



# ENSAYOS

sobre política económica

---

## *La inflación en Colombia: una aproximación desde las redes neuronales*

Martha Misas Arango  
Enrique López Enciso  
Pablo Querubín Borrero


Revista ESPE, No. 41-42, Art. 03, Junio-  
Diciembre de 2002  
Páginas 143-214



Los derechos de reproducción de este documento son propiedad de la revista *Ensayos Sobre Política Económica* (ESPE). El documento puede ser reproducido libremente para uso académico, siempre y cuando nadie obtenga lucro por este concepto y además cada copia incluya la referencia bibliográfica de ESPE. El(los) autor(es) del documento puede(n) además colocar en su propio website una versión electrónica del documento, siempre y cuando ésta incluya la referencia bibliográfica de ESPE. La reproducción del documento para cualquier otro fin, o su colocación en cualquier otro website, requerirá autorización previa del Editor de ESPE.

# *La inflación en Colombia: una aproximación desde las redes neuronales\**

*Martha Misas Arango  
Enrique López Enciso  
Pablo Querubín Borrero*



*Este documento presenta un modelo de estimación de la inflación en Colombia con base en la utilización de un modelo de red neuronal artificial (ANN). La prueba de no-linealidad de la relación entre el dinero y la inflación, al igual que diferentes argumentos teóricos mencionados en el trabajo, muestra la importancia de modelar la inflación con técnicas no lineales como las redes neuronales. La principal ventaja de esta técnica es que explota la riqueza de la estructura no lineal y la habilidad para aprender en una forma adaptativa del proceso generador de datos subyacente. La utilización de la técnica permite la obtención de pronósticos más precisos de la inflación, con lo cual se demuestra el potencial que tienen estos modelos en el pronóstico de la inflación, al competir y en algunos casos superar a los modelos lineales tradicionales. Con estos resultados se amplía y mejora la familia de modelos de que hoy se dispone para pronóstico de la inflación y, en particular, se fortalece el trabajo de los modelos que contienen como insumo variables monetarias.*

---

\* Se agradece de manera especial los comentarios y sugerencias de Miguel Urrutia M. y de un evaluador anónimo, como también, la colaboración de Norberto Rodríguez N. y Rocío Betancourt G. en la descripción y evaluación de los modelos lineales. Los resultados y opiniones son de exclusiva responsabilidad de los autores y no comprometen al Banco de la República ni a su Junta Directiva. Los dos primeros autores son investigadores de la Unidad de Investigación de la Subgerencia de Estudios Económicos y el tercero es asistente de investigación de la misma Subgerencia.

**Clasificación JEL:** C2, E3.

**Palabras clave:** *Redes neuronales artificiales, inflación, pronóstico, no linealidad.*

## I. INTRODUCCIÓN

Las redes neuronales (*ANN*)<sup>1</sup> son modelos matemáticos diseñados para simular el funcionamiento del cerebro y, en particular, la forma como éste procesa información. En el contexto de análisis de series de tiempo, se clasifican como modelos no lineales entrenados para i) realizar conexiones entre los valores pasados y presentes de una serie de tiempo, y ii) extraer estructuras y relaciones escondidas que gobiernan el sistema de información. El atractivo de este enfoque, inspirado en la neurología, es su habilidad para aprender, es decir, para identificar dependencias con base en una muestra finita, de manera que el conocimiento adquirido pueda generalizarse a muestras no observadas (Herbrich *et al.*, 1999). Si bien, como señalan Kuan y White (1994), las redes neuronales y sus algoritmos de aprendizaje asociados están todavía lejos de ofrecer una descripción acertada de cómo funciona el cerebro, éstas se han constituido en un marco de modelación muy poderoso e interesante cuyo potencial ha sido comprobado en diversas aplicaciones en todas las ciencias<sup>2</sup>. Para Moshiri y Cameron (1998), los investigadores son atraídos hacia ese enfoque porque las redes neuronales no están sujetas a supuestos restrictivos como la linealidad, que suele ser necesaria para la aplicación de los modelos matemáticos tradicionales.

La reputación de las redes neuronales para manejar datos e información compleja puede haber contribuido considerablemente a la difusión e implementación de modelos de redes neuronales en la economía y la econometría. Herbrich *et al.* (1999) señalan tres campos principales en los cuales se ha concentrado la aplicación de redes neuronales en economía: i) clasificación de agentes económicos, ii) pronóstico de series de tiempo y iii) modelaje de agentes con racionalidad limitada. El segundo campo ha sido de especial importancia. Franses y van Dijk (2000) seña-

---

<sup>1</sup> Conocidas en la literatura como redes neuronales artificiales o *ANN* (*Artificial Neural Network*).

<sup>2</sup> Durante los años sesenta las redes neuronales fueron desarrolladas como una herramienta para la clasificación y reconocimiento de patrones. Otras aplicaciones mencionadas por Kuan y White (1994) son: conversión de texto escrito a voz, reconocimiento de caracteres escritos a mano, realización de complejas tareas de coordinación, juegos de *backgammon*, diagnóstico de dolor de pecho y decodificación de caos determinístico.

lan que anualmente se publican alrededor de 20 ó 30 artículos relacionados con el pronóstico y modelación, a través de redes neuronales, de los precios de las acciones, la tasa de cambio, las tasas de interés, el producto y la inflación, entre otros<sup>3</sup>. Franses y van Dijk (2000), como Tkacz y Hu (1999), atribuyen la creciente popularidad de estos modelos *ANN* y su aplicación a series de tiempo, a la capacidad que poseen para permitir relaciones no lineales muy generales entre las variables. En efecto, al ser especificados de manera apropiada, pueden aproximar cualquier función no lineal. Adicionalmente, las redes neuronales son una herramienta importante en la modelación de variables en las cuales la existencia de un modelo estructural no es clara, pues no parten de supuestos *a priori* sobre los datos para el pronóstico, y todo lo que de ellas puede decirse es inherente a las observaciones (Evans, 1997).

El objetivo de este trabajo es modelar la relación entre dinero e inflación utilizando un modelo de redes neuronales. Los agregados monetarios se han utilizado tradicionalmente como determinantes o variables explicativas de la inflación. Sin embargo, la existencia de asimetrías entre la política monetaria y la inflación al igual que la evidencia de fijación asimétrica de precios en los agentes económicos, pueden justificar la existencia de no-linealidades entre dinero e inflación. Por lo tanto, la aplicación de esta técnica, capaz de capturar estas no linealidades, puede generar pronósticos más precisos de la inflación constituyéndose en una herramienta de pronóstico y de modelación muy valiosa.

Este trabajo está ordenado de la siguiente forma: en la segunda sección se discuten algunos elementos teóricos sobre la relación entre dinero e inflación y las posibles fuentes de no-linealidades entre estas dos variables. La tercera sección presenta la metodología e introduce al lector a las redes neuronales. La cuarta sección discute posibles interpretaciones económicas de la superficie oculta (*hidden layer*), un elemento central de las redes neuronales artificiales. La quinta sección reporta los resultados del trabajo y finalmente, en la última sección, se mencionan algunas conclusiones.

---

<sup>3</sup> Se destacan los artículos de Gradojevic y Yang (2000), Medeiros, Veiga y Pedreira (2001) y Evans (1997) que modelan y pronostican tasa de cambio, los artículos de Moshiri y Cameron (1998), Tkacz (2000) y Gazely y Binner (2000) para inflación, el trabajo de Moody, Levin y Rehfuss (1993) para el índice de producción industrial, Aiken (1996) y Draisma et al. (1995) para la tasa de desempleo, Tkacz y Hu (1999) para el producto interno bruto, y el trabajo de Swanson y White (1997) para el pronóstico de nueve series macroeconómicas como desempleo, producto, exportaciones, entre otras.

## II. DINERO E INFLACIÓN

### *A. IMPORTANCIA DEL ANÁLISIS DE LOS AGREGADOS MONETARIOS*

Hoy en día la mayor parte de los economistas está de acuerdo en que en el largo plazo la inflación es un fenómeno monetario. De hecho, esa aseveración constituye uno de los pilares básicos de la teoría económica moderna. De otro lado, la relación de largo plazo entre el dinero y los precios ha sido confirmada por un número de estudios empíricos, ya sea por ejercicios de corte transversal entre países o en series de tiempo para el caso de economías particulares.

La relación fundamental entre dinero y precios y el monopolio que sobre la creación de la base monetaria tienen los bancos centrales lleva a que estos últimos tengan un interés natural en la evolución de los agregados monetarios. En los años ochenta muchos bancos centrales buscaron cumplir con objetivos monetarios como forma de hacer política monetaria. Esa elección coincidió con que en ese período las innovaciones financieras y el cambio estructural que se dieron en la economía mundial modificaron las estructuras financieras. La consecuencia final fue la inestabilidad de la demanda de dinero, con lo cual, se hacía difícil interpretar la evolución de los agregados monetarios, y el abandono de las metas monetarias.

Hoy se arguye, como fruto de esa experiencia, que los bancos centrales no deben utilizar los agregados monetarios como indicadores del impacto de sus políticas en la economía<sup>4</sup>. Esa percepción también responde a que en el análisis moderno de la política monetaria, o por lo menos en una de sus vertientes más importantes, los agregados monetarios no tienen un papel explícito, como se puede constatar en los modelos teóricos y en los empíricos<sup>5</sup>. En esos modelos la característica típica es que el banco central utiliza la tasa de interés como su instrumento de política. Se supone que la política monetaria afecta directamente variables importantes como la inflación y el producto, sin que la cantidad de dinero tenga algún papel intermedio en su determinación. Si bien el acervo de dinero que debe ofrecerse para llegar a un nivel dado de tasa de interés puede determinarse por medio de una función de

---

<sup>4</sup> De hecho, numerosos bancos centrales abandonaron las metas monetarias, mientras que en otros la importancia dada a los indicadores monetarios disminuyó. En muchos bancos centrales europeos, sin embargo, los agregados monetarios y de crédito continuaron jugando un papel esencial en las décadas de los años ochenta y de los noventa (Banco Central Europeo, 2001).

<sup>5</sup> Véanse, por ejemplo, los modelos teóricos de Svensson (1997) y Svensson y Woodford (1999). Dentro de los modelos empíricos, un ejemplo patente es el modelo FRB/US.

demanda de dinero, esto no es realmente necesario para caracterizar la economía. El dinero, en consecuencia, es en esencia superfluo en el modelo.

