 2$ en (15) – (17).

4. Resultados

4.1 Enfoque Bivariado

En esta sección se presentan los principales resultados de los ejercicios descritos líneas arriba. En el Cuadro No. 2 se presentan los estadísticos de los 100 mejores indicadores individuales, según lo dispuesto en la columna “Orden”. Un primer vistazo a las cifras de este cuadro sugieren que, en promedio, la RECM del período de evaluación es ligeramente superior a 1.1% y que la U de Theil promedio fluctúa entre 0.11 y 0.12. Al ser estos valores satisfactorios, puede respaldarse la solidez la especificación y estimación de (1). El perfil predictivo de cada grupo puede ser observado en la Figura No. 3 donde se presentan los promedios de la RECM y la U de Theil promedio todas las variables y del 20% con mejor desempeño dentro de cada uno de ellos.

Figura No. 3
Resultados por Grupos de Variables



Las barras blancas [grises] son los promedios de los estadísticos de los pronósticos de todas [del 20% superior de] las variables dentro de un grupo.

Una primera conclusión de estos resultados es el buen perfil de las variables del Sector Monetario en predecir la inflación, en particular, las variables de crédito y agregados monetarios. Adicionalmente, resulta notable el buen desempeño de las variables vinculadas con la Bolsa de Valores de Lima y Volúmenes Producidos y decepcionante el de las Medidas de Utilización (vinculadas a la estabilidad de oferta la agregada). Básicamente, la interpretación a estos resultados está vinculada con el argumento⁴⁰ de que el aumento de precios en Perú es un fenómeno primordialmente transaccional⁴¹. No obstante ello, los estadísticos y el *ranking* del Cuadro No. 2 revelan una serie de variables no necesariamente vinculadas con el diseño de la política monetaria, por ejemplo el Índice Selectivo de la Bolsa de Valores de Lima o el Volumen Producido de Papas, que muestran un fuerte poder predictivo de la inflación. Independientemente de las posibles relaciones estructurales subyacentes entre ellas y la variable predicha, este resultado es consistente con Woodford (1994), quien argumenta que la intensidad de uso de alguna relación estadística significativa y conocida (por ejemplo la causalidad de emisión primaria hacia inflación) puede ser incluida y descontada en las expectativas de los agentes y, a la larga, ser mermada; en este sentido, tales variables pueden ser concebidas como información no explotada por la política monetaria⁴².

4.2 Enfoque Multivariado

En el Cuadro No. 3 se tabulan los resultados obtenidos a partir de las 50 mejores combinaciones de pronósticos individuales, considerando promedios ponderados, simples y medianas. En el primer bloque de este cuadro se muestra lo hallado con las combinaciones compuestas por todas las variables disponibles y la mitad, cuarta, quinta, décima y vigésima parte superior según lo establecido en el análisis bivariado (columna “Orden” el Cuadro No. 2). Luego se muestran los resultados por grupos, donde se combinan todo sus pronósticos y del 50% y 20% superior.

En líneas generales y como se esperaba, combinar proyecciones mejora los resultados: el promedio de los RECM del Cuadro No. 3 es 0.929 mientras que el promedio de los 50 menores RECM mostrados en el Cuadro No. 2 asciende a 1.056; por su parte, el promedio de la Tasa de Confusión de las proyecciones combinadas es de 72.0% mientras que el de las 50 mejores proyecciones individuales es 63.5%. Ello implica una mejora de los pronósticos combinados de entre 12 y 14% relativa a las proyecciones individuales. Este progreso puede ser acrecentado considerando sólo las proyecciones que encabezan los respectivos *rankings* (por ejemplo, hasta más de 17% con los 20 primeros pronósticos, ver Figura No. 4). Además, puede concluirse que el ponderador de Stock & Watson, (12), brinda mejores indicadores que el promedio simple o la mediana, sobre todo ante un gran número de variables. Finalmente, los resultados concernientes con la Prueba de Diebold & Mariano sugieren que, en gran medida, los pronósticos combinados contienen información propia que los diferencia de la proyección de menor RECM. Junto con los mejorados indicadores de bondad, este hecho abre la posibilidad de un mayor potencial en la búsqueda de una proyección *óptima* (podría pensarse en *combinar combinaciones*, por ejemplo).

En los Cuadros No. 4 y No. 5 se presentan los indicadores de desempeño de los 25 mejores Factores Estáticos y los 25 mejores Factores Dinámicos, respectivamente. Tal y como se esperaba, *grosso modo*, la composición de información brinda mejores resultados que la de proyecciones. En la Figura No. 4 se presenta la efectividad, vista como la reducción de la RECM o la U de Theil promedio o el aumento de la Tasa de Confusión, de los 25 y 10 primeros factores con respecto a los 25 y 10 (respectivamente) mejores indicadores individuales. Se

⁴⁰ Mayor detalle en De la Rocha (1998) y *Programa Monetario del BCRP*, disponible en su página web.

