



**BANCO CENTRAL DE RESERVA DEL PERÚ**

## **Tendencias comunes en el índice de precios al consumidor**

María Gracia Ramos<sup>1</sup> y Diego Winkelried<sup>2</sup>

<sup>1</sup> Banco Central de Reserva del Perú

<sup>2</sup> Universidad del Pacífico (Lima, Perú)

DT. N° 2016-004  
Serie de Documentos de Trabajo  
Working Paper series  
Abril 2016

Los puntos de vista expresados en este documento de trabajo corresponden a los autores y no reflejan necesariamente la posición del Banco Central de Reserva del Perú.

*The views expressed in this paper are those of the authors and do not reflect necessarily the position of the Central Reserve Bank of Peru.*

# Tendencias comunes en el índice de precios al consumidor\*

**María Gracia Ramos**

*Banco Central de Reserva del Perú*

[mariagracia.ramos@bcrp.gob.pe](mailto:mariagracia.ramos@bcrp.gob.pe)

**Diego Winkelried**

*Universidad del Pacífico (Lima, Perú)*

[winkelried\\_dm@up.edu.pe](mailto:winkelried_dm@up.edu.pe)

Esta versión: June 20, 2016

## Resumen

Este documento analiza el comportamiento de largo plazo de los rubros que componen el índice de precios al consumidor de Lima Metropolitana, utilizando el modelo factorial propuesto en Phillips y Sul (*Econometrica*, 75(6), 2007). Con ello, identificamos cuatro tendencias comunes: una de alta inflación, dos de inflación intermedia y una de baja inflación. Este análisis permite entender mejor por qué la inflación subyacente calculada por el BCRP resulta ser una buena medida de inflación tendencial.

**Clasificación JEL** : C22, E31.

**Palabras clave** : Inflación, *cluster* de convergencia, tendencias comunes.

---

\*Agradecemos los comentarios de Adrián Armas, Renzo Castellares, Rocío Gondo, Guillermo Moloche, Fernando Pérez, Marco Vega y de participantes del XXXII Encuentro de Economistas del BCRP. Todas las opiniones presentadas en este documento son nuestra responsabilidad.

# 1 Introducción

Desde el año 2002, el Banco Central de Reserva del Perú (BCRP) aplica el esquema de metas explícitas de inflación en la conducción de la política monetaria. Bajo este esquema, el BCRP se compromete a mantener la inflación, medida a través de la variación del índice de precios al consumidor (IPC) de Lima Metropolitana, dentro de un rango meta, y de tomar las acciones pertinentes para que cualquier desvío de esta revierta en el mediano plazo (véase [Armas y Grippa, 2006](#), para una mayor discusión).

Si bien el compromiso es con la inflación del IPC, el uso del IPC presenta limitaciones prácticas para el monitoreo de las condiciones económicas en tiempo real. Ello ocurre porque el IPC contiene rubros, como ciertos alimentos y combustibles, que son muy sensibles a choques de oferta, usualmente de gran magnitud pero de poca duración, por lo que no siempre daría una señal clara sobre un aumento de precios sostenido (véase [Winkelried, 2010, 2013](#)). Ante ello, como precisan [Armas y otros \(2011\)](#), es conveniente utilizar medidas de inflación subyacente, que intentan medir la tendencia de la inflación y, por ende, no serían tan propensas a reaccionar ante choques de poco interés para la política monetaria.

El enfoque más común para obtener una medida de inflación subyacente, por su simplicidad y replicabilidad, es la exclusión de rubros del IPC. Es decir, esta medida es la variación de agregaciones de índices de precios de canasta reducida del IPC que excluyen los rubros más volátiles. Siguiendo la práctica de la Fed, la medida más utilizada a nivel mundial es la inflación sin alimentos ni energía (SAE). En el caso del Perú, además, el BCRP calcula una medida alternativa (SUBY), en donde se excluyen los rubros del IPC que los expertos consideran solo añaden volatilidad a la inflación, mas no alteran su tendencia. [Armas y otros \(2011\)](#) muestran que esta construcción *ad hoc* de inflación subyacente resulta ser, entre varias alternativas, la mejor medida de inflación tendencial en el caso peruano.

El fundamento detrás de esta noción de inflación subyacente es que la inflación del rubro  $i$  del IPC en el momento  $t$  puede representarse como  $\pi_{it} = \mu_t + v_{it}$ , donde  $\mu_t$  sería la inflación tendencial de interés y  $v_{it}$  es un desvío transitorio de media cero. La inflación del IPC es un promedio ponderado de las  $n$  inflaciones individuales (con pesos  $w_i$  que suman 1), tal que  $\pi_t = \mu_t + V_t$  donde  $V_t = \sum_{i=1}^n w_i v_{it}$ . La ley de grandes números a lo largo de  $i$  hace que  $V_t$  sea un término más cercano a cero y de menor varianza que el  $v_{it}$  individual. Las medidas de exclusión guardan una lógica similar, pero con pesos redefinidos  $\tilde{w}_i$  y algunos de ellos iguales a cero:  $\tilde{\pi}_t = \mu_t + \tilde{V}_t$  donde  $\tilde{V}_t = \sum_{i=1}^n \tilde{w}_i v_{it}$ . Toda vez que la selección de  $\tilde{w}_i$  se oriente a reducir la varianza de  $\tilde{V}_t$ , se tendría una señal más cercana a  $\mu_t$  que la inflación misma  $\pi_t$ .

Es importante notar que la representación  $\pi_{it} = \mu_t + v_{it}$  corresponde a un modelo factorial *con un solo factor*. Es decir, un supuesto inherente detrás de la medición de la inflación subyacente por métodos de exclusión es que las inflaciones individuales comparten una tendencia común. Así, la exclusión de rubros volátiles facilita la inferencia sobre  $\mu_t$ . Este supuesto, en términos generales, es difícil de contrastar con herramientas habituales (por ejemplo, pruebas de cointegración) en un contexto donde  $n$  es grande. En el caso peruano, [Humala y Rodríguez \(1997\)](#) proveen una primera aproximación y encuentran que a nivel desagregado las inflaciones individuales serían mejor representadas con un modelo de varios factores.<sup>1</sup>

El propósito de este documento es evaluar el supuesto de una tendencia común en los rubros del IPC. Para

---

<sup>1</sup> [Barrera \(2005, 2007, 2013\)](#) explora el contenido informativo de las inflaciones individuales para predecir la inflación agregada y encuentra ganancias en la capacidad predictiva de modelos desagregados. Aunque estos estudios no formulan la presencia de factores o tendencias comunes, la gran heterogeneidad de las ecuaciones de predicción de las inflaciones individuales permite conjeturar la presencia de más de un factor. Asimismo, [Carrera y Ledesma \(2015\)](#) utilizan un gran modelo VAR Bayesiano para el mismo propósito. Llama la atención de este estudio que la introducción de *priors* que permiten una forma básica de cointegración entre las inflaciones individuales no mejora sustancialmente la capacidad predictiva de estos modelos. Ello es coherente con la presencia de muchas tendencias comunes, no todas ellas capturadas por este *prior*.

ello, utilizamos la metodología propuesta en [Phillips y Sul \(2007a\)](#).<sup>2</sup> Este enfoque permite estudiar las relaciones de largo plazo de un panel de series de tiempo fuera del marco habitual de cointegración. Una ventaja es que los supuestos sobre el proceso generador de datos de estas series son bastante generales, y permiten agrupar a las series que conforman el panel en *clusters* de convergencia. La representación  $\pi_{it} = \mu_t + v_{it}$  es válida dentro de cada *cluster*, pero podría no serlo para todo el panel. En otras palabras, cada *cluster* es definido por una tendencia común exclusiva para sus miembros. Los rubros individuales del IPC son clasificados no por su volatilidad relativa, que sería el caso para los criterios de exclusión, sino por su comportamiento de largo plazo. Nuestro principal hallazgo es la presencia de cuatro *clusters* de convergencia en los rubros del IPC, uno de ellos asociado a precios con alta inflación, dos asociados con tasas de inflación intermedias y el último asociado con precios con baja inflación (incluso, deflación).