Sin embargo, la mayoría de los bancos centrales, sea cual sea la estrategia de política monetaria que formalmente lleve a cabo, continúa monitoreando los agregados monetarios. Existen al menos dos argumentos para sustentar ese comportamiento. En primer lugar, el dinero se encuentra estrechamente relacionado con el crédito, y debe ser una parte muy importante del canal de crédito de la transmisión de la política monetaria. En segundo lugar, se reconoce que las variables monetarias contienen información muy valiosa.

En lo concerniente al primer punto, Altissimo *et al.* (2001) hacen un ejercicio en el que investigan si los residuales de las ecuaciones de demanda de dinero y de crédito del modelo central de la *Banca d'Italia* están correlacionados con los errores de pronóstico de las variables económicas esenciales. Sus resultados sugieren que la evolución de los agregados monetarios y del crédito revela información importante para entender los mecanismos de transmisión de la política monetaria asociados al comportamiento de los *spreads* de tasa de interés o al racionamiento cuantitativo de crédito.

El reconocimiento que se hace acerca del contenido de información de las variables monetarias es de una amplia gama. De una parte, se encuentran las explicaciones estructurales de la inflación donde el dinero tiene un papel activo y dominante. De otro lado, se da un tratamiento al dinero en el cual, como máximo, se le reconocen sus virtudes como indicador sintético, sin ninguna explicación causal en la evolución de la variable precios.

Con relación a ese último punto, Friedman (1984) reconoce que los agregados monetarios pueden ser excelentes indicadores del proceso inflacionario futuro o de los mecanismos de transmisión de la política monetaria, a pesar de que no jueguen un papel causal ni estructural. Desde ese punto de vista, aun si la inflación se entiende como el resultado de un exceso de demanda o de la presión de costos, la evolución de los agregados monetarios provee información para las decisiones de política monetaria, dado que permite a las autoridades identificar mejor la naturaleza de los choques que afectan la economía y/o predecir las tendencias en la evolución futura de los precios.

Una explicación de las propiedades de indicador líder que tiene el dinero para predecir la inflación futura, se encuentra en que los agregados monetarios pueden

estar relacionados con variables macroeconómicas importantes en la transmisión de la política monetaria. Por ejemplo, los estudios de demanda de dinero sugieren que el crecimiento del dinero está relacionado positivamente con el crecimiento del producto y negativamente con la tasa de interés. En ese contexto, el crecimiento del producto más allá de un cierto límite provocará un incremento en el crecimiento monetario y el surgimiento de presiones inflacionarias. Desde ese punto de vista, el crecimiento del dinero resume la información acerca de los determinantes de la demanda de dinero, con influencia, también, en la evolución futura de los precios.

### B. ANÁLISIS MONETARIO Y NO LINEALIDAD

Es muy amplia la variedad de instrumentos analíticos y técnicas disponibles para hacer análisis monetario y extraer información de los agregados monetarios. Al respecto, un punto de partida natural es la estimación de la demanda de dinero<sup>6</sup>. Los estudios recientes que presentan este tipo de estimaciones utilizan en su mayoría especificaciones de corrección de errores y técnicas de modelado basadas en la cointegración (Pill, 2001). En los bancos centrales de Canadá y Reino Unido se utilizan una gran variedad de técnicas econométricas que, sorprendentemente, son muy similares en los dos casos: modelos *VAR* y *VEC* (Hauser, 2001; Masuch, 2001).

Una variante de los modelos *VEC* son los modelos *P\** de la inflación (Hallman *et al.*, 1989, 1991)<sup>7</sup>. Este tipo de modelos utiliza la desviación de la cantidad de dinero corriente de un nivel consistente con un equilibrio de largo plazo como un indicador adelantado para la inflación. Dos desarrollos recientes de este tipo de modelos son los de Gerlach y Svensson (2000) y Orphanides y Porter (2001). Los primeros autores, en el contexto de la discusión sobre la política monetaria en Europa, encuentran que el modelo *P\** tiene un gran poder predictivo sobre la inflación futura, lo cual no se encuentra para el caso del crecimiento de *M3*<sup>8</sup>. Para los segundos, si se quiere obtener buenos pronósticos de la inflación en los modelos *P\**, se debe modelar como variable en el tiempo la velocidad de circulación del dinero y no asumirla como una constante según frecuentemente se hace. Resulta igualmente

---

<sup>6</sup> Laidler (1993) revisa los aportes al respecto.

<sup>7</sup> Existe una aplicación para Colombia realizada por Misa, López y Melo (1999). Véase Anexo 4.

<sup>8</sup> Nicoletti Altimari (2001) encuentra un resultado similar para una brecha monetaria extraída de un modelo *P\**, pero uno diferente para el caso de *M3*.

conveniente poder prever los cambios en la velocidad por medio de un análisis institucional detallado, para así poder tener un conocimiento adecuado de la situación económica.

Recientemente, los analistas han avanzado hacia modelos que consideran la existencia de una estructura no lineal en la relación del dinero con otras variables. Como anota Tkacz (2000), el supuesto de linealidad no puede justificarse si se piensa que los efectos de la política monetaria en la economía son asimétricos. Ya Friedman en 1968 señala que una política contraccionista tendrá un impacto relativamente mayor sobre el crecimiento del PIB que una política expansionista equivalente<sup>9</sup>.

Un impulso muy importante al tratamiento de las no linealidades proviene de los modelos recientes de demanda de dinero. Lütkepohl *et al.* (1999) encuentran que a partir de la unificación de Alemania su estimación de la demanda de dinero presenta inestabilidad. Por tal razón, los autores sugieren una especificación no lineal de la demanda de dinero (*LSTR*)<sup>10</sup>. Según esos autores, la fuente de la no linealidad se encuentra en la variable de tasa de inflación. Esta última, además de recoger una porción sustancial de la estacionalidad del modelo, es la variable que permite controlar que el ajuste del modelo de demanda se dé en términos reales o nominales, como predice la teoría económica.

Soto (1997), quien construye un modelo de redes neuronales, ha profundizado en las posibles fuentes de no linealidad en la demanda de dinero. Para este autor existen tres elementos que pueden llevar a una estructura no lineal en la relación entre el dinero, el ingreso y la tasa de interés: la especificación microeconómica de la función, la agregación y la intermediación financiera.

Con base en un modelo genérico de costo de transacción, Soto demuestra la existencia de fuentes potenciales de no linealidad que surgen del comportamiento microeconómico de los agentes. Con el fin de obtener un tipo de especificación de la demanda de dinero que pueda estimarse con métodos econométricos, se suponen

---

<sup>9</sup> Esta asimetría en el impacto de la política monetaria sobre el PIB podría extenderse a una asimetría de la política monetaria sobre la inflación si se considera una curva de Phillips de corto plazo.

<sup>10</sup> *Logistic Smooth Transition Regression Model*. Véase sección III.



funciones explícitas de utilidad y de costos de transacción. Estas funciones muy restrictivas suponen, por ejemplo, que la tasa de descuento es constante e independiente de la riqueza de los hogares o que la función de utilidad es separable y es una función *CES*. Este tipo de funciones no cumple con los requerimientos matemáticos de la teoría o al basarse en el agente representativo no permite capturar el comportamiento del consumo agregado. Este tipo de enfoque se aleja de los modelos cerrados simples y genera estructuras no lineales caracterizadas, como ejemplo, por *thresholds* o comportamiento dependiente del tiempo por parte de los agentes.

Las no linealidades que surgen de la agregación de funciones individuales se producen porque se asume la existencia de  $n$  individuos idénticos. Se puede dar el caso, sin embargo, que el comportamiento combinado de los agentes afectados por *shocks* idiosincráticos o colectivos lleve a desviaciones radicales del comportamiento individual. En ese caso se tendría una respuesta no lineal a los *shocks*.

También es posible obtener no linealidades en la respuesta de la demanda de dinero a cambios en los fundamentales, como consecuencia del comportamiento de los intermediarios financieros. Como ha mostrado la literatura del canal del crédito, los intermediarios surgen como consecuencia de las asimetrías de información típicas de los mercados financieros. Si se consideran las innovaciones financieras, su presencia puede llevar a una respuesta no lineal de los agregados monetarios a cambios en los fundamentales.

Rhee y Rich (1995) retoman la discusión de precios rígidos de la literatura neokeynesiana para mostrar que en estos modelos los *shocks* monetarios tienen un efecto asimétrico sobre la inflación. Dicha inflación responde en mayor grado a los *shocks* monetarios positivos que a los *shocks* negativos. La asimetría estaría positivamente relacionada con los movimientos en la inflación promedio. El ejercicio empírico realizado para Corea provee evidencia acerca de la existencia de esa asimetría y de que esta es más marcada si hay movimientos positivos en la inflación promedio.

Para Gazely y Binner (2000), en el caso de la relación entre dinero e inflación, cualquier relación funcional particular especificada es arbitraria y cualquier conclusión derivada está sujeta a una especificación arbitraria del modelo, motivo por el cual la flexibilidad de las redes neuronales y su capacidad para aproximar cualquier función no lineal representan elementos esenciales para el pronóstico y modelación

de estas variables. De otro lado, estas autoras sugieren que buena parte del fracaso en los *targets* monetarios se debe a un problema de mala medición de los agregados. Su propuesta es construir índices monetarios tipo Divisia y utilizarlos como variable insumo dentro de una red neuronal construida para pronosticar la inflación<sup>11</sup>.

### III. METODOLOGÍA

En esta sección se explican, de manera general, algunos tópicos relacionados con la arquitectura de la red neuronal biológica vs. la red neuronal artificial, como también, los procesos de estimación, selección y validación de una red neuronal artificial.