⁴¹ Es importante destacar que las propiedades predictivas de los agregados monetarios (en particular en el caso de la emisión primaria) no garantizan, necesariamente, el éxito de un régimen de control de cantidades o enfatizan el poder de la política monetaria. El uso de agregados monetarios como variables informativas (que es el dado en este documento) es conceptualmente distinto a su rol como meta intermedia (véase Friedman, 1996), ya que el segundo presupone una relación estable entre el agregado y la inflación y un claro entendimiento de los aspectos estructurales del mecanismo de transmisión (véase Baumgartner et. al., 1997).

⁴² El caso histórico más conocido de este fenómeno es la Curva de Phillips en los años 70.

aprecia que los 10 primeros Factores Dinámicos incrementan la bondad predictiva en cerca 20%; igualmente, el uso de cualquier tipo de factor mejora la bondad predictiva evaluada mediante la U de Theil, lo que indica que tanto la inflación puntual h meses adelante como la trayectoria de la inflación de $T + 1$ hasta $T + h$ son mejor predichas por esta metodología.

Figura No. 4
Efectividad según Enfoque y Criterio, con respecto a
Predicciones Individuales (en porcentajes)

¡Error! Vínculo no válido.

Brechas promedio de los k mejores pronósticos, según metodología, con respecto a los promedios de las k mejores proyecciones individuales.

La discusión anterior sobre el desempeño de los enfoques multivariados, resumida en la Figura No. 4, establece el claro orden *Factores – Combinaciones – Individuales* justificado por la discusión en torno al contenido informativo de cada enfoque de la sección 2.

Los resultados obtenidos no permiten concluir rotundamente cuál enfoque de extracción de factores es superior. Por un lado, si bien el cálculo de Factores Estáticos puede considerarse como una práctica *ad hoc*, su capacidad de resumir grandes cantidades de información es ventajosa. Por otro lado, los Factores Dinámicos compensan el reducido uso de información (variables) empleado en su cálculo con el hecho de admitir una estructura dinámica inexistente en el caso anterior. En todo caso, el buen desempeño de los factores los hace especialmente útiles como *índices adelantados* de la inflación, hecho que puede ser observado en las persistentes y significativas respuestas de la inflación ante choques en los factores mostradas en la Figura No. 5⁴³.

4.3 ¿Y Cualitativamente?

Una característica deseable de los factores, adicionalmente a su buen desempeño como predictor puntual, es su capacidad de adelantar cualitativamente el comportamiento de la inflación. Para estudiar este atributo, es necesario identificar las fechas dentro del período muestral en donde la inflación tras reducciones sucesivas se incrementa⁴⁴. Esta fecha, denominada *turning point*, es establecida, siguiendo a Wecker (1979), definiendo una variable auxiliar,

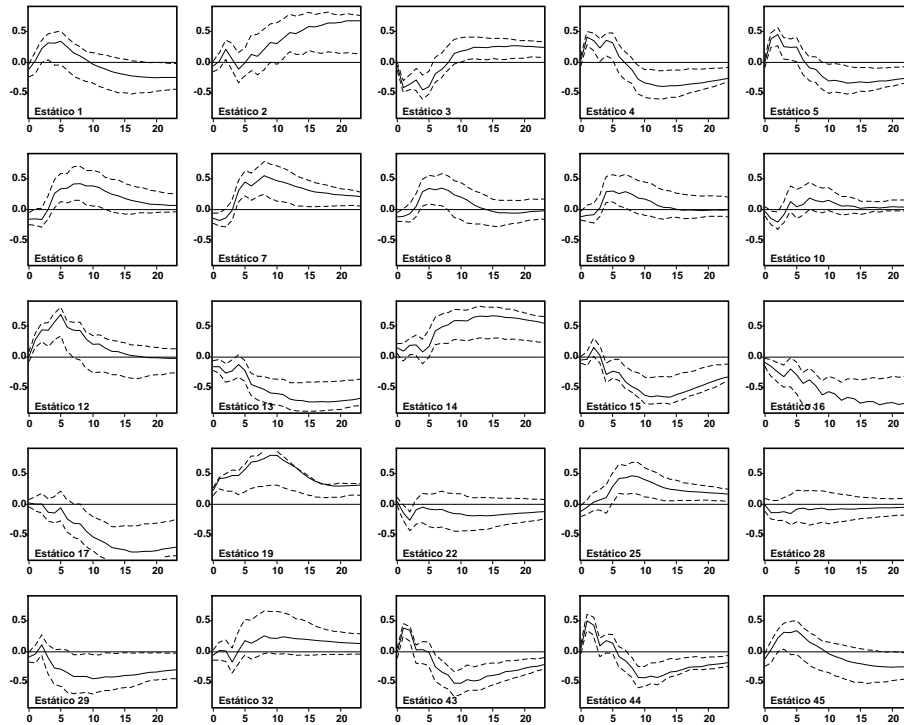
$$u_t = 1 \quad \text{si} \quad p_{t-3} > p_{t-2} > p_{t-1} > p_t \quad \text{y} \quad p_{t+1} > p_t$$

En otras palabras, se define a un *turning point* de la inflación como la fecha en donde ésta se incrementa tras un trimestre de reducirse secuencialmente. Al aplicar este criterio pudo determinarse hasta 9 puntos, 8 de ellos mostrados el primer panel de la Figura No. 6 (fechas sombreadas), junto con las trayectorias del Factor Estático del Sector Monetario (número 6) y del Factor Dinámico número 1, ambas rezagadas un año. Se aprecia que cualitativamente estas series proporcionan información valiosa sobre el futuro comportamiento de la inflación.