El resto del documento se organiza de la siguiente manera. La sección 2 discute la metodología de [Phillips y Sul \(2007a\)](#) y describe el algoritmo empleado para hallar los *clusters* de convergencia. Posteriormente, la sección 3 describe los datos y presenta los resultados. Finalmente, la sección 4 discute líneas de investigación futuras que pueden derivarse de nuestro análisis.

## 2 Marco metodológico

A continuación, describimos la metodología propuesta por [Phillips y Sul \(2007a\)](#) para identificar patrones de convergencia en un panel de datos. Parte importante de este enfoque es el proveer una prueba estadística simple para determinar *clusters* de convergencia; es decir, grupos dentro del panel cuyo comportamiento es similar en el largo plazo. Lo más interesante, sin embargo, es que la metodología no requiere de mayores supuestos de estacionariedad o no estacionariedad de las series involucradas en el análisis, lo que permite modelar empíricamente el comportamiento de largo plazo de las series fuera del marco usual de cointegración.

El punto de partida es el modelo de factor común

$$p_{it} = \beta_{it}\mu_t, \quad (1)$$

donde  $p_{it}$  es la serie de tiempo observada (el logaritmo del índice de precio) que corresponde a la unidad  $i$  del panel;  $\mu_t$  representa al factor común, al que nos referimos como la “tendencia común”; y  $\beta_{it}$  es un componente transitorio que desvía a la variable observada  $p_{it}$  de esta tendencia. En un contexto de convergencia, estos desvíos son transitorios aunque podrían ser altamente persistentes. Más aún,  $p_{it}$  podría mostrar inicialmente un comportamiento divergente respecto a la tendencia  $\mu_t$ , y la convergencia podría darse siempre que esta discrepancia inicial se diluya con el paso del tiempo. Este tipo de comportamiento típicamente resta potencia a los contrastes de cointegración, favoreciendo la inexistencia de una relación estable de largo plazo.

A su vez, el comportamiento de  $\beta_{it}$  se modela de forma semiparamétrica como

$$\beta_{it} = \beta_i + \frac{e_{it}}{L(t)t^\alpha}. \quad (2)$$

donde  $\beta_i$  es un parámetro;  $e_{it} \sim iid(0, \sigma_i^2)$  a lo largo de  $i$  y estacionario a lo largo de  $t$ ; y  $L(t)$  es una función

---

<sup>2</sup> Esta metodología ha sido utilizada para estudiar la convergencia en varios fenómenos económicos: emisiones de carbono ([Camarero y otros, 2013](#); [Wang y otros, 2014](#)), precios de viviendas ([Kim y Rous, 2012](#); [Montañés y Olmos, 2010](#)), precios de productos individuales ([Fischer, 2012](#); [Morrison y Fontenla, 2013](#)), profundidad financiera ([Apergis y otros, 2012](#)) y, por supuesto, crecimiento e ingreso per cápita ([Phillips y Sul, 2007b, 2009](#); [Fritsche y Kuzin, 2011](#); [Bartkowska y Riedl, 2012](#)). Para el caso peruano, el método ha sido utilizado por [Delgado y Rodríguez \(2013\)](#) en el análisis de convergencia regional.

de  $t$  que diverge a una tasa menor que  $t$ ; por ejemplo, [Phillips y Sul \(2007a\)](#) sugieren  $L(t) = \log(t + 1)$ . Es claro que si  $\alpha \geq 0$ , entonces  $\beta_{it}$  convergerá a  $\beta_i$  y, por tanto,  $p_{it}$  convergerá a  $\beta_i \mu_t$ . Así, dado  $i$ ,  $\alpha \geq 0$  resulta ser la hipótesis de interés. No obstante, si todos los rubros del panel han de converger a la tendencia común, se requiere adicionalmente que  $\beta_i = \beta$  para todo  $i$ .

La especificación en (2) es válida toda vez que  $p_{it}$  no presente variaciones de corto plazo, en frecuencias cíclicas, o mucho ruido. De otro modo, habría que agregar un término estocástico a (2) que capture estos movimientos. Por ello, [Phillips y Sul \(2007a\)](#) sugieren prefiltrar los datos. Para tal propósito se utiliza el filtro de [Hodrick y Prescott \(1997\)](#) con un parámetro de suavizamiento de  $\lambda = 8331$ . Siguiendo a [Gómez \(2001\)](#), esta calibración de  $\lambda$  hace que el filtro de [Hodrick y Prescott](#) aisle las fluctuaciones de cinco años o más de una serie de tiempo mensual.<sup>3</sup>

Una manera práctica de extraer información sobre  $\alpha$  a partir de los datos observados  $p_{it}$  es considerar la *curva de transición relativa* definida como

$$h_{it} = \frac{p_{it}}{\sum_{k=1}^n p_{kt}/n} = \frac{\beta_{it}}{\sum_{k=1}^n \beta_{kt}/n}, \quad (3)$$

que mide  $\beta_{it}$  en relación al promedio transversal (para un valor dado de  $t$  y a lo largo de  $n$  rubros) y describe la transición de  $p_{it}$  hacia la tendencia común. Note que  $h_{it}$  puede interpretarse como un precio relativo respecto a la tendencia medida a través del promedio transversal. Cuando todos los rubros de la sección transversal convergen y  $\beta_i = \beta$ , se tiene que  $h_{it} \rightarrow 1$  para todo  $i$ . Luego,

$$H_t = \frac{1}{n} \sum_{k=1}^n (h_{kt} - 1)^2 \quad (4)$$

mide la dispersión observada respecto al estado de convergencia.

[Phillips y Sul \(2007a\)](#) proponen una regresión simple para determinar, finalmente, si la convergencia se da. *Bajo el supuesto que  $\beta_i = \beta$* , se tiene que

$$H_t = \frac{U_t}{L(t)^2 t^{2\alpha}} \quad \text{donde} \quad U_t = \frac{1}{n} \sum_{k=1}^n \left( \frac{e_{kt} - \bar{e}_t}{\beta + \bar{e}_t L(t)^{-1} t^{-\alpha}} \right)^2, \quad (5)$$

siendo  $\bar{e}_t$  el promedio transversal de  $e_{it}$ . Note que el denominador de la variable aleatoria  $U_t$  será igual a  $\beta^2$  para valores suficientemente grandes de  $t$ . Luego, es simple verificar que al tomar logaritmos a  $H_1/H_t$  se consigue

$$\log \left( \frac{H_1}{H_t} \right) = -2 \log L(t) = c + \phi \log t + u_t, \quad (6)$$

donde  $c = 2 \log L(1) + \mathbb{E}[\log(U_1/U_t)]$ ,  $u_t = \log(U_1/U_t) - \mathbb{E}[\log(U_1/U_t)]$  y  $\phi = 2\alpha$ . Es decir, una regresión simple de  $\log(H_1/H_t)$  sobre una constante y  $\log t$  permite inferir directamente sobre el valor de  $\alpha$ .