Como lo señalan Granger y Teräsvirta (1993), la construcción de un modelo que relacione una variable  $y_t$  con su propia historia y/o con la historia de otras variables,  $X_t$ , puede llevarse a cabo a través de una variedad de alternativas. Estas dependen de la forma funcional mediante la cual se aproxima la relación, como también, de la relación existente entre dichas variables, es decir, de si ésta es de carácter lineal o no lineal. Las diferentes alternativas pueden clasificarse de la siguiente forma:

- No paramétricos:  $y_t = f(X_t) + e_t$  donde  $f$  no está restringida a pertenecer a una clase específica de funciones.
- Paramétricos: supone una forma funcional específica para  $f(\ )$  usualmente con parámetros que deben estimarse. Por ejemplo:
  - Lineales:  $y_t = \beta'X_t + e_t$
  - No lineales:
    - Transición suave<sup>12</sup>:  $y_t = \beta'_1X_t + F(X_t)\beta'_2X_t + e_t$  donde la función  $F(\ )$  captura la transición del modelo

<sup>11</sup> De acuerdo con este enfoque, el problema radica en que los agregados monetarios se construyen por medio de una suma simple. Lo ideal sería efectuar una suma ponderada, donde el factor de ponderación provenga del rendimiento del activo respectivo.

<sup>12</sup> Dos trabajos para Colombia que utilizan este tipo de modelo son los de Arango y González (1998) y Jalil y Melo (2000).

- Redes neuronales:  $y_t = \Phi_0 + X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' y_j) + e_t$
- Semiparamétricos:  $y_t = \beta' \bar{X}_t + f(Z_t) + e_t$ , donde las variables entran en el modelo de forma paramétrica y no paramétrica.

#### A. ¿QUÉ ES UNA RED NEURONAL ARTIFICIAL?, ¿CUÁL ES SU RELACIÓN CON LA RED NEURONAL BIOLÓGICA?

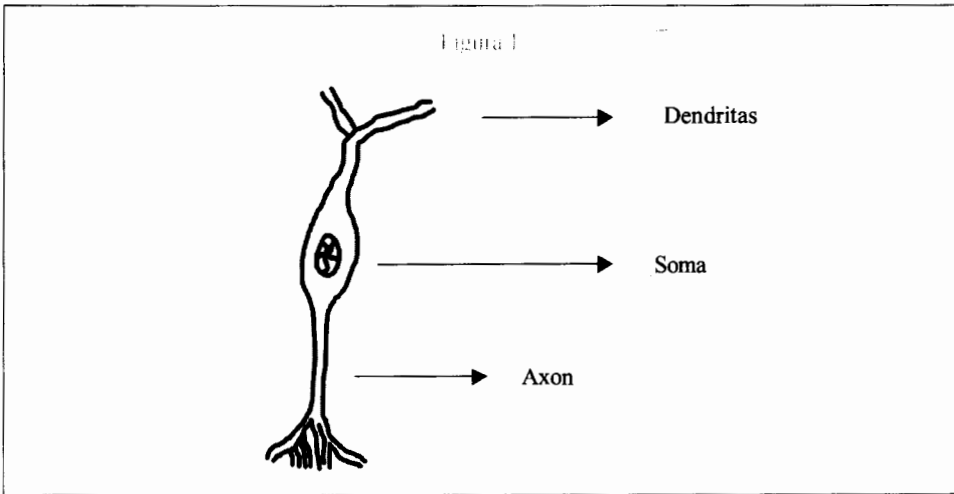
La pregunta que surge inicialmente al abordar el tema de redes neuronales artificiales es ¿qué es una red neuronal artificial? Una respuesta a esta pregunta está dada por Kuan y White (1994) y Swanson y White (1995, 1997 a, b), quienes señalan que las redes neuronales artificiales, propuestas por científicos cognitivos, son una clase de modelos no lineales flexibles, capaces de aprender a través de ensayo y error, los cuales están inspirados en ciertas características asociadas a la forma como el cerebro humano procesa información.

De acuerdo con Klerfors (1998) y Plummer (2000), la relación entre una red neuronal artificial y el esquema de procesamiento del cerebro humano puede entenderse a través de la siguiente explicación: el elemento básico del cerebro humano es un tipo específico de célula, llamada neurona, la cual nos provee, en nuestro quehacer continuo, de capacidad de pensar, recordar y conectar con experiencias previas. Cada una de estas neuronas puede conectarse con otras células similares. Así, la potencia del cerebro proviene del número de dichos elementos básicos y de las múltiples conexiones generadas entre ellos.

Las neuronas naturales o biológicas tienen tres componentes morfológicos básicos: dendritas, soma y axon, y un espacio de comunicación o sinapsis. Básicamente, una neurona recibe *inputs* de diversas fuentes, los cuales se combinan de formas distintas, generalmente a través de esquemas no lineales, para producir finalmente un *output*. La Figura 1 presenta una neurona biológica simplificada y la relación de sus componentes. Existen varios aspectos fundamentales para resaltar la forma como la red neuronal biológica procesa la información: i) paralelismo masivo<sup>13</sup>, ii) respuesta

---

<sup>13</sup> En los sistemas neuronales biológicos el número de unidades de procesamiento puede ser del orden de billones o más (masivo). Tal número nunca se encuentra en los modelos económicos. Como lo señalan Kuan y White (1994), el procesamiento en paralelo es lo común.



no lineal ante un *input*<sup>14</sup>, iii) procesamiento a través de múltiples superficies conformadas por unidades neuronales<sup>15</sup> y iv) retroalimentación dinámica entre unidades.

Las redes neuronales artificiales son modelos computacionales construidos siguiendo la estructura de la neurona biológica. Así, la unidad básica es la neurona artificial, la cual imita las cuatro funciones básicas de la neurona biológica. En la Figura 2 se presenta una neurona artificial.

Como se observa en la Figura 2, la neurona artificial recibe distintos *inputs* ( $z_n$ ). Estos, antes de llegar al área de procesamiento, se multiplican por una ponderación específica o conector ponderante, ( $\gamma$ ). En el caso más sencillo, en esta área dichos productos son agregados y filtrados para producir un *output*.

Tanto la red neuronal biológica como la red neuronal artificial presentan una estructura topológica similar. En tal estructura la conexión con el mundo real se lleva a cabo a través de neuronas que reciben de éste sus distintos *inputs*, otras que lo proveen con los *outputs* y las restantes que se encuentran “ocultas” de éste. En la

<sup>14</sup> Esta es la tendencia de ciertos tipos de neuronas que solo reaccionan ante cierto nivel de estímulo o actividad *input*, es decir, se vuelven activas cuando éste supera cierto límite particular. Este punto introduce el hecho fundamental de la respuesta no lineal al paradigma de las redes neuronales.

<sup>15</sup> Es común observar procesos que se realizan a través de múltiples superficies. Por ejemplo, en la corteza cerebral humana se encuentran seis superficies de procesamiento diferentes.

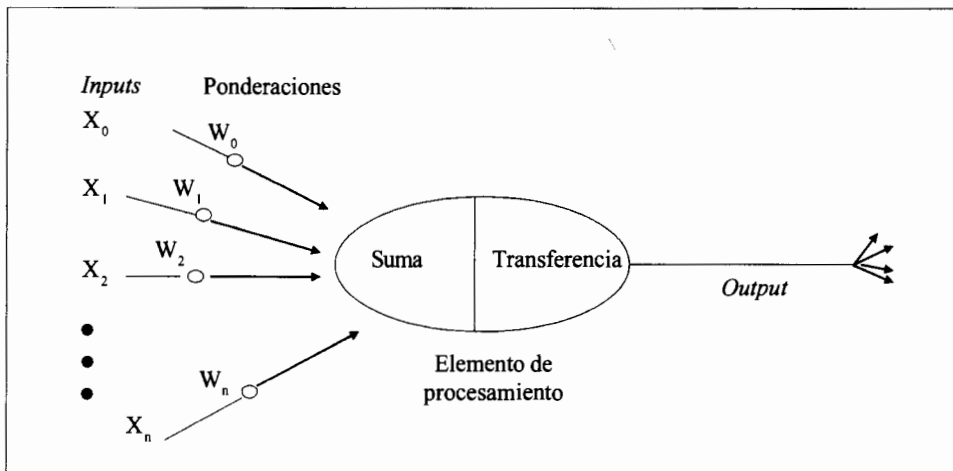



Figura 3 se observa cómo las neuronas se agrupan en diferentes superficies, dependiendo de su conexión con el mundo exterior<sup>16</sup>. Así, cuando la superficie-*input* recibe una señal o *input* sus neuronas producen un *output*, el cual se convierte en *input* de la siguiente superficie. El proceso continúa hasta que se alcanzan ciertas condiciones y la superficie-*output* produce el resultado final.



La comunicación entre neuronas se da a través de un conjunto de conectores. Así, una neurona recibe *inputs* de diferentes neuronas pero produce un único *output*, el cual se comunica con otras. La conexión entre superficies se realiza de diferentes

<sup>16</sup> Es de señalar que entre los nodos de entrada o superficie *input* y la superficie *output* pueden existir varias superficies ocultas.

formas, una de ellas, conocida como alimentación hacia adelante (*feed forward*), se tiene cuando las neuronas de la primera superficie envían sus *outputs* a las neuronas de la segunda superficie, sin recibir *inputs* de retorno<sup>17</sup>. Adicionalmente, si cada neurona de la primera superficie está conectada con cada neurona de la segunda superficie, se dice que la red está completamente conectada (*fully connected*).

El proceso de aprendizaje del cerebro humano se basa esencialmente en la experiencia. La red neuronal artificial se define como un algoritmo mecánico de aprendizaje, debido a que cambios en las ponderaciones de sus conectores la conducen a aprender la solución de un problema. El peso de las conexiones entre neuronas es almacenado como valor de ponderación de los conectores. Así, el sistema adquiere nuevos conocimientos ajustando el conjunto de ponderaciones asociados a dichos conectores.

La habilidad del aprendizaje de una red neuronal artificial está determinada por su arquitectura o construcción y por el algoritmo seleccionado para su entrenamiento o aprendizaje. El método de entrenamiento puede seguir diferentes esquemas. Uno de estos es el conocido como de propagación hacia atrás (*back propagation*), donde no sólo se tiene en cuenta la manera como la red efectúa su tarea, sino que, la información sobre los errores es filtrada y retornada al sistema para ajustar las conexiones entre las diferentes superficies y de esta forma incrementar el desempeño de la red. Es decir, para conformar un proceso de aprendizaje supervisado.