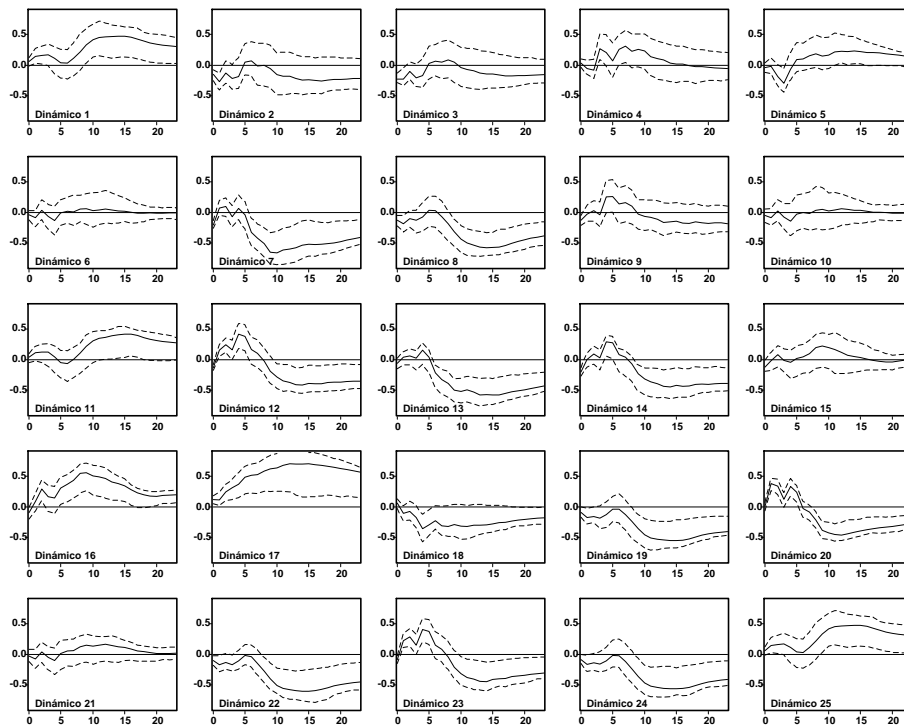
⁴³ Las funciones impulso-respuesta de esta figura son determinadas a partir de un modelo VAR bivariado Factor – Inflación, en toda la muestra. Cada factor fue estandarizado de modo que el choque ortogonalizado por la descomposición de Cholesky sea unitario.

⁴⁴ Puede extenderse este análisis a los puntos en donde la inflación tras incrementarse, se reduce. No obstante, en toda la muestra se encontró un número reducido de estas fechas.

Figura No. 5
Respuestas de la Inflación ante Choque Unitario en los Factores
Factores Estáticos



Factores Dinámicos



Las líneas punteadas son el intervalo de confianza al 95% obtenido con 2000 replicaciones Bootstrap. El período de estimación, de un modelo similar a (1), comprende de enero de 1992 a diciembre del año 2001.

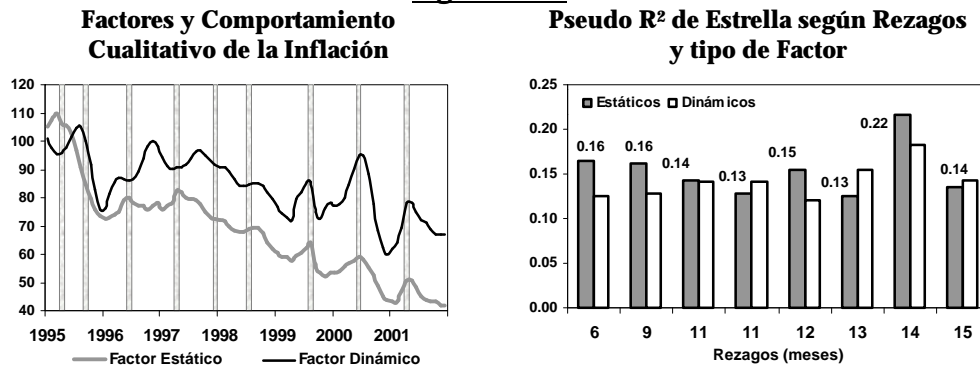
Un análisis más riguroso sobre esta capacidad cualitativa se consigue al replicar el trabajo de Mishkin & Estrella (1996). Estos autores proponen el uso de modelos probit, donde se asume que existe una serie no observable relacionada con el indicador u_t , de modo que si ésta es mayor a algún valor umbral (desconocido), la economía genera presiones hacia el alza de la inflación. Este hecho se observa cuando $u_t = 1$. Si se asume normalidad en el comportamiento de la variable no observada, la probabilidad de que la inflación se encuentre en un *turning point* puede ser vinculada al comportamiento del factor C_t según

$$\Pr(u_t = 1) = \Phi(a_0 + a_1 C_{t-l}) + x_t \quad \dots(20)$$

donde Φ es la función de distribución normal acumulada. Si el ajuste de (20) es bueno, para algún valor de l , puede decirse que C_t anticipa el evento $u_t = 1$ l meses atrás. Existen varios criterios de ajuste de (20); en este trabajo se opta por el Pseudo R^2 de Estrella (1998).