La hipótesis nula de interés,  $\alpha \geq 0$ , pasa a ser  $\phi = 2\alpha \geq 0$ . Esta hipótesis debe ser verificada utilizando un estimador HAC para el error estándar ya que es altamente probable que  $u_t$  sea un término de error autocorrelacionado. Un ratio  $t$ ,  $\tau_\phi$ , muy negativo provee evidencia en contra de la convergencia. El valor

<sup>3</sup> Específicamente, [Gómez \(2001\)](#) muestra que para series de tiempo muestreadas  $s$  veces al año, la tendencia calculada con el filtro de [Hodrick y Prescott](#) puede interpretarse como el componente de la serie que explica su variabilidad en periodos de  $T^*$  años o más, cuando  $\lambda = [2 \sin(\pi/(T^*s))]^{-4}$ . Para  $T^* = 5$  y  $s = 12$ , se consigue  $\lambda = 8331$ . El caso emblemático de  $\lambda = 1600$  corresponde a un periodo de aproximadamente  $T^* = 10$  años para datos trimestrales,  $s = 4$ .

crítico, al 5 por ciento de significación, de la prueba de una cola que tiene como hipótesis alternativa  $\alpha > 0$ , es  $-1.65$ .

La hipótesis  $\phi \geq 0$  podría ser rechazada porque el supuesto básico detrás de la validez de (6), es decir  $\beta_i = \beta$ , podría no cumplirse. Surge entonces la idea de *clusters de convergencia*: para un grupo de precios  $\beta_i = \beta_A$ , mientras que para otro  $\beta_i = \beta_B \neq \beta_A$ . En este caso, cada rubro dentro de un grupo convergerá a su propia tendencia, pero todos los rubros divergirán si se les considera como parte de un único grupo. Phillips y Sul (2007a) proponen utilizar la regresión (6) secuencialmente para dar cuenta de esta posibilidad. El resultado es el siguiente algoritmo de determinación de *clusters*:

1. Los datos son normalizados tal que  $p_{i1} = p_1$  para todo  $i$ . Luego, se ordenan los rubros de acuerdo con el valor de  $p_{iT}$ , donde  $T$  es el número de observaciones temporales en el panel (los rubros que mayor inflación han acumulado van primero).
2. Se forma un *grupo inicial*. Los primeros  $k \geq 2$  rubros se eligen, agregando uno a la vez, y se calcula el estadístico  $\tau_\phi(k)$  hasta que la condición  $\tau_\phi(k) > -1.65$  deje de ser satisfecha. Luego se elige el valor de  $k$  que maximiza el estadístico  $\tau_\phi(k)$ . El resto de rubros pasa a formar un *grupo complementario*.

Si resulta que este estadístico es maximizado para  $k = n$ , entonces el grupo entero es convergente y el algoritmo termina. Por el contrario, si la condición  $\tau_\phi(k) > -1.65$  no se cumple para  $k = 2$ , entonces el primer rubro es considerado atípico, es descartado y el procedimiento se repite para los rubros restantes. Si ello ocurre para todos los subsecuentes pares de rubros, entonces se concluye que no existen *clusters* de convergencia y el algoritmo termina.

3. El *grupo inicial* es ahora aumentado. Se incluyen, uno por uno, rubros del grupo complementario al grupo inicial y se calcula el estadístico  $\tau_\phi$ , que denominamos  $\tau_\phi(k)$ . En este punto es importante ser exigentes con el criterio de inclusión al *cluster* y solamente se consideran como candidatos los rubros  $k$  que cumplen con  $\tau_\phi(k) > 0$ . Una vez identificados estos rubros se procede a incluirlos en bloque al grupo inicial y se verifica si  $\tau_\phi > -1.65$  en el grupo extendido. Si este es el caso, hemos conseguido el *cluster* de convergencia. Si no, se excluyen, uno por uno de acuerdo con el valor obtenido por el estadístico  $\tau_\phi(k)$  (de menor a mayor), hasta obtener  $\tau_\phi > -1.65$ .<sup>4</sup>
4. Los rubros descartados en el paso 3 forman un nuevo grupo complementario. Si se consigue  $\tau_\phi > -1.65$  para este grupo, entonces el algoritmo termina y se consigue un nuevo *cluster* de convergencia. De lo contrario, se repiten los pasos 1, 2 y 3 utilizando como panel únicamente los rubros del grupo complementario.

Dos consideraciones finales. Primero, dado que el algoritmo requiere la normalización  $p_{i1} = p_1$ , los datos podrían dar la impresión artificial de convergencia inicial si se incluyen todas las observaciones temporales. Por ello, es deseable descartar una fracción inicial de observaciones  $r$  para aminorar los efectos en la inferencia de esta normalización. Phillips y Sul (2007a) muestran que la potencia del algoritmo y su capacidad de identificar correctamente los *clusters* dependen del valor de  $r$  elegido y sugieren utilizar  $r \in (0.2, 0.3)$ . En la práctica, no obstante, es deseable realizar un análisis de sensibilidad sobre esta elección. Segundo, el paso 3 del algoritmo es bastante conservador para evitar la inclusión de un miembro falso en el *cluster*. Ello hace que el algoritmo muestre cierta tendencia a formar más *clusters* que los que

<sup>4</sup> Phillips y Sul (2007a) proponen un paso 3 diferente, en donde iteran el valor crítico utilizado para inclusión de rubros al grupo inicial. Nuestro enfoque es más sencillo y no encontramos diferencias importantes con los resultados del algoritmo original.

realmente existen. Por ello, [Phillips y Sul \(2007a\)](#) sugieren que una vez que se identifican los *clusters* se realice una prueba de convergencia adicional entre los miembros de *clusters* contiguos y, de ser el caso (al obtener  $\tau_\phi > -1.65$ ), juntarlos en un único *cluster*.

### 3 Exploración empírica

#### 3.1 Datos

El Instituto Nacional de Estadística e Informática (INEI) publica mensualmente los datos del IPC de Lima Metropolitana que, desde el año 2009, es el agregado de los índices de precios de 174 bienes y servicios que componen la canasta de consumo representativa. Anteriormente, la base del IPC era diciembre de 2001 y la canasta se componía de 163 bienes y servicios. Como detallan [Armas y otros \(2011\)](#), en el nivel de mayor desagregación pueden encontrarse 7 rubros que dejaron de ser incluidos en la canasta representativa, mientras que 17 nuevos rubros fueron incorporados (algunos de ellos son mayores desagregaciones de categorías excluidas). Para trabajar con una única canasta sin valores omitidos, agregamos los rubros de ambas canastas con observaciones omitidas en categorías que se mantienen durante todo el periodo de análisis. Así, conseguimos 150 rubros (es decir, el total de 174 rubros menos los 24 que experimentaron algún cambio), durante el periodo que va desde diciembre de 1994 hasta diciembre de 2013 (229 observaciones).

Los 150 rubros bajo análisis son clasificados por el INEI en los ocho grandes grupos mostrados en el Cuadro 1. De este total, 106 corresponden a la inflación subyacente calculada por el BCRP (inflación SUBY) y representan 65.1 por ciento de la canasta del IPC. Por su parte, la inflación SAE contiene 72 rubros que representan el 56.4 por ciento de la canasta del IPC. En ambos casos, los rubros excluidos pertenecen a los grupos de alimentos y bebidas, alquiler de vivienda, combustible y electricidad, y transportes y comunicaciones.