## B. APLICACIONES DE REDES NEURONALES EN EL ANÁLISIS DE SERIES DE TIEMPO

Las ANN pueden entenderse, en el contexto de análisis de series de tiempo, como modelos no lineales entrenados para i) realizar conexiones entre los valores pasados y presentes de una serie de tiempo y ii) extraer estructuras y relaciones ocultas que gobiernan el sistema de información, (Azoff, 1996). El aumento en la investigación sobre redes neuronales se debe, primordialmente, a la gran capacidad que estas muestran en el reconocimiento de patrones de comportamiento<sup>18</sup>.

<sup>17</sup> Generalizable a cualquier par de superficies continuas, donde, debido al orden de la red, una jugará el papel de la primera, y la siguiente, de la segunda.

<sup>18</sup> Por ejemplo, al considerar una serie de tiempo que presenta una relación dinámica no lineal, las ANN podrían detectar dicho comportamiento y ajustar la serie de un modo más adecuado que lo que la ajustaría un procedimiento lineal.

Estas han demostrado aproximar casi cualquier función no lineal de una manera acertada<sup>19</sup>, motivo por el cual, al aplicarse a series de tiempo, pueden detectar las dinámicas no lineales y lograr un mejor ajuste en comparación con modelos lineales (Franses y van Dijk, 2000). Adicionalmente, como lo presentan Tckaz y Hu (1999), las redes neuronales han demostrado tener la capacidad de reconocer y ‘modelar’ comportamientos atípicos, tales como ‘outliers’ o cambios de nivel en las series de tiempo, lo cual puede denotar precisamente, un alejamiento con respecto al mundo lineal.

La red neuronal aquí considerada presenta la forma funcional dada en las ecuaciones (1) y (2).

$$(1) \quad \hat{y}_t = F(X_t; \Theta)$$

donde

$$(2) \quad F(X_t; \Theta) = \Phi_0 + X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

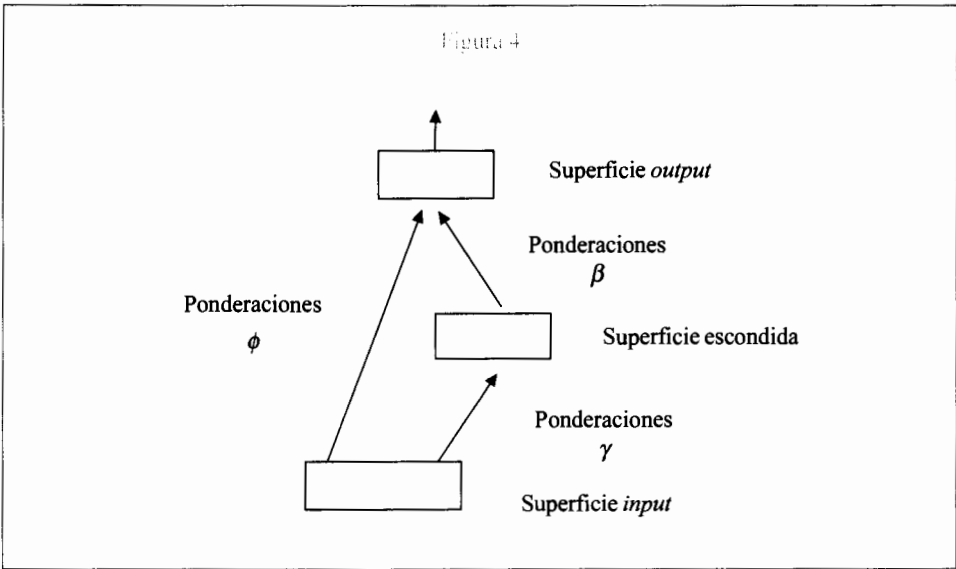
siendo  $Z_t \subseteq X_t$ ,  $X_t = \{y_{t-1}, \dots, y_{t-p}, w_{1t}, \dots, w_{mt}\}$  con  $y_{t-j}$ ,  $j=1, \dots, p$  rezagos de la variable dependiente,  $w_{jt}$ ,  $j=1, \dots, m$  variables exógenas y  $G$  la función logística, es decir:

$$(3) \quad G(w) = \frac{1}{1 + \exp(-w)}$$


La red neuronal presentada en (2) se nota como  $ANN(K, K', Q)$  o red neuronal ampliada<sup>20</sup>, de tal forma que,  $K = p + m$ , número de *inputs* en la parte lineal,  $K' \leq K$ , número de *inputs* en la parte no-lineal y  $Q$  número de componentes logísticas. Es de señalar que, el término  $X_t' \Phi$  puede verse como la representación de la parte lineal de la relación entre  $y_t$  y  $X_t$ , en tanto que, la componente logística caracteriza la parte no lineal. En la Figura 4 se presenta el esquema correspondiente a este modelo.

<sup>19</sup> Esto se conoce como la propiedad de aproximación universal de las redes neuronales, lo cual no es posible si no se introduce una superficie oculta o *hidden layer* (Tckaz y Hu, 1999).

<sup>20</sup> Esta por considerar tanto la parte lineal como la no lineal.



En la Figura 5 se muestra un ejemplo gráfico de la componente no-lineal de la ecuación (2), suponiendo  $K=K'$  y  $Q=2$ , Franses y van Dijk (2000). Este ejemplo permite relacionar la ecuación (2) con los conceptos de redes neuronales artificiales y biológicas dadas anteriormente. En este caso, la red está constituida por tres superficies diferentes. La superficie base o superficie-*input* está conformada por las variables explicativas, las cuales determinan a  $Z_t$  y se conocen como *inputs*. Dichos *inputs* se





multiplican por los valores de ponderación de los conectores,  $\{\gamma_{ij}, i=1, \dots, k\} = \gamma_j, j=1, \dots, Q$ , los cuales atenúan o amplifican las señales originales para, posteriormente, entrar a la superficie oculta<sup>21</sup>, donde, en este caso, existen dos unidades ocultas asociadas a funciones logísticas. Es importante resaltar que dichas unidades pueden entenderse como variables latentes que enriquecen el modelo lineal. En esta superficie se forman las combinaciones  $Z_j, \gamma_j$  ( $j=1, \dots, K$ ) que se transforman a valores entre cero y uno mediante las funciones de activación<sup>22</sup>  $G(\cdot)$ . Finalmente, éstas se multiplican por ponderaciones  $\beta_j$  para dar como resultado el *output*  $y_t$ <sup>23</sup>. Dado que esta red presenta una sola superficie oculta y que la información va en una única dirección entrada-salida (*input-output*) se conoce como red neuronal multicapa de una capa o superficie oculta (*single hidden layer feedforward network*).

Como lo señalan Kuan y White (1994), el proceso de aprendizaje de la red neuronal artificial es de carácter secuencial. Así, el aprendizaje es un proceso por el cual la red adquiere conocimiento paso a paso, siendo éste definido como la acumulación de experiencias ocurridas. En las ANN, el conocimiento se adquiere a través de los conectores o parámetros  $\Theta = \{\gamma_{ij}, \beta_j, \phi_k\}$ . En un esquema general, dado el conocimiento  $\hat{\Theta}_t$  en el tiempo ( $t$ ), el conocimiento  $\hat{\Theta}_{t+1}$  en el tiempo ( $t+1$ ) está conformado por:

$$(4) \quad \hat{\Theta}_{t+1} = \hat{\Theta}_t + \Delta_t$$

donde  $\Delta_t$  representa un incremento en el conocimiento (aprendizaje). Un procedimiento de aprendizaje satisfactorio debe, por consiguiente, especificar alguna forma apropiada que permita la actualización  $\Delta_t$ , con base en i) el conocimiento previo y ii) los nuevos valores observados  $W_t = (y_t, X_t)$ , de tal forma que se encuentre una función apropiada  $\Psi_t(\Delta_t = \Psi_t(W_t, \hat{\Theta}_t))$ .

Formalmente, los conectores o parámetros del modelo presentado en (2) se estiman minimizando la suma de residuales al cuadrado de la siguiente función:

<sup>21</sup> No relacionada de manera directa con el mundo real.

<sup>22</sup> Dichas funciones se asocian a la forma como la neurona biológica responde ante un estímulo, (véase nota 14 de pie de página).

<sup>23</sup> Swanson y White (1995) se refieren a los parámetros  $\gamma_{ij}$  como ponderaciones *input to hidden unit*, mientras que los parámetros  $\beta_j$  son ponderaciones *hidden unit to output*. A su vez, los parámetros  $\Phi$  de la parte lineal en (2) se conocen como ponderaciones *input to output*.

$$(5) \quad S(\Theta) = \sum_{t=1}^n [y_t - F(X_t; \Theta)]^2$$

donde el vector  $\Phi$  contiene  $(K+1)+Q(K+1)$  parámetros y  $n$  corresponde al número de observaciones consideradas. En general, cualquier algoritmo de mínimos cuadrados no-lineales puede utilizarse para obtener  $\hat{\Theta}$ . El proceso de estimación se lleva a cabo a través de un esquema recursivo. Así, dados, en la  $r$ -ésima iteración,  $\hat{\Theta}^{(r)}$  vector de parámetros estimados,  $S(\hat{\Theta}^{(r)})$  suma de residuales al cuadrado y  $\nabla S(\hat{\Theta}^{(r)})$  gradiente asociado, la estimación  $r+1$ -ésima se obtiene a través de la siguiente formulación<sup>24</sup>:

$$(6) \quad \hat{\Theta}^{r+1} = \hat{\Theta}^r - \lambda A(\hat{\Theta}^r)^{-1} \nabla S(\hat{\Theta}^r)$$

donde, de acuerdo con el algoritmo de propagación hacia atrás o *backpropagation*, la matriz  $A(\hat{\Theta}^r)$  es igual a una matriz idéntica. Es importante anotar que, bajo este algoritmo particular, diferentes elementos del vector gradiente puedan ser estimados recursivamente<sup>25</sup> y, de esta forma, el error cometido en ( $r$ ) es de vital importancia para la estimación en ( $r+1$ ), hecho que, como ya se había señalado, coincide con el proceso de aprendizaje del cerebro humano en lo referente a la consideración de los errores pasados. Así, como afirman Moshiri y Cameron (1998), en el contexto de las series de tiempo modeladas por medio de las redes neuronales, el aprendizaje o *entrenamiento* se define como un proceso de iteración y ajuste de parámetros que permite llevar el *output* producido por la red neuronal, en línea con el *output* observado de tal forma que se minimice la función objetivo.