En el segundo panel de la Figura No. 6 se presenta el perfil promedio de este indicador para los 25 mejores Factores Estáticos y Dinámicos y distintos valores de l^{45} . En general, puede desprenderse cierta superioridad de los Factores Estáticos al anticipar los movimientos inflacionarios en períodos menores a un año. Adicionalmente, los Factores Dinámicos mejoran significativamente este atributo en períodos superiores a un año. El lector familiarizado con los modelos dicotómicos como (20) encontrará que el ajuste medio de estas estimaciones es satisfactorio.

Figura No. 6



El panel izquierdo muestra la trayectoria rezagada un año de un Factor Estático y uno Dinámico y sus coincidencias con los turning points de la inflación. En el panel derecho se presentan los promedios de los Pseudo R^2 de Estrella de la estimación de (20), para distintos valores de l , correspondientes a los factores de los Cuadros No. 4 y No. 5.

4.4 Mayores Horizontes de Predicción


De la exposición anterior, puede decirse que el objetivo de mejorar los pronósticos individuales de un año de la inflación ha sido alcanzado. Sin embargo, es importante realizar una discusión similar con un horizonte predictivo mayor, hecho sustentado en cálculos previos del *rezago de política monetaria*⁴⁶ y en experiencias de manejo de política en un esquema de anuncio de metas inflacionarias⁴⁷ que recomiendan que las metas de inflación de fin de año sean anunciadas antes del inicio del mismo. Ambos puntos conlleva al diseño multianual de la política monetaria en Perú, por lo que surge la necesidad de contar con proyecciones de más de 12 meses.

⁴⁵ Solamente se han realizado evaluaciones *ex ante* a falta de suficientes eventos fuera de la muestra. Para fines de presentación los factores del primer panel de la Figura No. 6 son expresados con base 1994 = 100 y suavizados a través de una media móvil de dos rezagos y dos adelantos.

⁴⁶ En Rossini (2001) éste se encuentra en alrededor de 15 meses. Véase, además, Armas et. al. (2001).

⁴⁷ Un caso ilustrativo es el chileno, expuesto en Morandé & Schmidt–Hebbel (2001).

Figura No. 7
Efectividad según Horizonte Predictivo



Diagramas de Dispersión en el plano (Inflación Predicha, Inflación Observada) para distintos valores de h . Los pronósticos son los promedios de los obtenidos con los factores de los Cuadros No. 4 y No. 5.

En la Figura No. 7 se presenta el comportamiento del pronóstico promedio de los factores (Estáticos y Dinámicos) ante distintos horizontes de predicción. La Pérdida de Efectividad (mayor incertidumbre) por aumentar h puede observarse en esta figura como la reducción de la pendiente de la línea de regresión en el plano Inflación Predicha – Inflación Observada. Para un horizonte de muy corto plazo, 6 meses, esta línea tiene una pendiente pronunciada y cercana a la unidad. Esta pendiente se ve reducida, aunque levemente, para horizontes de un año mientras es casi nula para $h = 24$. Todo ello limita la capacidad predictiva de los modelos aquí desarrollados a un período de máximo 15 – 18 meses. Acorde con la convención, proyecciones de mayores plazos requieren de juicio del investigador, supuestos sobre la conducta futura de la economía y de un conocimiento mínimo de las relaciones estructurales (asumidas como estables) detrás de las variables por proyectar. Las líneas punteadas de la Figura No. 7 corresponde a las líneas de regresión de los pronósticos individuales.

En el Cuadro No. 6 se presentan los estadísticos relativos a las proyecciones de 12 meses. En el caso de los Factores Estáticos, la pérdida de efectividad es relativamente estable entre los diferentes indicadores de bondad predictiva para $h = 18$ y asciende a cerca de 30%. Esto, es si la RECM o la U de Theil fue en promedio 1% para $h = 12$, para $h = 18$ será, en promedio, 1.3%; asimismo, si la Tasa de Confusión fue de 100, para el horizonte mayor será de 70. Un fenómeno similar ocurre con los Factores Dinámicos aunque con pérdidas mayores, básicamente por su menor contenido informativo. Asimismo, puede esbozarse una evolución exponencial del indicador de pérdida ante incrementos en el horizonte predictivo. La Pérdida de Efectividad fluctúa alrededor de 30% al pasar de proyectar un horizonte de 6 meses a uno de 15, cifra similar a la observada al pasar de un horizonte de 12 meses a uno de 18 (el paso de 18 meses a dos años no es concluyente).