El panel (a) del Gráfico 1 muestra los percentiles de las distribuciones transversales (es decir, para un valor dado de  $t$ ) del logaritmo de los índices de precios, bajo la normalización  $p_{i1} = \log(100)$  en diciembre de 1994, y después de haber sido suavizados con el filtro [Hodrick y Prescott](#) con un parámetro de suavizamiento de  $\lambda = 8331$ . Es interesante notar la gran heterogeneidad que se puede observar hacia el final de la muestra, donde la distribución transversal de índices individuales varía desde valores menores que  $\log(130)$  hasta valores mayores a  $\log(250)$ . Por su parte, el panel (b) del Gráfico 1 presenta la distribución transversal de las tasas de inflación (de los últimos 12 meses), en donde también se percibe una gran disparidad: si bien es cierto que la inflación mediana ha sido estable y ha fluctuado desde inicios de la década de los 2000 en torno a entre 2 y 4 por ciento, las distribuciones transversales pueden registrar tanto tasas de inflación muy altas (más allá de 10 por ciento) como tasas muy bajas (negativas). Nuestro propósito es investigar si esta heterogeneidad puede ser caracterizada por un grupo pequeño de tendencias comunes o *clusters* de convergencia.

#### 3.2 Condiciones iniciales

El panel (a) del Gráfico 1 muestra que el efecto de la condición inicial  $p_{i1} = \log(100)$  tiende a diluirse, aunque puede tardar algunos años en hacerlo. Inicialmente, por construcción, los percentiles de las distribuciones transversales se encuentran muy concentrados en torno a la mediana, y conforme pasa el tiempo estos van dispersándose hasta llegar a lo que aparentemente es una distribución estable. El Gráfico 2 muestra las diferencias entre varios percentiles de la distribución transversal de  $p_{it}$  como un resumen de la evolución de la dispersión de estas distribuciones. Se aprecia que en un inicio estas medidas tienden a incrementarse muy rápidamente, mientras que en un segundo régimen estas tienden a incrementarse pero



a un ritmo bastante más moderado. El primer régimen es una manifestación del efecto de la normalización  $p_{i1} = \log(100)$ , mientras que el segundo puede considerarse como un periodo en donde estas condiciones iniciales no influyen más en el análisis.

El Gráfico 2 muestra, además, la tendencia lineal quebrada que mejor ajusta estos datos, para cada una de las diferencias entre percentiles.<sup>5</sup> Estas tendencias presentan una pronunciada pendiente positiva inicial, seguida de una pendiente bastante más cercana a cero. Las fechas de ocurrencia de los cambios en tendencia se encuentran a inicios de la década de los 2000. Considerando el periodo completo de análisis, las observaciones del segundo régimen corresponden a la fracción  $r \approx 0.25$ , es decir el primer régimen ocupa el primer cuarto de la muestra. Este valor es bastante cercano al sugerido por Phillips y Sul (2007a) para la estimación de (6). Más aún, en el caso peruano este valor de  $r$  corresponde también al momento cuando la inflación deja de mostrar una marcada tendencia negativa para estabilizarse en torno a niveles internacionales, como una antesala al inicio del régimen de metas explícitas de inflación en 2002. Así, más allá de aminorar los efectos de la normalización  $p_{i1} = \log(100)$ , la elección de  $r \approx 0.25$  hace que nuestro exploración empírica se centre en la era reciente de estabilidad de precios.

El Cuadro 2 muestra los resultados de estimar la regresión (6) para distintos valores de  $r$ , la fracción de la muestra descartada. Estas regresiones son para la convergencia de los  $n = 150$  rubros del IPC considerados. Los estadísticos  $\tau_\phi$ , sin excepciones, son considerablemente menores al valor crítico de  $-1.65$ , lo que implica un fuerte rechazo de la hipótesis de convergencia de todos los rubros del IPC hacia una única tendencia común. Estos resultados son bastante robustos a la elección de  $r$ , quien varía de  $r \approx 0.15$  a  $r \approx 0.40$ . Otros aspectos del análisis de convergencia también resultaron robustos a esta elección. En adelante, presentamos los resultados obtenidos para la muestra de 168 observaciones que se inicia en enero de 2000.

### 3.3 Grupos de convergencia

La aplicación del algoritmo descrito en la sección metodológica dio como resultado cuatro *clusters* de convergencia. Es decir, da respaldo a la presencia de cuatro tendencias comunes entre los 150 rubros que componen el IPC. A continuación describimos los resultados obtenidos.

#### *Primer cluster (cluster de alta inflación)*

El primer *cluster* se compone de 24 rubros del IPC. El estadístico  $\tau_\phi$  de la regresión de convergencia para los  $n = 150$  rubros del IPC fue  $\tau_\phi = -22.97$ , un rechazo categórico a la convergencia de todos estos rubros. El paso 2 del algoritmo permitió identificar un grupo inicial conformado por los siguientes 5 rubros: cereales poco transformados, otros combustibles y gas natural, transporte nacional, mariscos y consumo de agua. El estadístico  $\tau_\phi$  en el grupo inicial fue de  $\tau_\phi = 2.48$ , mientras que el correspondiente a los 145 rubros del grupo complementario ascendió a  $\tau_\phi = -16.79$ .

Luego, el paso 3 agregó 19 rubros al grupo inicial. Estos fueron (con el respectivo estadístico  $\tau_\phi(k)$  entre paréntesis): camote (2.48), enseñanza y matrícula (1.85), cigarrillos (1.81), pasaje en avión (1.81), papaya (1.62), combustibles de vehículos y lubricantes (1.56), servicio de correo (1.46), medicinas y anticonceptivos (1.00), frijol (0.95), productos alimenticios diversos (0.82), artículos de joyería (0.71), pescado fresco y congelado (0.70), sal (0.49), hospitalización (0.47), pan (0.22), gastos judiciales (0.19), maíz (0.09), trigo (0.06) y pescados en conserva (0.01). El estadístico  $\tau_\phi$  en el grupo aumentado fue de  $\tau_\phi = 1.28$ , mientras que el correspondiente a los 126 rubros restantes fue de  $\tau_\phi = -14.62$ . Así, no hubo

<sup>5</sup> Defina la variable *dummy*  $D_t = 1$  si  $t > t^*$  y  $D_t = 0$  si  $t \leq t^*$ . Para alguna de estas diferencias  $z_t$ , se estimó la regresión  $z_t = \beta_0 + \beta_1[(1 - D_t)t + D_t t^*] + \beta_2 D_t(t - t^*) + \text{error}_t$ , que implica que  $\mathbb{E}[z_t | D_t = 0] = \beta_0 + \beta_1 t$  en el primer régimen, mientras que  $\mathbb{E}[z_t | D_t = 1] = \beta_0 + (\beta_1 - \beta_2)t^* + \beta_2 t$  en el segundo régimen. Ello describe una tendencia lineal quebrada pero continua,  $\mathbb{E}[z_{t^*} | D_t = 0] = \mathbb{E}[z_{t^*} | D_t = 1]$ . Se eligió el valor de  $t^*$  que maximizó el ajuste de esta regresión.



necesidad de mayor refinamiento y se consiguió el primer *cluster*.

### *Segundo cluster (cluster de inflación intermedia)*

El segundo *cluster* se compone de 68 rubros del IPC. El estadístico  $\tau_\phi$  de la regresión de convergencia para los 126 rubros fuera del primer *cluster* fue  $\tau_\phi = -14.62$ . El paso 2 del algoritmo permitió identificar un grupo inicial conformado por los siguientes 8 rubros: cortinas y otros accesorios de la vivienda, camas, otros gastos de vehículos, huevos, comidas fuera del hogar, otras hortalizas, harina de cereales y cereales procesados, y aparatos terapéuticos. El estadístico  $\tau_\phi$  en el grupo inicial fue de  $\tau_\phi = 4.20$ , mientras que el correspondiente a los 118 rubros del grupo complementario fue de  $\tau_\phi = -12.01$ .