Como lo sugieren Franses y van Dijk (2000), las propiedades numéricas del método de estimación de mínimos cuadrados no-lineales pueden mejorarse si: i) las variables son re-escaladas de tal forma que tengan media cero y desviación estándar unitaria y ii) si en la función objetivo del proceso de estimación, ecuación (5), se involucra un término de penalización (*weight decay*), de tal forma que se evite la presencia de parámetros muy grandes. Así, la nueva función objetivo es:

<sup>24</sup> Quedando especificada la forma funcional  $\Psi$ . Es de señalar que tal forma funcional está asociada al algoritmo de optimización utilizado.

<sup>25</sup> Por ejemplo, la derivada parcial de  $S(\Theta)$  respecto a  $\beta$ , es igual a:  $-2 \sum_{t=1}^n \varepsilon_t G(x, \gamma)$

$$(7) \quad S(\Theta) = \sum_{i=1}^n [y_i - F(X_i; \Theta)]^2 + r_\phi \sum_{i=0}^{k'} \phi_i^2 + r_\beta \sum_{j=1}^Q \beta_j^2 + r_\gamma \sum_{j=1}^Q \sum_{i=0}^k \gamma_{ij}^2$$

La implementación de una red neuronal artificial requiere de la selección de cuatro elementos básicos: i) la función de activación, ii) el número de unidades ocultas (*hidden units*), ( $Q$ ), iii) el número de variables *input*, ( $K$ ) y iv) la determinación de dos conjuntos de información: el primero definido como información dentro de muestra, el cual se utiliza para ‘entrenar’ la red y estimar los parámetros, y el segundo, definido como información fuera de muestra, usado para evaluar los pronósticos. En general, la función logística se utiliza como función de activación y por consiguiente, dicho punto se pierde como elemento de selección.

Existen diferentes estrategias que pueden considerarse para determinar el número de unidades ocultas y el conjunto de variables *input*, como lo presentan Moody y Utans (1991), Moody (1994, 1995), Levin *et al.* (1994), Franses y van Dijk (2000) y Swanson y White (*Op. Cit.*, 1995, 1997a). Estos últimos autores proponen, como esquema para definir el conjunto de variables *input*, la adopción de una estrategia *step-wise* en la componente lineal, de tal forma que, en cada paso, la variable adicionada sea considerada en el conjunto *input* si ésta mejora los criterios de selección<sup>26</sup>. Una vez definido el conjunto de variables *input* de la componente lineal,  $X_i$  ecuación (2), se conforma el conjunto  $Z_i$ ,  $Z_i \subseteq X_i$ . En primera instancia, el conjunto  $Z_i$  incluye tan sólo la primera variable del conjunto *input*, luego se adiciona a dicho conjunto la segunda variable *input* de tal forma que en el último paso  $Z_i = X_i$ . La estimación de la red se lleva a cabo considerando cada uno de estos conjuntos  $Z_i$  y diferente número de unidades ocultas, ( $Q$ ) ( $Q = 1, \dots, Q^*$ )<sup>27</sup>. De acuerdo con Gradojevic y Yang (2000), el número de unidades ocultas  $Q$  por elegir presenta un *trade-off*. Demasiadas unidades conllevan a un sobreentrenamiento o sobreajuste, lo cual evita que la red aprenda una solución general; muy pocas unidades ocultas por otro lado, inhiben el aprendizaje del patrón entre el *input* y el *output*. La selección del mejor modelo se lleva a cabo a través de medidas tradicionales de evaluación de pronóstico dentro y fuera de muestra<sup>28</sup>.

<sup>26</sup> Criterios tales como AIC y BIC.

<sup>27</sup> Donde  $Q^*$  es el máximo número de unidades ocultas.

<sup>28</sup> Swanson y White (1995, *Op. Cit.*) señalan que al existir modelos que resultan mejores de acuerdo con alguna medida de evaluación pero no de acuerdo con otras, se deben mirar todas

La relevancia de las variables *input* en el modelo seleccionado se lleva a cabo a través de un análisis de sensibilidad, el cual puede realizarse mediante dos enfoques: Franses (2000) y Draisma *et al.* (1995). En tal análisis se compara la variable  $y_t$  observada con la variable *output* estimada,  $\hat{y}_t$ , a través de la red. El esquema de Draisma *et al.* (1995) evalúa la contribución de una variable *input* ( $z_j$ ) sobre el *output* rompiendo las conexiones de la red con dicha variable<sup>29</sup>.

Como se mencionó anteriormente, las redes neuronales<sup>30</sup> se clasifican dentro de los modelos paramétricos no lineales. Sin embargo, no es común pensar en ellas como procesos generadores de datos. Así, carece de sentido realizar una prueba sobre existencia de no linealidades tipo red neuronal. Sin embargo, a través de las redes neuronales puede llevarse a cabo un test sobre no linealidad general como el desarrollado por Lee *et al.* (1993).

Finalmente, es importante señalar algunos problemas asociados a la implementación de las redes neuronales. Por un lado, los parámetros son casi imposibles de interpretar y no brindan información sobre qué tipo de modelo paramétrico no lineal sería adecuado para describir los patrones o dinámicas no lineales identificados. Por esto suele hacerse referencia a las redes neuronales como ‘cajas negras’ en el sentido de que sirven sólo para identificar patrones en la serie y para pronóstico, pero no permiten interpretar ni dar sentido económico a los parámetros estimados. Adicionalmente, un buen ajuste de la red dentro de muestra (que puede lograrse introduciendo un número suficientemente grande de componentes logísticos no lineales) no garantiza un buen desempeño de la red para pronóstico fuera de muestra; es decir, existe el riesgo de sobreajuste debido a la alta flexibilidad de estos modelos, tal y como se señaló anteriormente.

---

las medidas y se podría inclusive especificar una función de pérdida que asigne ponderaciones a las diferentes medidas. Adicionalmente, un modelo que resulte mejor según las medidas dentro de muestra, no necesariamente es adecuado para pronóstico fuera de muestra, por lo cual, al escoger el mejor modelo, deben tenerse en cuenta todas las medidas.

<sup>29</sup> Tal rompimiento se logra imponiendo ceros a los conectores o coeficientes vinculados con la variable en cuestión, tanto en la componente lineal como en la no lineal. Como se sugiere en Draisma *et al.* (1995), este procedimiento es comparable con el análisis de contribución parcial de términos lineales.

<sup>30</sup> Es de señalar que su estructura puede gozar de algún tipo de interpretación.

#### IV. INTERPRETACIÓN ECONÓMICA DEL *HIDDEN LAYER* O SUPERFICIE OCULTA

En la modelación de variables económicas, la existencia de asimetrías entre el *input* y el *output* puede dar origen a no linealidades en su relación. Tal y como se vio anteriormente, las componentes logísticas o unidades ocultas caracterizan la parte no lineal de la relación entre el *input*  $Z_i$  y el *output*  $y_i$ .

Esta relación entre  $Z_i$  y  $y_i$  puede no ser directa, en cuyo caso existirían variables intermedias o latentes que se vean afectadas por las variables *input* antes que el *output*<sup>31</sup>. Tkacz y Hu (1999) señalan que estas variables intermedias, que son precisamente los *hidden layers* o componentes logísticos en la red neuronal, son etapas intermedias de procesamiento donde los *inputs*  $Z_j$ , y sus ponderaciones  $\gamma_j$ , son sujetos a otra reponderación, antes de afectar a  $y_i$ . Al modelar y pronosticar series económicas con redes neuronales, estas variables intermedias no tienen que ser identificadas y pueden tratarse como desconocidas u ocultas<sup>32</sup>.

En el caso de modelos de redes neuronales para inflación, en la sección II presentamos evidencia de diferentes trabajos que confirman asimetrías entre la política monetaria y el nivel de precios, lo que justifica la consideración de no linealidades entre variables monetarias e inflación<sup>33</sup>. Si bien las variables intermedias o latentes que operan en el *hidden layer* de tales modelos no tienen que ser conocidas, algunas variables que se ven afectadas por la política monetaria antes que la inflación pueden mencionarse especulativamente, constituyéndose en mecanismos de transmisión importantes que se pueden estar capturando por el *hidden layer*. Tal y

---

<sup>31</sup> Tkacz y Hu (1999), mencionan que para el caso de la relación entre tasas de interés y producto, es de esperarse que variables intermedias afectadas por la tasa de interés tales como la inversión, se vean afectadas antes que el producto. Por ejemplo, una caída en la inversión presente causada por un aumento en las tasas de interés, conlleva una caída en el producto presente. Sin embargo, esta caída en la inversión actual conduce también a una caída en el producto futuro debido a la pérdida de flujos futuros de ingresos resultante de la inversión en capital que no se llevó a cabo. El *hidden layer* está capturando estas dinámicas intermedias u ocultas entre la tasa de interés y la inversión.

<sup>32</sup> Moody, Levin y Rehfuss (1993) y Moody (1995) señalan que esta dificultad para identificar y conocer todas las variables que afectan las relaciones económicas, ha conducido, en muchos casos, a la ausencia de modelos científicos confiables o convincentes, y a la utilización de modelos 'caja negra' para pronosticar series económicas que no requieren el conocimiento o identificación de todas las variables que operan entre el *input* y el *output*.

<sup>33</sup> Algunos de estos trabajos son los de Friedman (1968), Cover (1992), Morgan (1993) y Rhee y Rich (1995).

como señala Tkacz (2000), la política monetaria (ya sea a través de instrumentos de tasa de interés o de agregados monetarios) puede afectar el nivel de inversión, lo cual, a su vez tiene un efecto sobre el nivel de actividad económica y el producto, que vía una curva de Phillips de corto plazo, afecta el nivel de precios. De esta manera, a pesar de no incluir explícitamente variables como la inversión o la brecha del producto como *inputs* del modelo, estos mecanismos de transmisión pueden estarse modelando en el *hidden layer*, de manera que su relación y sus dinámicas no lineales con la inflación se estén considerando en la superficie oculta de la red.

## V. RESULTADOS


Este trabajo se llevó a cabo con información trimestral correspondiente a la primera diferencia del logaritmo de las series *IPC*, *M1* y *M3*. El estudio abarca el período comprendido entre el primer trimestre de 1969 y el segundo de 2001. Con el propósito de mejorar las propiedades de estimación, como se mencionó anteriormente, las variables son re-escaladas en el intervalo (0,1)<sup>34</sup>.