A pesar de ello, en ningún caso la Pérdida Efectiva supera el 40% para períodos de 18 meses lo cual es aceptable. Bajo el supuesto de que RECM promedio es ligeramente mayor a 0.5% para pronósticos de cada año (asignando la RECM total a cada año dentro del período de simulación, aunque la cifra puede ser menor dado el *undershooting* inicial de la inflación comentado en la sección 3⁴⁸), proyecciones de 18 meses consiguen una RECM de menos de 1%. Este aspecto es fundamental en el diseño de política monetaria con bandas inflacionarias de 1.5%, que corresponde al caso peruano (con una meta de largo plazo de 1.5 – 3.0%), y constituye un punto a favor de las bondades de los factores como predictores de la inflación dentro del diseño de la política monetaria en Perú.

⁴⁸ El patrón genérico que puede desprenderse de todas las proyecciones realizadas (Cuadros No. 2, 3, 4 y 5) es que la RECM de diciembre de 1998 hasta diciembre de 1999 es entre 3 y 6 veces el obtenido para el año 2000 y el año 2001. Por ejemplo, la RECM de la Velocidad de Circulación del Circulante (vCirc) reportada para el período diciembre de 1998 – diciembre 2001 es de 1.229; este estadístico para el período diciembre de 1998 – diciembre de 1999 es de 1.584 mientras que para los años 2000 y 2001 es de 0.586 y 0.889, respectivamente.

4.5 Predicción en Tiempo Real

La exposición anterior ha sido realizada suponiendo, implícitamente, que los datos disponibles en el período T son *definitivos*, lo cual no es necesariamente cierto. Si bien la inflación, tasas de interés, tipo de cambio, índices bursátiles, entre otras, son variables cuyo valor definitivo puede conocerse pocos días después de T (los primeros días de cada mes), los Agregados Monetarios e Indicadores de Producción constituyen cifras sujetas a revisión, que pueden ser actualizadas hasta varios meses después. Ello es plausible por redefiniciones, correcciones por estacionalidad, cambios de base o porque algunas variables son obtenidas residualmente, en un contexto de programación financiera y consistencia macroeconómica donde varía la dinámica proyectada de la economía hacia las metas de mediano y largo plazo planteadas⁴⁹. De este modo, desde una perspectiva de tiempo real, es probable que al momento de predecir se cuente con un conjunto de series cuyas cifras finales sean *preliminares*.

A fin de evaluar la importancia de este efecto sobre la proyección de la inflación, combinación de pronósticos y extracción de factores, la simulación anterior fue nuevamente ejecutada con los valores *efectivamente disponibles* en T . Se supuso que estas predicciones son llevadas a cabo en la segunda quincena de cada mes de modo que las cifras de meses anteriores correspondieron a las del Boletín Semanal de la segunda semana del mes $T + 1$. Este ejercicio se realizó considerando las 25 primeras variables del *ranking* del Cuadro No. 2 sujetas a revisiones. Los resultados fueron prácticamente invariantes con respecto a los discutidos anteriormente, por lo que no se presentan en este texto.

5. Conclusiones y Comentarios Finales

En este trabajo se han explorado, dentro de un conjunto de 268 variables, las relaciones existentes entre la inflación y los indicadores económicos que la predicen mejor. Dentro de este análisis, la inflación es medida como la variación anual del IPC ya que sobre ésta se realizan los anuncios del BCRP y es muy probable que siga siendo la variable objetivo en un virtual esquema de metas de inflación. Esta elección es particularmente importante ya que los resultados de simulaciones realizadas dependen, obviamente, de la medida utilizada.

A modo de ilustración la siguiente tabla reporta los indicadores individuales fuera del Sector Monetario que encabezan los *rankings* para diversas medidas de inflación⁵⁰

IPC (anual)		IPC (mensual)		Subyacente (anual)		Subyacente (mensual)	
CapS	Cpla	Qplo	EXNTagr	EX	Qplo	ISCGC	EXTVpla
ISBVL	Qarro	TuPRP	IPCSC\$	Phie	PBlman	Cpet	IPEX
BVLban	Ppla	DLC	ISBVL	TuQCP	ProPNP	BVLinv	PBlnpr
BVLmin	GCGC	Wnom	BVLmin	IPCSC\$	PBlagr	DLC	ProPNP
Qpapa	EXTmin	PBlnpr	TCRco	GCGC	BVLban	BVLind	ToT
IGBVL	IGVGC	OGAPs	RPGCr	EXNtext	TuPNP	TuPNP	IP_comS
Qplo	EXNTagr	ToT	Ppet	CapS	IMCd	GKGCr	EXO

Aunque más homogéneos, los resultados de las variables del Sector Monetario son también variables, como se aprecia en la siguiente tabla

IPC (anual)		IPC (mensual)		Subyacente (anual)		Subyacente (mensual)	
FEEx\$	TOSES	TIPMN	vCirc	TIPMN	LMN94	Tcol	EmPfin
LT94	TAMN	Cmon1	din	TOSES	EEEB	TIPME	CIN
CIN	FEEI\$	EmPprom	TP30MN	FEEIS	LT94	CC	TOSES
CISPuS94	TIPME	Tcol	LT94	EESB	CISPr	Circfin	CajaB

⁴⁹ Otros motivos se encuentran en Diebold & Rudebusch (1991) y Amato & Swanson (2000).