El paso 3 agregó los siguientes 60 rubros al grupo inicial (estadístico  $\tau_\phi(k)$  entre paréntesis): otras menestras (6.89), cacao y sucedáneos (5.64), gira turística y hoteles (4.98), artículos de confección y tejido (4.80), alimentos preparados (4.77), margarina (4.77), arroz (4.61), textos y útiles escolares y de escritorio (4.47), bebidas con alto contenido alcohólico (4.44), choclo (4.42), otros utensilios domésticos (4.30), aceites (4.29), papa (4.24), yuca (4.17), pasaje urbano e interurbano (4.11), otros alimentos fuera del hogar (4.09), arbitrios municipales (4.08), preparados de carne (4.05), legumbres frescas (4.04), artículos de limpieza (4.02), bebidas con bajo contenido alcohólico (3.96), vajilla (3.93), cebolla (3.88), gastos en bautismo y matrimonio (3.84), ropa para hombres y niños mayores de 12 años (3.84), tomate (3.83), pasteles y similares (3.67), servicio dental (3.46), zapallo (3.32), zanahoria (3.30), seguros (3.11), telas (3.05), reparación de vehículos (3.00), gas (2.85), plátano (2.84), colchón (2.72), consultas médicas (2.68), confección de diversas prendas de vestir (2.65), compra de muebles (2.54), frazadas (1.94), carne de carnero (1.86), reparación y repuestos de electrodomésticos (1.83), uva (1.79), café (1.79), ají (1.77), ropa y reparación de ropa de niños y niñas (1.69), licuadora y extractor (1.69), apio (1.66), repuestos y lavado de vehículos (1.46), carne de cerdo (1.45), productos azucarados (1.36), refrigeradora (1.31), azúcar (1.25), leche en conserva (1.22), ajos (0.84), carne de otras aves (0.74), frutas secas o en conserva (0.43), gaseosas, jugos o refrescos (0.32), ropa para mujeres y niñas mayores de 12 años (0.05) y otras frutas frescas (0.05). El estadístico  $\tau_\phi$  en el grupo de 68 rubros fue de  $\tau_\phi = 2.51$ , mientras que el correspondiente a los 58 rubros restantes fue de  $\tau_\phi = -9.58$ . No hubo, pues, necesidad de mayor refinamiento y se consiguió el segundo *cluster*.

Al juntar a los 24 miembros del primer *cluster* con los 68 del segundo, se obtuvo un estadístico  $\tau_\phi = -3.10$ , rechazado así que el grupo como un todo converga a una misma tendencia. Se confirma, con ello, la presencia de dos tendencias comunes hasta el momento.

### *Tercer cluster (cluster de inflación intermedia)*

El tercer *cluster* se compone de 50 rubros. Como se mencionó, el estadístico  $\tau_\phi$  de la regresión de convergencia para los 58 rubros fuera de los dos primeros *clusters* fue  $\tau_\phi = -9.58$ . El paso 2 del algoritmo permitió identificar un grupo inicial con 20 rubros: bebidas no alcohólicas, reparaciones diversas de ropa y calzado, reparación de radio y televisor, otros servicios médicos, leche fresca, servicio de limpieza, empleados del hogar, calzado para mujeres y niñas mayores de 12 años, alquiler de vivienda, bebidas alcohólicas, revistas y afines, aparatos de cocina y para calentar, calzado niños y niñas, avena, servicios de cuidado personal, artículos de cuidado personal, entradas a espectáculos, gastos en clases y gastos en mascotas, calzado para hombres y niños mayores de 12 años, compostura de muebles, y reparación, servicios y otros gastos de la vivienda. El estadístico  $\tau_\phi$  para el grupo inicial fue de  $\tau_\phi = 2.64$ , mientras que el correspondiente a los 38 rubros del grupo complementario fue de  $\tau_\phi = -5.98$ .

Luego, el paso 3 agregó 30 rubros al grupo inicial (estadístico  $\tau_\phi(k)$  entre paréntesis): olluco y similares (6.17), plancha (5.55), fideos (5.43), artículos recreativos (5.20), carne de pollo (5.09), colcha y cubrecamas (5.07), otros gastos diversos (5.04), compra de vehículos (4.88), carne de res (4.88),

cerveza (4.86), electricidad (4.74), toallas (4.70), otras menudencias (4.54), galletas (4.48), cristalería (4.27), quesos (4.17), harina y otros derivados (3.99), otros artículos del hogar (3.99), lavadora (3.98), mantequilla (3.80), sábanas (3.77), manzana (3.71), duraznos (3.62), libros no escolares (3.12), especias y sazónadores (2.62), aceituna (2.61), cítricos (2.35), palta (2.14), té (2.04), y otros alimentos (0.93). El estadístico  $\tau_\phi$  en el grupo de 50 rubros fue de  $\tau_\phi = 2.64$ , mientras que el correspondiente a los 8 rubros restantes fue de  $\tau_\phi = -7.65$ . No se precisó de mayor refinamiento y se consiguió el tercer *cluster*.

Tras juntar a los 68 miembros del segundo *cluster* con los 50 del tercero, se obtuvo un estadístico  $\tau_\phi = -2.23$ , confirmando así la presencia de tres tendencias comunes hasta el momento.

#### *Cuarto cluster (cluster de baja inflación)*

Finalmente, el cuarto *cluster* se compone de 7 rubros del IPC. El estadístico  $\tau_\phi$  de la regresión con 8 rubros fuera de los tres primeros *clusters* fue de  $\tau_\phi = -7.65$ . El grupo inicial obtenido en el paso 2 estuvo conformado por 6 rubros: bombas de luz, aparatos de radio y equipos de sonido, menudencia de pollo y otras aves, hierbas para infusión y similares, teléfono e internet, y aparatos de televisión. El estadístico  $\tau_\phi$  en el grupo inicial fue de  $\tau_\phi = 8.10$ , mientras que el correspondiente a los 2 rubros del grupo complementario ascendió a  $\tau_\phi = -3.13$ .

El paso 3 agregó un rubro al grupo inicial, periódicos, con el respectivo estadístico  $\tau_\phi = 5.22$ . El rubro excluido fue aparatos de recreo y cultura y no fue posible asignarlo a ninguno de los cuatro *clusters* identificados. Junto con el rubro periódicos, este ha mostrado una tasa de inflación negativa (el índice ha decrecido) en toda la muestra de análisis. No obstante, la deflación de periódicos fue aproximadamente de 3 por ciento, lo que permitió agregarlo al cuarto *cluster*, mientras que la de aparatos de recreo y cultura fue de casi 6 por ciento.

Tras juntar a los 50 miembros del tercer *cluster* con los 7 del cuarto, se obtuvo un estadístico  $\tau_\phi = -4.13$ , confirmando así la presencia de cuatro tendencias comunes.

### **3.4 Tendencias comunes**

El Gráfico 3 (p. 16) muestra estimaciones de las tendencias comunes, calculadas como los promedios simples de los índices de precios que conforman cada *cluster*, y sus respectivas inflaciones. Es bastante claro que estas tendencias muestran un comportamiento diferenciado en el largo plazo. El primer *cluster* agrupa índices de precios que han acumulado altas tasas de inflación en el periodo de análisis, mientras que el cuarto *cluster* agrupa precios que incluso han disminuido en el mismo periodo. El segundo y tercer *cluster* se conforman de precios con inflación intermedia.