Como períodos de entrenamiento (*training samples*) se consideran dos conjuntos de información diferentes, el primero, desde 1969:2 hasta 1997:4 y el segundo, desde 1969:2 hasta 1999:4. Así, para el primer conjunto, la información para pronóstico fuera de muestra está conformada por 14 observaciones 1998:01-2001:02, en tanto que, para el segundo, se reduce a seis, 2000:01-2001:02. Como se observa en los gráficos 1 y 2, a partir de 1998 el proceso desinflacionario experimentado por el país explica el comportamiento decreciente de la serie hasta el año 2001. Este hecho justifica la selección de los dos conjuntos de información como períodos de entrenamiento, ya que ello permite que la red ‘aprenda’ e ‘identifique’ las dinámicas y patrones asociados a dicha caída y que por consiguiente, pueda mejorar su capacidad de pronóstico. Es importante resaltar que la consideración de los dos períodos de entrenamiento hace parte de una estrategia que trata de tomar en cuenta, por un lado, la dinámica de la caída y, por otro, el número de observaciones fuera de muestra.

La estrategia *stepwise*, propuesta por Swanson y White (1995,1997a) y descrita anteriormente, se lleva a cabo con el propósito de determinar el conjunto de varia-


<sup>34</sup>  $x_t^* = \frac{x_t - \bar{x}_t}{\sigma(x_t)}$ ;  $x_t = \ln(x_t) - \ln(x_{t-1})$ . Es de señalar que la notación “\*” se utiliza para referirse a la transformación de la diferencia del logaritmo de cada serie.

Gráfico 1  
Inflación trimestral  $\Delta LIPC^*$



\* Transformación de re-escalamiento.

Gráfico 2  
Inflación trimestral  $\Delta LIPC$



bles *inputs* de la componente lineal. Así, se parte de una regresión lineal cuya variable dependiente es  $\Delta LIPC_t^*$  y cuyas variables explicativas varían de acuerdo con el modelo considerado. En el primer modelo, el conjunto de variables explicativas, o *inputs* de la componente lineal, considera los primeros ocho rezagos de la inflación, es decir,  $\Delta LIPC_{t-1}^*$  hasta  $\Delta LIPC_{t-8}^*$ . En los modelos segundo y tercero se consideran tan solo variables monetarias como explicativas. El segundo incluye los seis primeros rezagos de  $M1$ ,  $\Delta M_{t-1}^*$  hasta  $\Delta M_{t-6}^*$ , en tanto que, en el tercero, la variable monetaria considerada es  $M3$ . Los modelos cuarto y quinto incluyen rezagos de inflación y dinero en su conjunto de información y tienen en cuenta el mismo número de rezagos que se consideró para los tres primeros modelos, sólo que en el cuarto modelo la variable monetaria considerada es  $M1$  mientras que en el quinto es  $M3$ <sup>35</sup>.

El Cuadro 1 resume los resultados de la estrategia *stepwise* para cada modelo y presenta las variables que conforman el conjunto de información  $X_t$ , señalado en (2), del cual se selecciona el conjunto de información  $Z_t \subseteq X_t$  que conforma la parte no lineal.

Cuadro 1  
Resultados estrategia *stepwise*

	Período de entrenamiento 1969:2-1997:4	Período de entrenamiento 1969:2-1999:4
	$y_t = \Delta LIPC_t^*$ $m_{1t} = \Delta LM1_t^*$ $m_{3t} = \Delta LM3_t^*$	
Modelo 1	$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$
Modelo 2	$X_t = \{m_{1t-1}, m_{1t-2}\}$	$X_t = \{m_{1t-1}, m_{1t-2}, m_{1t-5}\}$
Modelo 3	$X_t = \{m_{3t-1}, m_{3t-2}, m_{3t-3}, m_{3t-5}\}$	$X_t = \{m_{3t-1}, m_{3t-2}, m_{3t-3}, m_{3t-5}\}$
Modelo 4	$X_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$	$X_t = \{y_{t-1}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$
Modelo 5	$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}\}$	$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$

<sup>35</sup> El motivo por el cual se consideran los primeros ocho rezagos de la inflación y los primeros seis rezagos del dinero se debe a que diferentes trabajos como Misas et al. (1999) y Jalil et al. (2000) muestran que el rezago con el cual el dinero afecta la inflación es de año y medio, mientras que el componente autorregresivo de la inflación suele considerar los últimos dos años.



Una vez seleccionado el conjunto  $X_i$ , se lleva a cabo el proceso de estimación de la red neuronal, ecuación (2), para distintas configuraciones del conjunto de información  $Z_i$ ,  $Z_i \subseteq X_i$  y para los dos períodos de entrenamiento seleccionados. Para cada modelo, se estima la red incluyendo en el conjunto  $Z_i$  la primera variable de  $X_i$ , y para  $Q$  *hidden units* desde 1 hasta 4. Luego se incluye en  $Z_i$ , las primeras dos variables de  $X_i$  y se estima la red para  $Q$  desde uno hasta 4. El proceso se repite hasta que se estima la red con  $Z_i = X_i$ <sup>36</sup>.

El método de optimización numérica, utilizado en el proceso de estimación, es el Quasi-Newton de Broyden, Fletcher, Goldfarb y Shano. Como señalan Franses y van Dijk (2000), la convergencia en el proceso de estimación no garantiza la obtención del mínimo global<sup>37</sup>. Por consiguiente, se llevan a cabo múltiples estimaciones de cada una de las diferentes redes utilizando distintos valores iniciales del vector de parámetros  $\hat{\Theta}$ . En particular, cada red se estima para 30 valores iniciales diferentes del vector de parámetros. Tales valores iniciales se obtienen aleatoriamente a partir de una distribución uniforme entre [-2,2] y los parámetros del término de *weight decay* en la función objetivo  $S(\Theta)$  se fijaron de la siguiente manera:  $r_\phi = 0.01$ ,  $r_\beta = r_\gamma = 0.0001$ . La selección de la estimación óptima, en cada modelo, se realiza considerando dos criterios: i) menor valor de la función objetivo y ii) vector de gradientes, asociado a los parámetros de la estimación, sin elementos superiores a  $1 \times 10^{-3}$ . Finalmente, para cada red estimada, se calculan medidas de evaluación dentro y fuera de muestra, las cuales permiten elegir la mejor red para cada modelo<sup>38</sup>.

En los cuadros 2 y 3 se presentan, para cada conjunto de variables *inputs*, los modelos o redes neuronales seleccionados, de acuerdo con las medidas de evaluación dentro y fuera de muestra para los períodos comprendidos entre 1969:02-1997:04 y 1969:02-1999:04, respectivamente<sup>39</sup>.

---

<sup>36</sup> En las tablas de resultados se incluye el caso  $Q=0$ , que hace referencia al modelo que sólo tiene en cuenta el componente lineal de la red.

<sup>37</sup> De hecho, según Franses y van Dijk (2000), la función  $S(\Theta)$  posee muchos mínimos locales.

<sup>38</sup> Las medidas de evaluación consideradas son las siguientes: *AIC*, *BIC*, *RMSE*, *RMSPE*, *MAE*, *MAPE* y *SR* dentro de muestra y *RMSE*, *RMSPE*, *MAE*, *MAPE*, *SR* y *U-THEIL* para fuera de muestra. Dichas medidas se describen en el Anexo 2.

<sup>39</sup> En el Anexo 1 se presentan los resultados de las medidas de evaluación de la red neuronal dentro y fuera de muestra para cada uno de los períodos y modelos bajo estudio.

De acuerdo con los resultados<sup>40</sup> presentados en el Cuadro 2, el modelo 4 se constituye como el mejor modelo de redes neuronales<sup>41</sup> para el período comprendido entre 1969:02 y 1997:04. Este modelo considera: i) un conjunto de variables *input* en la parte lineal,  $X_t$ , igual que el de la parte no lineal,  $Z_t$ , conformado por el segundo y el octavo rezago de la inflación mensual y por los dos primeros del crecimiento de *M1*,

Cuadro 2 Modelos seleccionados 1969:02 – 1997:04												
Modelo general:												
$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t \quad G(z) = (1 + \exp(-z))^{-1}$												
$y_t = \Delta LIPC_t^*, m_{1t} = \Delta LM1_t^*, m_{3t} = \Delta LM3_t^*$												
Dentro de muestra							Fuera de muestra					
<i>AIC</i>	<i>BIC</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>	<i>U-THEIL</i>
Modelo 1 : <i>Inputs</i> : $X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$ , $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$ , $Q=4$												
-0,949	-0,449	0,516	6,306	0,386	2,076	83,01	1,259	1,390	1,039	1,131	53,84	0,177
Modelo 2 : <i>Inputs</i> : $X_t = \{m_{1t-1}, m_{1t-2}\}$ , $Z_t = \{m_{1t-1}, m_{1t-2}\}$ , $Q=3$												
-0,884	-0,594	0,578	6,141	0,454	2,117	79,46	1,106	5,671	0,938	3,010	100,0	0,919
Modelo 3 : <i>Inputs</i> : $X_t = \{m_{3t-1}, m_{3t-2}, m_{3t-3}, m_{3t-5}\}$ , $Z_t = \{m_{3t-1}, m_{3t-2}, m_{3t-3}\}$ , $Q=3$												
-0,649	-0,281	0,631	5,226	0,464	1,952	78,90	0,461	3,202	0,379	1,527	100,0	0,383
Modelo 4 : <i>Inputs</i> : $X_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$ , $Z_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$ , $Q=4$												
-1,090	-0,490	0,463	7,416	0,360	1,838	81,13	0,904	3,319	0,812	1,745	100,0	0,424
Modelo 5 : $X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}\}$ , $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}\}$ , $Q=4$												
-0,286	0,314	0,693	7,400	0,556	2,281	66,98	1,022	1,257	0,904	1,085	53,85	0,161

<sup>40</sup> Los diferentes resultados, presentados en este artículo, se obtienen a través de programación bajo el módulo *IML* de *SAS*, versión 8.2.