⁵⁰ La inflación subyacente es definida como la variación del IPC excluyendo los rubros más volátiles.

La determinación de los mejores indicadores se ha basado en una serie de criterios de evaluación fuera de predicción fuera de la muestra, a diferencia de la práctica tradicional de considerar la RCME o un estadístico similar. Ello permite identificar algunas propiedades deseables de las variables analizadas. El uso de la Tasa de Confusión es un buen ejemplo de ello ya que, aunque presenten RCME fácilmente superables, variables como los Ingresos del Gobierno Central por el Impuesto General a las Ventas (IGVGC) son muy buenas anticipando los movimientos de la inflación.

Esta serie de bondades aparentemente dispersas a lo largo de todas las variables, pueden ser concentradas en una proyección a partir de las combinaciones de pronósticos. Particularmente, considerando ponderadores distintos y estimados a partir de patrones dentro de la muestra, puede alcanzarse mejores resultados que los correspondientes a indicadores individuales. Asimismo, la composición de la información muestral en índices o *factores* exhibe un desempeño superior incluso a la combinación de pronósticos, tanto en proyecciones de corto plazo (por los valores de la U de Theil Promedio de los Cuadros No. 4 y No. 5) como de mediano plazo (sección 4.4). Más aún, cualitativamente estos factores han mostrado tener la capacidad de adelantar los *turning points* de la inflación, incluso con anticipación de 15 meses. Así, junto con la aparente robustez al predecir con datos en tiempo real, los factores presentados son herramientas potencialmente útiles en el seguimiento y evaluación de la política monetaria.

Ciertamente, conforme se tengan muestras de mayor tamaño y el período de análisis se aleje de los episodios de alta inflación de inicio de los noventa, se espera que predecir la inflación sea una tarea más sencilla. Ello, junto con el mejor entendimiento de las relaciones estructurales más relevantes dentro del mecanismo de transmisión, y la atención a información referencial dada en investigaciones como Barrera (1997, 1999) y la presente, pueden constituir un paso importante para la total implementación operacional de un esquema de metas de inflación.

Finalmente, el presente trabajo espera ser la motivación para el desarrollo de posteriores investigaciones que incluyan el uso de procesos heurísticos y computacionalmente intensivos en el manejo de la información. En cuanto a la proyección de la inflación en Perú, la investigación futura puede centrar su atención en la introducción de no linealidades, predicción de densidades y la búsqueda de especificaciones parsimoniosas, fácilmente comunicables, dentro de un contexto multivariado y posiblemente estructural.

6. Bibliografía

1. Amato, Jeffrey D. & Norman R. Swanson (2000), “The Real-Time Predictive Content of Money for Output”, Bank of International Settlements, *BIS Working Paper No. 96*.
2. Armas, Adrián, Francisco Grippa, Zenón Quispe & Luis Valdivia (2001), “De Metas Monetarias a Metas de Inflación en una Economía con Dolarización Parcial: el Caso Peruano”, Banco Central de Reserva del Perú, *Revista Estudios Económicos No. 7*.
3. Armstrong J. S. & Robert Fildes (1995), “On the Selection of Error Measures for Comparisons Among Forecasting Methods”, *Journal of Forecasting*, 14, pp. 67 – 71.
4. Ashley, Richard (1997), “A New Technique for Post sample Model Selection and Validation”, Virginia Tech, *Economics Department Working Paper No. E97-01*.
5. Barrera, Carlos R. (1997), “Indicadores Anticipados de la Inflación: Un Análisis Preliminar”, Banco Central de Reserva del Perú, edición mimeografiada.
6. Barrera, Carlos R. (1999), “Un Sistema de Proyección de Corto Plazo de Variables Macroeconómicas en el Perú: Combinación de Proyecciones con Ponderaciones Variables”, Banco Central de Reserva del Perú, edición mimeografiada.
7. Baumgartner, Josef, Ramana Ramaswamy & Göran Zettergren (1997), “Monetary Policy and Leading Indicators of Inflation in Sweden”, *IMF Working Paper WP/97/34*.
8. Chauvet, Marcelle (2000), “Leading Indicators of Inflation for Brazil”, Central Bank of Brazil, Research and Studies Department, *Working Paper No. 7*.
9. Christoffersen & Francis X. Diebold (1997),
10. Clemen, RT (1989), “Combining Forecasts: A Review and Annotated Bibliography”, *International Journal of Forecasting*, 5, pp. 559 – 581.
11. Clements, Michael P. & David F. Hendry (1998), “Forecasting Economic Processes”, *International Journal of Forecasting*, No. 14, pp. 111 – 131.
12. Cumby RE & J Huizinaga (1992), “Testing the Autocorrelation Structure of Disturbances in Ordinary Least Squares and Instrumental Variables Regressions”, *Econometrica*, 60, pp. 185 – 195.
13. De la Rocha, Javier (1998), “The Transmission Mechanism of Monetary Policy in Peru”, en “The Transmission of Monetary Policy in Emerging Market Economies”, *BIS Policy Papers No. 3*, pp. 181 –194.
14. Diebold, Francis X. & Glenn D. Rudebusch (1991), “Forecasting Output with the Composite Leading Index: An Ex Ante Analysis”, *Journal of the American Statistical Association*, 86, pp. 603 – 610.
15. Diebold, Francis X. & Jose A. López (1996), “Forecast Evaluation and Combination” en Maddala, G.S. & C.R. Rao (eds.), *Handbook of Statistics*, Amsterdam: North-Holland.
16. Diebold, Francis X. & Roberto S. Mariano (1995), “Comparing Predictive Accuracy”, *Journal of Business and Economic Statistics*, No. 13, pp. 253 - 265.
17. Dion, Richard (1999), “Indicator Models of Core Inflation in Canada”, Bank of Canada, *Working Paper 99-13*.
18. Elliot, Graham, Thomas J. Rothenberg & James H. Stock (1996), “Efficient Tests for an Autoregressive Unit Root”, *Econometrica*, Vol. 64, No. 4, pp. 813 – 836.
19. Emerson, Rebecca A. & David F. Hendry (1996), “An Evaluation of Forecasting using Leading Indicators”, *Journal of Forecasting*, No. 15, pp. 271 – 291.
20. Ericsson, Neil R. (1992), “Parameter Constancy, Mean Square Forecast Errors and Measuring Forecast Performance: An Exposition, Extensions and Illustration”, *Journal of Policy Modeling*, Vol. 14, No. 4, pp. 465 – 495.
21. Friedman, Benjamin M. (1996), “The Rise and Fall of Money Growth Targets as Guidelines for U.S. Monetary Policy”, *NBER Working Paper 5465*.