El panel (a) del Cuadro 3 (p. 14) muestra estadísticas descriptivas sobre la inflación de los índices promedios en cada *cluster* durante el ejercicio del esquema de metas de inflación (de enero de 2002 a diciembre de 2013). Mientras que la inflación promedio de todos los rubros del IPC fue de 2.50 por ciento, la inflación promedio en el primer *cluster* fue de 4.85 por ciento, y la del cuarto *cluster* fue de -1.72 por ciento. Las inflaciones de los *clusters* restantes ascendieron a 2.93 y 1.48 por ciento. Todas estos estimados son estadísticamente diferentes al 2.50 por ciento agregado: el estadístico  $t$  de la hipótesis nula de igualdad de inflaciones ( $t_\Delta$ ) cae siempre y categóricamente en zona de rechazo. Finalmente, el gran promedio de 2.50 por ciento puede descomponerse en una contribución de 1.82 por ciento de los *clusters* de inflación intermedia ( $1.82 = 1.33 + 0.49$ ), más 0.78 por ciento del *cluster* de alta inflación y -0.09 del *cluster* de baja inflación.

El panel (b) del Cuadro 3 muestra resultados análogos, después de ponderar los rubros por los pesos que reciben en la canasta del IPC. En esta ocasión, se aprecia que la inflación promedio del IPC fue de 2.22 por ciento, la inflación promedio en el primer *cluster* fue de 3.83 por ciento, la del cuarto *cluster* fue de

−3.25 por ciento, y las de los *clusters* intermedios ascendieron a 2.92 y 1.32 por ciento. Estos estimados, nuevamente, son estadísticamente diferentes al 2.22 por ciento agregado. La inflación promedio del IPC se descompone en una contribución de 1.66 por ciento de los *clusters* de inflación intermedia, más 0.75 por ciento del *cluster* de alta inflación menos 0.20 del *cluster* de baja inflación. Asimismo, se aprecia que el 20 por ciento de la canasta del IPC corresponde a rubros que pertenecen al primer *cluster*, 74 por ciento a rubros de los *clusters* intermedios y el restante 6 por ciento al *cluster* de baja inflación.

Es interesante comparar estos resultados con los del panel (c) del Cuadro 3, que corresponden a la inflación SUBY. La inflación SUBY promedio fue idéntica a la del IPC, 2.22 por ciento de los cuales 1.61 por ciento se debe a los *clusters* de inflación intermedia, 0.68 por ciento al *cluster* de alta inflación y −0.08 al *cluster* de baja inflación. De hecho, el 20 por ciento de la canasta del IPC SUBY corresponde a rubros que pertenecen al primer *cluster*, 77 por ciento a rubros de los *clusters* intermedios y el restante 3 por ciento al *cluster* de baja inflación. Respecto a lo obtenido con el IPC total, se aprecia que la contribución de los *clusters* intermedios es similar pero las contribuciones de los *clusters* extremos son algo menores. Ello estaría sugiriendo que los miembros de los *clusters* de alta y baja inflaciones serían más propensos a ser excluidos de la inflación SUBY, por ser más volátiles. No obstante, los resultados son muy similares en ambos casos. Dado que nuestra clasificación se basa sobre el comportamiento tendencial de los índices de precios, estas similitudes proveen evidencia a favor de la conclusión de Armas y otros (2011) que la inflación SUBY es una buena medida tendencial de la inflación en el Perú.

Donde se perciben diferencias más notorias es en el caso de la inflación SAE, panel (d) del Cuadro 3. Llama la atención el mayor peso asignado a los rubros de los *clusters* extremos y, consecuentemente, la mayor contribución de estos *clusters*. La contribución de 0.92 del *cluster* de alta inflación (significativamente mayor que las contribuciones de 0.75 y 0.68 en los casos anteriores) es compensada por una contribución negativa de 0.35 por ciento proveniente del *cluster* de baja inflación (significativamente mayor que las contribuciones negativas de 0.20 y 0.68 en los casos anteriores).

El Gráfico 4 (p. 17) presenta estos resultados de una manera más visual. Dada la fuerte contribución de los *clusters* en las inflaciones IPC y SUBY, junto con una moderada contribución del *cluster* de alta inflación, estas dos medidas de inflación presentan una dinámica común. En el caso de la inflación IPC se aprecia que la mayor contribución del *cluster* de alta inflación es compensada con una mayor contribución, pero negativa, del *cluster* de baja inflación. Esta última es casi inexistente en la inflación SUBY, ciertamente una medida más estable. Por el contrario, la inflación SAE promedia extremos y reporta una menor contribución de los *clusters* de inflación intermedia.

## 4 Discusión y agenda

Nuestro principal hallazgo, que es posible identificar hasta cuatro tendencias en los rubros que componen el IPC, tienen ciertas implicancias y abre varias preguntas sobre la dinámica de la inflación en el Perú.

Primero, a diferencia del planteamiento del modelo de un factor discutido a inicios de este documento, una representación más adecuada de las inflaciones individuales sería  $\pi_{it} = \mu_{kt} + v_{it}$ , donde toma los valores de  $k = \{1, 2, 3, 4\}$  de acuerdo con el *cluster* al que pertenece el rubro  $i$ . Por construcción, estas cuatro tendencias *no cointegran*. Así, tras agregar,

$$\pi_t = w_1\mu_{1t} + w_2\mu_{2t} + w_3\mu_{3t} + w_4\mu_{4t} + V_t,$$

donde  $w_k$  son los pesos mostrados en el Cuadro 3. Análogamente, en el caso de la inflación subyacente se

tendría

$$\tilde{\pi}_t = \tilde{w}_1\mu_{1t} + \tilde{w}_2\mu_{2t} + \tilde{w}_3\mu_{3t} + \tilde{w}_4\mu_{4t} + \tilde{V}_t,$$

por lo que

$$\pi_t - \tilde{\pi}_t = (w_1 - \tilde{w}_1)\mu_{1t} + (w_2 - \tilde{w}_2)\mu_{2t} + (w_3 - \tilde{w}_3)\mu_{3t} + (w_4 - \tilde{w}_4)\mu_{4t} + (V_t - \tilde{V}_t).$$

De acuerdo con los resultados del Cuadro 3, se tiene que  $w_k \simeq \tilde{w}_k$  para todo  $k$  para el caso de la inflación SUBY, por lo que podría esperarse que  $\pi_t - \tilde{\pi}_t \simeq V_t - \tilde{V}_t$ . Es decir, que la inflación SUBY cointegrarse con la inflación del IPC (se entiende, con un vector de cointegración  $[1 \ -1]$ ). Una manifestación de ello es, por ejemplo, el hecho de que ambas promedien el mismo valor en periodos largos de tiempo. Ello, asimismo, explica el mejor desempeño de la inflación SUBY documentado en [Armas y otros \(2011\)](#). Note que no ocurre lo mismo con la inflación SAE en donde se tiene que  $w_k \neq \tilde{w}_k$  para al menos un  $k$  (los casos más elocuentes son  $k = 1$  y  $k = 4$ ), por lo que se espera que la inflación SAE *no cointegre* con la inflación IPC. Ello explicaría, entre otras cosas, por qué ambas inflaciones no promedian el mismo valor a lo largo del tiempo.