<sup>41</sup> Dentro del conjunto de redes neuronales estudiadas en este trabajo.

y ii) cuatro unidades ocultas  $Q$ . Si bien en algunas medidas, el modelo 4 es superado por los otros modelos, una mirada global a todas las medidas demuestra que el modelo 4 resulta ser el mejor según *AIC*, *RMSE*, *MAE*, *MAPE* (dentro de muestra) y el segundo mejor en medidas como *BIC*, *RMSE* y *MAE* (fuera de muestra).

El análisis de los resultados presentados en el Cuadro 3 permite concluir que el modelo 5 es el mejor modelo de redes neuronales para el período de 1969:02 a 1999:04. Este modelo, al igual que el anterior, presenta el mismo conjunto de variables *input* en la parte lineal como en la no lineal. Dicho conjunto está conformado por

Cuadro 3 Modelos seleccionados 1969:02 - 1999:04													
Modelo general: $y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon, \quad G(z) = (1 + \exp(-z))^{-1}$ $y_t = \Delta LIPC_t^*, m_{1t} = \Delta LM1_t^*, m_{3t} = \Delta LM3_t^*$													
Dentro de muestra							Fuera de muestra						
<i>AIC</i>	<i>BIC</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>	<i>U-THEIL</i>	
Modelo 1 : <i>Inputs</i> : $X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$ , $Z_t = \{y_{t-2}, y_{t-4}\}$ , $Q=4$													
-0,815	-0,415	0,572	8,281	0,433	2,190	83,96	0,979	3,007	0,858	1,547	84,61	0,384	
Modelo 2 : <i>Inputs</i> : $X_t = \{m_{1t-1}, m_{1t-2}, m_{1t-5}\}$ , $Z_t = \{m_{1t-1}, m_{1t-2}\}$ , $Q=4$													
-0,813	-0,438	0,582	17,780	0,448	3,444	80,34	1,026	3,353	0,891	2,080	80,00	0,904	
Modelo 3 : $X_t = \{m_{3t-1}, m_{3t-2}, m_{3t-3}, m_{3t-5}\}$ , $Z_t = \{m_{3t-1}, m_{3t-2}, m_{3t-3}\}$ , $Q=4$													
-0,685	-0,216	0,599	13,722	0,446	3,221	78,63	0,405	1,436	0,297	0,807	100,0	0,357	
Modelo 4 : <i>Inputs</i> : $X_t = \{y_{t-1}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$ , $Z_t = \{y_{t-1}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$ , $Q=4$													
-1,141	-0,568	0,458	12,333	0,351	2,965	85,96	1,077	4,493	0,933	2,674	80,00	0,907	
Modelo 5 : $X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$ , $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$ , $Q=3$													
-1,059	-0,558	0,490	11,492	0,375	2,358	85,08	0,492	0,694	0,295	0,511	80,00	0,140	


los rezagos dos, cuatro y ocho de la inflación mensual y los dos primeros rezagos del crecimiento de  $M3$ . En este modelo el número de unidades ocultas es igual a tres.

Los gráficos 3 y 4 presentan la inflación mensual observada y pronosticada a través de la red.

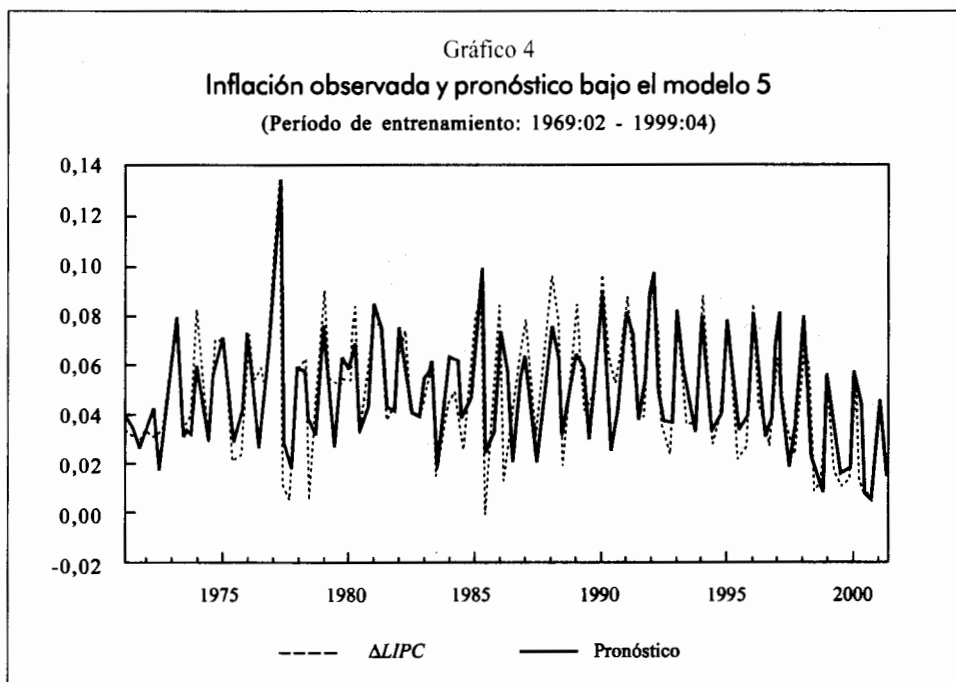
En el Gráfico 3, la inflación pronosticada proviene del modelo 4 correspondiente al período de entrenamiento de 1969:02 a 1997:04. En este gráfico se consideran pronósticos fuera de muestra aquellos reportados para el período de 1998:01 a 2001:02.

En el Gráfico 4, la inflación pronosticada proviene del modelo 5 correspondiente al período de entrenamiento de 1969:02 a 1999:04. Los pronósticos fuera de muestra, en este caso, son los correspondientes al período de 2000:01 a 2001:02.

Al comparar los pronósticos fuera de muestra correspondientes al año 2000 y 2001<sup>42</sup>, se observa un mejor ajuste de aquellos provenientes del modelo 5, Gráfico 4. Este



<sup>42</sup> Comunes para los dos períodos de entrenamiento.



mejor ajuste se debe a que este modelo considera mayor información, la cual permite incrementar el proceso de aprendizaje de la red neuronal. Esto confirma la importancia de haber considerado un segundo período de entrenamiento que le permita a la red incorporar la información relacionada con la caída en la inflación desde 1998. De hecho, puede verse en el Gráfico 3, que la red seleccionada para el primer período de entrenamiento, la cual no tiene en cuenta la caída de la serie entre 1998 y 2001 y, por consiguiente, no ‘aprende’ la nueva relación entre dinero e inflación experimentada durante este período desinflacionario, tiende a sobre-pronosticar la inflación.

Los cuadros 4 y 5 muestran los resultados del análisis de sensibilidad, sugerido por Draisma *et al.* (1995), correspondientes a los modelos 4 (1969:02-1997:04) y 5 (1969:02-1999:04), respectivamente. Como se observa, al comparar las medidas de evaluación de pronóstico dentro y fuera de muestra del modelo 4, Cuadro 1, con las obtenidas en el análisis de sensibilidad, el modelo presenta su mayor pérdida de capacidad predictiva, dentro y fuera de muestra, al desconectar el primer rezago del crecimiento monetario<sup>43</sup>. Sin embargo, a partir del

<sup>43</sup> En el Anexo 3 se presenta un resultado similar siguiendo la metodología de análisis de sensibilidad propuesta por Franses y van Dijk (2000).

Cuadro 4  
Análisis de sensibilidad sobre la red neuronal seleccionada: modelo 4  
1969:02 – 1997:04

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon, \quad G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_{1t} = \Delta LM1_t^*$$

*Inputs:*  $X_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$ ,  $z_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$   
 $Q=4$

Dentro de muestra								Fuera de muestra				
Desconexión	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR	RMSE	RMSPE	MAE	MAPE	SRU-THEIL
(1) $y_{t-2}$	-0,274	0,325	0,697	14,472	0,548	3,729	76,4	1,261	3,185	1,013	1,807	69,2 0,407
(2) $y_{t-8}$	0,042	0,642	0,816	21,209	0,629	3,993	66,0	1,170	3,076	0,991	1,761	69,2 0,393
(3) $m_{1t-1}$	0,919	1,519	1,265	29,477	1,011	8,001	56,6	1,625	6,264	1,212	2,851	46,2 0,800
(4) $m_{1t-2}$	0,330	0,930	0,942	6,358	0,674	2,709	68,9	1,130	6,481	1,029	3,189	100 0,828

Cuadro 5  
Análisis de sensibilidad sobre la red neuronal seleccionada: modelo 5  
1969:02 – 1999:04

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon, \quad G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

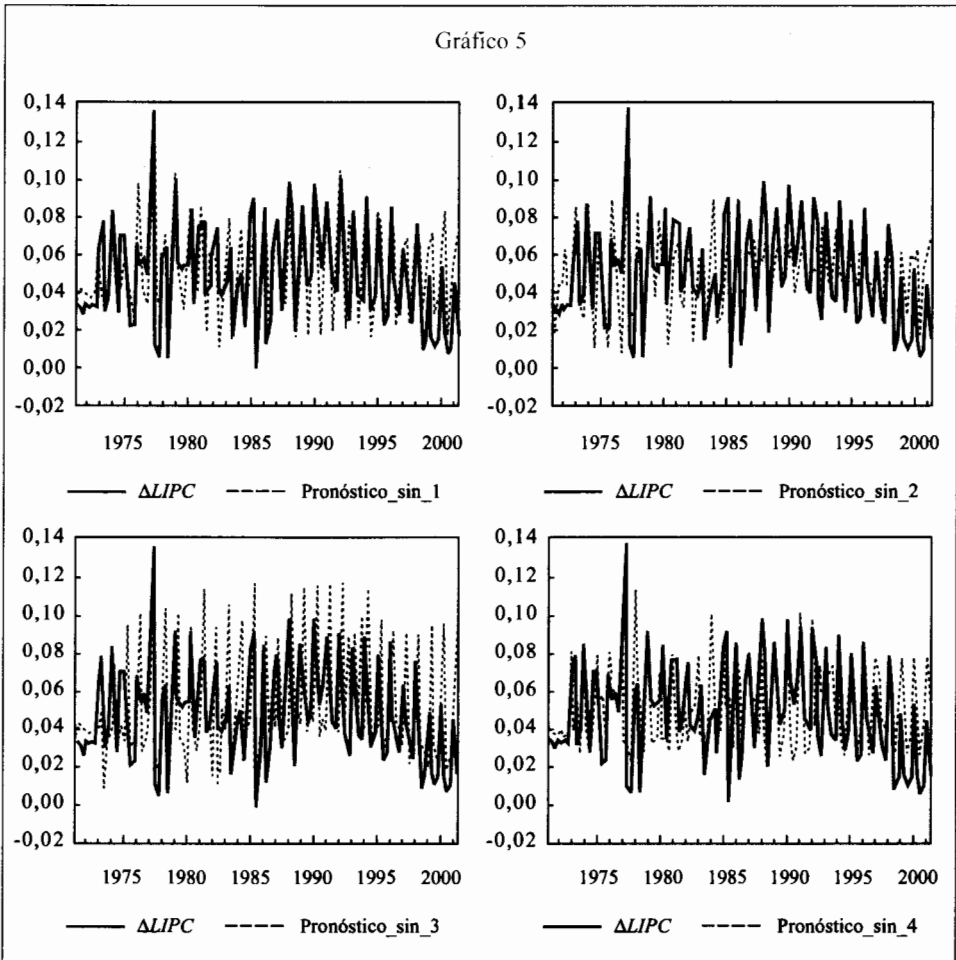
$$m_{3t} = \Delta LM3_t^*$$

*Inputs:*  $X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$ ,  $z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$   
 $Q=3$