22. Granger, Clive W. J. & Paul Newbold (1986), *Forecasting Economic Time Series*, Academic Press.
23. Harvey, Andrew C. (1989), *Forecasting, Structural Time Series Models and the Kalman Filter*, Cambridge University Press.
24. Harvey, David I. & Paul Newbold (2000), “Properties of Macroeconomic Forecast Errors”, Loughborough University, *Economic Research Paper No. 00/2*.
25. Hansen, Bruce E. (2000), “Testing for Structural Changes in Conditional Models”, *Journal of Econometrics*, No. 97, pp. 93 – 115.
26. Joutz, Fred & H. O. Stekler (2000), “An Evaluation of the Predictions of the Federal Reserve”, *International Journal of Forecasting*, No. 16, pp. 17 – 38.
27. Kaene, Michael P. & David E. Runkle (1989), “Are Economic Forecasts Rational?”, Federal Reserve Bank of Minneapolis, *Quarterly Review*, Vol. 13, No. 2.
28. Kim, Chang-Jin & Charles R. Nelson (1999), *State-Space Models with Regime Switching: Classical and Gibbs-sampling approaches with applications*, The MIT Press.
29. Lahiri, Kajal & Geoffrey H. Moore (1991), *Leading Economic Indicators: New Approaches and Forecasting Records*, Cambridge University Press.
30. Morandé & Klaus Schmidt-Hebbel (2001), “
31. Nadal-De Simone, Francisco (2000), “Forecasting Inflation in Chile Using State-Space and Regime-Switching Models”, *IMF Working Paper WP/00/162*.
32. Neumaier, Arnold & Tapio Schneider (2000), “Estimation of Parameters and Eigenmodes of Multivariate Autoregressive Models”, Courant Institute of Mathematical Sciences, mimeo.
33. Peseran, M. Hashem & Allan Timmermann (1994), “A Simple Nonparametric Test of Predictive Performance”, *Journal of Business and Economic Statistics*, 10, pp. 461 – 465.
34. Reeves, J.J., C.A. Blyth, C.M. Triggs & J. P. Small (1996), “The Hodrick-Prescott Filter, a Generalisation, and a New Procedure for Extracting an Empirical Cycle from a Series”, University of Auckland, *Working Paper No. 160*.
35. Robertson, John C. & Ellis W. Tallam (1999), “Vector Autoregressions: Forecasting and Reality”, Federal Reserve Bank of Atlanta, *Economic Review*, First Quarter, pp. 4 – 18.
36. Rossini, Renzo (2001), “Aspectos de la Adopción de un Régimen de Metas de Inflación en el Perú”, Banco Central de Reserva del Perú, *Revista Estudios Económicos No. 7*.
37. Roth, Howard L. (1991), “Leading Indicator of Inflation”, en Lahiri, Kajal & Geoffrey H. Moore, *Leading Economic Indicators: New Approaches and Forecasting Records*, Cambridge University Press, pp. 275 – 301.
38. Stock, James H. & Mark W. Watson (1990), “New Indexes of Coincident and Leading Economic Indicators”, en *NBER Macroeconomics Annual 1989*, Cambridge, MA: MIT Press, pp. 351-394,
39. Stock, James H. & Mark W. Watson (1991), “A Probability Model of the Coincident Economic Indicators”, en Lahiri, Kajal & Geoffrey H. Moore, *Leading Economic Indicators: New Approaches and Forecasting Records*, Cambridge University Press, pp. 63 – 90.
40. Stock, James H. & Mark W. Watson (1998), “Diffusion Indexes”, *NBER Working Paper 6702*..
41. Stock, James H. & Mark W. Watson (1999), “Forecasting Inflation”, *Journal of Monetary Economics*, 44, pp. 293 – 335.
42. Stock, James H. & Mark W. Watson (2001), “Forecasting Output and Inflation: The Role of Asset Prices”, *NBER Working Paper 8180*..
43. Swanson, Norman R. & Halbert White (1995), “A Model Selection Approach to Real-Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks”, The Penn State University, mimeo.