Así, nuestras conclusiones no invalidan el uso de la inflación SUBY como medida tendencial de inflación. Aparentemente, los rubros excluidos de la inflación SUBY están homogéneamente distribuidos a lo largo de los cuatro *clusters*, lo que ha permitido que el resultado  $w_k \simeq \tilde{w}_k$  emerja. No obstante, la idea de que existe una única tendencia en la inflación y que la inflación SUBY es una buena medida de esta tendencia, sí debe ser cuestionada.

Por otra parte, como se mencionó, posiblemente una de las inferencias más esquivas cuando se cuentan con muchas series de tiempo es cuántas relaciones de cointegración (o cuántas tendencias estocásticas) caracterizan al panel. El saber *a priori* que son cuatro las tendencias comunes en los rubros del IPC podría ser útil, por ejemplo, para fines predictivos. En particular, el conocer que los miembros de un *cluster* cointegran entre sí pero que, por construcción, no cointegran con los miembros de otro *cluster* podría ayudar a reducir considerable los problemas de dimensionalidad que enfrentan los sistemas de predicción desagregados como los propuestos en [Barrera \(2005, 2007, 2013\)](#) o [Carrera y Ledesma \(2015\)](#). Consideramos interesante investigar hasta qué punto se pueden obtener ganancias en capacidad predictiva utilizando la clasificación de rubros acá propuesta.

Finalmente, nuestro estudio se ha limitado a la identificación de las tendencias comunes y a la formación de los *clusters*. No obstante, es necesario profundizar el análisis para que nuestros resultados provean información útil para el quehacer de la política monetaria. Los *clusters* son formados de acuerdo con cómo han evolucionado los precios en el largo plazo, pero no de acuerdo con cuáles han sido las fuerzas económicas detrás de esta evolución. Por ejemplo, el *cluster* de alta inflación contiene rubros como enseñanza y matrícula, pasaje en avión, medicinas y anticonceptivos o artículos de joyería cuya dinámica podría ser explicada en buena parte por la consolidación de una mayor clase media en la economía peruana durante el periodo de análisis (véase [Asencios, 2014](#)). Es decir, la inflación de estos rubros estaría determinada por choques de demanda. No obstante, el mismo *cluster* contiene productos como frijol, pescado fresco y congelado o trigo, cuya evolución podría deberse a consideraciones de oferta. Es parte de nuestra agenda de investigación proponer una clasificación que responda a estas inquietudes.

## Referencias

- Apergis, N., C. Christou y S. Miller (2012), “Convergence patterns in financial development: Evidence from club convergence”, *Empirical Economics*, 43(3), 1011-1040.
- Armas, A. y F. Grippa (2006), “Targeting inflation in a dollarized economy: The Peruvian experience”, en Armas, A., A. Ize y E. Levy-Yeyati (eds.), *Financial Dollarization: The Policy Agenda*, Palgrave Macmillan, cap. 6.
- Armas, A., L. Vallejos y M. Vega (2011), “Indicadores tendenciales de inflación y su relevancia como variables indicativas de política monetaria”, Banco Central de Reserva del Perú, *Revista Estudios Económicos*, 20, 27-56.
- Asencios, R. (2014), “Crecimiento de la clase media en el Perú”, *Revista Moneda*, Banco Central de Reserva del Perú, 159, 27-30.
- Bartkowska, M. y A. Riedl (2012), “Regional convergence clubs in Europe: Identification and conditioning factors”, *Economic Modelling*, 29(1), 22-31.
- Barrera, C. (2005), “Proyecciones desagregadas de la variación del índice de precios al consumidor (IPC), del índice de precios al productor (IPM) y del crecimiento del producto real (PBI)”, Banco Central de Reserva del Perú, Documento de Trabajo 2005-006.
- Barrera, C. (2007), “Proyecciones desagregadas de inflación con modelos Sparse VAR robustos”, Banco Central de Reserva del Perú, Documento de Trabajo 2007-015.
- Barrera, C. (2013), “El sistema de predicción desagregada: Una evaluación de las proyecciones de inflación 2006-2011”, Banco Central de Reserva del Perú, Documento de Trabajo 2013-009.
- Carrera, C. y A. Ledesman (2015), “Aggregate inflation forecast with Bayesian vector autoregressive models”, Banco Central de Reserva del Perú, Documento de Trabajo 2015-003.
- Camarero, M., A. J. Picazo-Tadeo y C. Tamarit (2013), “Are the determinants of CO2 emissions converging among OECD countries?”, *Economics Letters*, 118(1), 159-162.
- Delgado, A. y G. Rodríguez (2013), “Growth of the Peruvian economy and convergence in the regions of Peru: 1970-2010”, Departamento de Economía - Pontificia Universidad Católica del Perú, Documento de trabajo 2013-365.
- Fischer, C. (2012), “Price convergence in the EMU? Evidence from micro data”, *European Economic Review*, 56(4), 757-776.
- Fritsche, U. y V. Kuzin (2010), “Analysing convergence in Europe using the non-linear single factor model”, *Empirical Economics*, 41(2), 343-369.
- Gómez, V. (2001), “The use of Butterworth filters for trend and cycle estimation in economic time series”, *Journal of Business and Economic Statistics*, 19(3), 365-373.
- Hodrick, R. y E. C. Prescott (1997), “Postwar U.S. business cycles: An empirical investigation”, *Journal of Money, Credit, and Banking*, 29(1), 1-16.
- Humala A. y G. Rodríguez (2012), “A factorial decomposition of inflation in Peru: An alternative measure of core inflation”, *Applied Economics Letters*, 19(14), 1331-1334.
- Kim, Y. S. y J. J. Rous (2012), “House price convergence: Evidence from US state and metropolitan area panels”, *Journal of Housing Economics*, 21(2), 169-186.
- Montañés, A y L. Olmos (2013), “Convergence in US house prices”, *Economics Letters*, 121(2), 152-155.

- Morrison, M. y M. Fontenla (2013), "Price convergence in an online virtual world", *Empirical Economics*, 44(3), 1053-1064.
- Phillips, P. C. B. y D. Sul (2007a), "Transition modeling and econometric convergence tests", *Econometrica*, 75(6), 1771-1855.
- Phillips, P. C. B. y D. Sul (2007b), "Some empirics on economic growth under heterogeneous technology", *Journal of Macroeconomics*, 29(3), 455-469.
- Phillips, P. C. B. y D. Sul (2009), "Economic transition and growth", *Journal of Applied Econometrics*, 24(7), 1153-1185.
- Wang, Y., P. Zhang, D. Huang y C. Cai (2014), "Convergence behavior of carbon dioxide emissions in China", *Economic Modelling*, 43(C), 75-80.
- Winkelried, D. (2010), "Sobre los determinantes de la inflación", Banco Central de Reserva del Perú, *Revista Moneda*, 145, 12-16.
- Winkelried, D. (2013), "Modelo de proyección trimestral del BCRP: Actualización y novedades", Banco Central de Reserva del Perú, *Revista Estudios Económicos*, 26, 9-60.

**Cuadro 1. Clasificación de los rubros del IPC de Lima Metropolitana**

	Total		SUBY		SAE	
	<i>n</i>	%	<i>n</i>	%	<i>n</i>	%
Alimentos y bebidas	74	37.8	39	23.0	0	0.0
Vestido y calzado	10	5.4	10	5.4	10	5.4
Alquiler de vivienda, combustible y electricidad	7	9.3	3	3.2	4	4.8
Muebles, enseres y mantenimiento de la vivienda	23	5.8	23	5.8	23	5.8
Cuidado, conservación de la salud y servicios médicos	7	3.7	7	3.7	7	3.7
Transportes y comunicaciones	10	16.5	5	2.5	9	15.2
Esparcimiento, diversiones, servicio cultural y enseñanza	11	14.9	11	14.9	11	14.9
Otros bienes y servicios	8	6.7	8	6.7	8	6.7
<b>Total</b>	<b>150</b>	<b>100.0</b>	<b>106</b>	<b>65.1</b>	<b>72</b>	<b>56.4</b>

**Notas:** Clasificaciones del INEI y del BCRP. “*n*” representa el número de rubros y “%” representa la participación en la canasta del IPC, utilizando los pesos del año base 2010. SUBY se refiere a la canasta de la inflación subyacente del BCRP, mientras que SAE se refiere a la canasta sin alimentos ni energía.

**Cuadro 2. Prueba de convergencia para distintos puntos de inicio de la muestra**

Inicio	Ene 1998	Ene 1999	Jul 1999	Ene 2000	Jul 2000	Ene 2001	Jul 2001	Ene 2003
<i>r</i>	0.16	0.21	0.24	0.27	0.29	0.32	0.34	0.42
<i>T</i>	192	180	174	168	162	156	150	132
$\hat{\phi}$	-1.14	-1.06	-1.01	-0.96	-0.91	-0.88	-0.86	-0.87
$\tau_{\phi}$	-23.53	-19.30	-20.14	-22.97	-28.11	-34.86	-37.81	-28.77

**Notas:** *r* denota la fracción de la muestra total que es descartada, considerando las fechas de inicio mostradas; *T* es el número de observaciones en la regresión (6);  $\hat{\phi}$  es el estimador MCO de  $\phi$ ; y  $\tau_{\phi}$ , el estadístico de significación de  $\phi$ , calculado con error estándar HAC.




**Cuadro 3. Inflaciones por grupos**

	Total	Cluster 1	Cluster 2	Cluster 3	Cluster 4
<b>(a) Sin ponderar</b>					
Inflación promedio	2.50	4.85	2.93	1.48	-1.72
$\Delta$ = Inflación de <i>cluster</i> – inflación sin ponderar		2.34	0.42	-1.02	-4.22
Estadístico $t_{\Delta}$		6.24	3.78	6.72	11.00
Contribución a la inflación sin ponderar	2.50	0.78	1.33	0.49	-0.09
Pesos	150	24	68	50	8
<b>(b) IPC total</b>					
Inflación promedio	2.22	3.83	2.92	1.32	-3.35
$\Delta$ = Inflación de <i>cluster</i> – inflación IPC		1.61	0.70	-0.89	-5.56
Estadístico $t_{\Delta}$		6.95	6.23	5.91	12.86
Contribución a la inflación IPC	2.22	0.75	1.24	0.42	-0.20
Pesos	100	20	43	32	6
<b>(c) IPC SUBY</b>					
Inflación promedio	2.22	3.39	3.05	1.11	-2.63
$\Delta$ = Inflación de <i>cluster</i> – inflación SUBY		1.17	0.84	-1.11	-4.84
Estadístico $t_{\Delta}$		8.21	7.57	12.66	10.26
Contribución a la inflación SUBY	2.22	0.68	1.20	0.41	-0.08
Pesos	100	20	39	37	3
<b>(d) IPC SAE</b>					
Inflación promedio	1.60	3.55	2.44	0.87	-3.48
$\Delta$ = Inflación de <i>cluster</i> – inflación SAE		1.95	0.84	-0.73	-5.08
Estadístico $t_{\Delta}$		16.60	4.78	5.11	12.55
Contribución a la inflación SAE	1.60	0.92	0.74	0.29	-0.35
Pesos	100	26	30	33	10


**Notas:** Los promedios son calculados de enero de 2002 a diciembre de 2013 (144 observaciones). Se utilizan errores estándares HAC para el cálculo de los estadísticos  $t_{\Delta}$  (hipótesis nula: la inflación del *cluster* es igual a la inflación agregada).

**Gráfico 1.** *Deciles de índices de precios e inflaciones*




**Notas:** Los índices fueron suavizados utilizando el filtro de Hodrick y Prescott con un parámetro de suavizamiento de  $\lambda = 8331$ . Las inflaciones son las variaciones porcentuales a 12 meses de estos índices. Las líneas continuas muestran las medianas de las secciones transversales de los 150 rubros que componen el IPC; las líneas discontinuas, el resto de deciles.

**Gráfico 2.** *Convergencia y condiciones iniciales*



**Notas:** Se muestran las diferencias de percentiles  $P_q$  de la sección transversal de índices de precios. En orden decreciente:  $P_{90} - P_{10}$ ,  $P_{85} - P_{15}$ ,  $P_{80} - P_{20}$ ,  $P_{75} - P_{25}$  y  $P_{70} - P_{30}$ . Asimismo, se muestran las tendencias lineales quebradas que mejor explican estas diferencias, con la fecha de quiebre marcadas con un círculo vacío.


**Gráfico 3. Tendencias comunes**




**Notas:** Las líneas delgadas (ruidosas) en el panel (a) son los promedios simples de los índices de precios en cada *cluster* y las líneas gruesas (suaves), sus respectivas tendencias Hodrick y Prescott. Las inflaciones del panel (b) son las variaciones porcentuales de los últimos 12 meses de estas tendencias. La línea vertical marca el inicio de la muestra utilizada en el análisis.

**Gráfico 4. Contribuciones de las inflaciones por cluster**

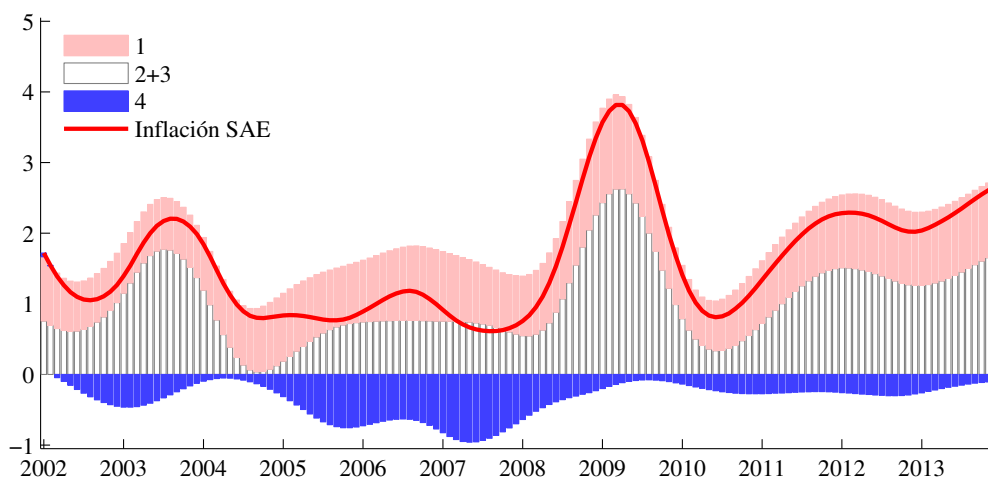
(a) Inflación total



(b) Inflación subyacente (SUBY)



(c) Inflación sin alimentos ni energía (SAE)



**Notas:** Variaciones porcentuales de los últimos 12 meses de los índices de cada *cluster* ponderados por los pesos de las distintas canastas. Para facilitar la visualización, los índices fueron suavizados con el filtro de Hodrick y Prescott con un parámetro  $\lambda = 69$ , que hace que el filtro capture movimientos de un año y medio o más en series mensuales.