44. Theil, H (1961), *Economic Forecasts and Policy*, North – Holland.
45. Webb, Roy H. (1991), “On Predicting the Stage of the Business Cycle”, en Lahiri, Kajal & Geoffrey H. Moore, *Leading Economic Indicators: New Approaches and Forecasting Records*, Cambridge University Press, pp. 109 – 140.
46. Wecker, William E. (1979), “Predicting the Turning Points of a Time Series”, *Journal of Business*, 55, pp. 57 – 85.
47. Zha, Tao (1998), “A Dynamic Model for Use in Formulating Policy”, Federal Reserve Bank of Atlanta, *Economic Review*, First Quarter, pp. 16 – 28.
48. ZELNER, Arnold & Franz Palm (1962), “Time Series Analysis and Simultaneous Equation Econometric Models”, *Journal of Econometrics*, No. 2, pp. 17 – 54.

Nota a los Cuadros Estadísticos

Las columna titulada **f(y)** en el **Cuadro No. 2** muestra el siguiente código: Sea y_t una de las variables del Cuadro No. 1a, luego x_t en (1) es una de las siguientes transformaciones (el orden difiere al expuesto en el texto):

- | | |
|--|---|
| 1. Niveles | $x_t = y_t$ |
| 2. Primeras Diferencias | $x_t = y_t - y_{t-1}$ |
| 3. Segundas Diferencias | $x_t = y_t - 2y_{t-1} + y_{t-2}$ |
| 4. Logaritmo Natural | $x_t = \ln(y_t) \quad (y_t > 0, \forall t)$ |
| 5. Tasa de Crecimiento Mensual | $x_t = \ln(y_t) - \ln(y_{t-1})$ |
| 6. Segundas Diferencias Logarítmicas | $x_t = \ln(y_t) - 2\ln(y_{t-1}) + \ln(y_{t-2})$ |
| 7. Serie sin Tendencia (HP de un lado) | $x_t = y_t - g_t \quad \text{o} \quad x_t = \ln(y_t) - \tilde{g}_t$ |
| 8. Tasa de Crecimiento Anual | $x_t = \ln(y_t) - \ln(y_{t-12}) \approx y_t / y_{t-12} - 1$ |

Además, la siguiente tabla muestra los títulos de las columnas de los Cuadros No. 2 – 5 y sus respectivas descripciones:

Título	Descripción
S	“*” si la serie ha sido desestacionalizada.
#	Establece el orden de cada variable en su grupo.
n	En el Cuadro No. 3, es el número de pronósticos combinados. Se trata de los n primeros por cada subgrupo, según la columna “#”.
RMSE	Raíz del error cuadrático medio de cada proyección recursiva de todo el período de evaluación y su error estándar entre paréntesis.
CR	Tasa de Confusión (7).
p(DM)	<i>P-value</i> de la prueba de Diebold & Mariano (9). Si éste es marcado con “*”, la proyección i es informativamente igual a la de menor RMSE de cada grupo.
U de Theil	Promedio de las NU de Theil calculadas y su desviación estándar entre paréntesis.
GCT	“*” si por lo menos el 80% de las N veces que (1) es estimado se rechaza la falta de causalidad a lo Granger.
Unb	Porcentaje de veces que la Prueba de Racionalidad (5) es aceptada, revelando que la proyección es insesgada.
p(WRT)	“*” si la Prueba de Orden de Wilconox acepta que tanto la proyección como la inflación observada provienen de la misma distribución poblacional.
p(Hansen)	<i>P-value</i> de la Prueba de Estabilidad de Hansen. Está marcado con “*” si se acepta constancia de parámetros de (1). Se reporta lo obtenido en la última estimación.
Orden	<i>Ranking</i> establecido a partir de los criterios anteriores.

Finalmente, en el Cuadro No. 6 se presentan estadísticos relativos a los de los Cuadros No. 4 y No. 5. Por ejemplo, si Ω_{12} es el valor de un criterio de evaluación con $h = 12$ y Ω_6 es el mismo criterio pero con $h = 6$, la primera columna del Cuadro No. 6 reporta Ω_6 / Ω_{12} . Lógicamente para el caso de RMSE y U de Theil [Tasa de Confusión] si este cociente es menor [Mayor] a la unidad, $\Omega_6 < \Omega_{12}$ [$\Omega_6 > \Omega_{12}$], el pronóstico que se compara con el de $h = 12$ es mejor. Así, la fila **Pérdida de Efectividad Promedio** es en el caso de RMSE y de Theil igual al promedio de estos cocientes menos uno mientras que para la Tasa de Confusión, la fila corresponde a uno menos el promedio de los ratios.