Dentro de muestra								Fuera de muestra				
Desconexión	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR	RMSE	RMSPE	MAE	MAPE	SR U-THEIL
(1) $y_{t-2}$	0,144	0,645	0,895	16,570	0,653	4,271	69,3	1,872	10,401	1,136	4,986	40,0 2,101
(2) $y_{t-4}$	0,445	0,946	1,041	6,479	0,692	2,436	70,2	0,819	0,968	0,574	0,792	100 0,195
(3) $y_{t-8}$	-0,317	0,184	0,711	6,854	0,554	2,112	76,3	0,839	0,741	0,700	0,673	80,0 0,150
(4) $m_{3t-1}$	-0,479	0,022	0,656	14,458	0,512	2,716	80,7	0,898	0,901	0,717	0,822	100 0,182
(5) $m_{3t-2}$	-0,133	0,369	0,780	8,154	0,541	2,339	77,2	0,645	2,325	0,537	1,544	100 0,47


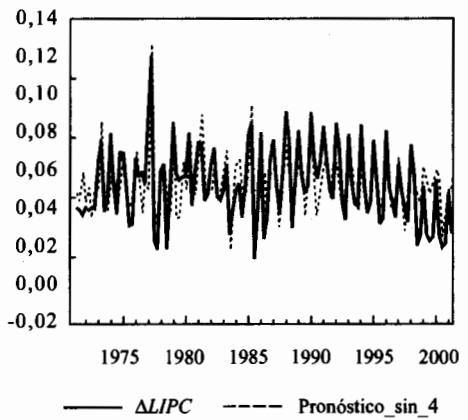
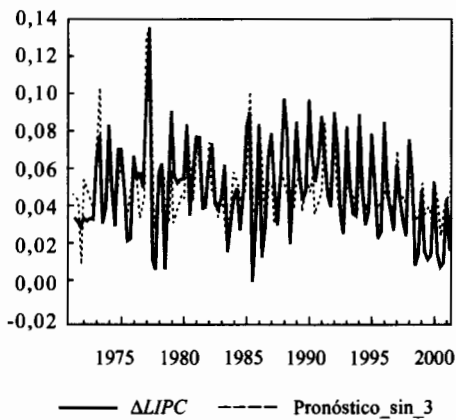


Gráfico 5<sup>44</sup> se concluye que en este modelo todas las variables *inputs* son relevantes para el pronóstico tanto dentro como fuera de muestra.

Al comparar las medidas de evaluación de pronóstico dentro y fuera de muestra correspondientes al modelo 5, Cuadro 2, con aquellas obtenidas al llevar a cabo el análisis de sensibilidad, Cuadro 5, se observa que la mayor pérdida de capacidad predictiva se alcanza al desconectar el rezago de orden dos de la inflación. Al igual que en el caso anterior, el Gráfico 6 permite concluir que todas las variables *input*



<sup>44</sup> El gráfico presenta la inflación trimestral re-escalada observada y la pronosticada, desconectando cada una de las variables *inputs* de la red.

Gráfico 6





son relevantes tanto para el pronóstico dentro de muestra como para el de fuera de ésta.

Dado que la estimación de un modelo de redes neuronales exige la existencia de una relación no lineal entre la variable dependiente y las variables *input*, en nuestro caso inflación y crecimiento monetario, es necesario verificar estadísticamente tal existencia. El Cuadro 6 señala los resultados del test de Lee *et al.* (1993)<sup>45</sup>, basado en redes neuronales<sup>46</sup>, llevado a cabo sobre los dos períodos de entrenamiento. Para la muestra comprendida entre 1969:02 y 1997:04 y a un nivel de significancia  $\alpha=10\%$  existe evidencia para rechazar la hipótesis nula de relación lineal entre las variables en cuestión. Al considerar el segundo período de entrenamiento de 1969:02 a 1999:04, se encuentra a un nivel de significancia  $\alpha=5\%$  que existe evidencia para rechazar la hipótesis nula de linealidad. Así, hay evidencia sobre la existencia de una relación no lineal entre la inflación y el crecimiento de *M1* y *M3* para los períodos de entrenamiento respectivo.

Los cuadros 7 y 8 presentan las medidas de evaluación de pronóstico dentro y fuera de muestra de la red neuronal seleccionada *vs.* algunos modelos de carácter lineal, Anexo 4, para los períodos de 1969:02 a 1997:04 y de 1969:02 a 1999:04, respectivamente. Es de señalar que, las medidas de evaluación de pronóstico se llevan a cabo sobre la inflación anual en unidades originales (no transformadas).

Replicaciones	Muestra	Modelo seleccionado	P-value Test Lee, White y Granger
5.000	1969:02 – 1997:04	Modelo 4	0,067321
5.000	1969:02 – 1999:04	Modelo 5	0,044263

<sup>45</sup> Este test, tipo *pormanteau*, plantea linealidad bajo la hipótesis nula, en tanto que, bajo la alterna, sugiere no linealidad.

<sup>46</sup> En cada período de entrenamiento se utilizó la red neuronal seleccionada.

Cuadro 7  
Desempeño de la red versus otros modelos  
1969:02 – 1997:04

Modelos	Dentro de muestra					Fuera de muestra					
	RMSE	RMSPE	MAE	MAPE	SR	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
<b>Red neuronal artificial</b>											
<b>Modelo 4</b>	0,0110	2,516	0,009	0,535	84,38	0,0225	1,715	0,020	1,140	100,0	0,871
<b>Modelos lineales</b>											
<b>C. Phillips</b>	0,0103	3,658	0,008	0,627	85,94	0,0176	1,208	0,015	0,911	92,31	0,613
<b>P* tradicional</b>	0,0105	1,787	0,009	0,424	87,50	0,0102	0,645	0,008	0,473	92,31	0,327
<b>Escandinavo</b>	0,0113	2,864	0,009	0,546	89,06	0,0161	1,219	0,013	0,884	92,31	0,619
<b>Precios relativos</b>	0,0080	1,789	0,006	0,359	93,75	0,0162	0,814	0,014	0,694	76,92	0,413
<b>ARIMA</b>	0,0148	4,780	0,011	0,878	87,50	0,0249	1,848	0,023	1,526	76,92	0,938

Cuadro 8  
Desempeño de la red versus otros modelos  
1969:02 – 1999:04

Modelos	Dentro de muestra					Fuera de muestra					
	RMSE	RMSPE	MAE	MAPE	SR	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
<b>Red neuronal artificial</b>											
<b>Modelo 5</b>	0,0125	2,983	0,010	0,625	90,28	0,0125	0,827	0,007	0,470	80,00	0,589
<b>Modelos lineales</b>											
<b>C. Phillips</b>	0,0111	3,076	0,008	0,596	87,50	0,0058	0,534	0,005	0,332	100,0	0,380
<b>P* tradicional</b>	0,0104	1,532	0,009	0,411	87,50	0,0103	0,521	0,008	0,396	100,0	0,371
<b>Escandinavo</b>	0,0118	2,528	0,009	0,543	88,89	0,0087	0,434	0,007	0,363	100,0	0,309
<b>Precios relativos</b>	0,0085	1,880	0,007	0,402	90,28	0,0102	0,726	0,008	0,509	100,0	0,517
<b>ARIMA</b>	0,0149	4,653	0,011	0,878	87,50	0,0167	1,148	0,015	1,006	100,0	0,817

Los resultados de los cuadros 7 y 8 permiten concluir que los modelos seleccionados de redes neuronales pueden considerarse competitivos dentro del conjunto de modelos trimestrales utilizados para predecir la inflación en Colombia. El modelo 4 supera los modelos escandinavo y *ARIMA* en las medidas dentro de muestra y compite con los demás modelos en *RMSE*, *MAE* y *SR*. Para las medidas fuera de muestra, el modelo 4 supera el *ARIMA* en todas las medidas y supera todos los modelos lineales en el *SR*. El modelo 5, elegido para el segundo período de entrenamiento, supera el *ARIMA* en todas las medidas dentro de muestra; supera también todos los modelos en el *SR* dentro de muestra, como también, al modelo C. Phillips en el *RMSPE* y compite con todos los modelos en el *MAE*. En las medidas fuera de muestra, el modelo supera el *ARIMA* en todas las medidas excepto *SR*, supera todos los modelos (con excepción del C. Phillips) en *MAE* y supera el modelo de precios relativos en *MAPE*.

## VI. CONCLUSIONES

Los resultados de este trabajo demuestran el potencial que tienen los modelos de redes neuronales en el pronóstico de la inflación, al competir, y, en algunos casos, superar los modelos lineales tradicionales. Con estos resultados se amplía y mejora la familia de modelos de que hoy se dispone para pronóstico de la inflación y, en particular, se fortalece el trabajo de los modelos que contienen como insumo variables monetarias.

La prueba de no-linealidad, al igual que diferentes argumentos teóricos mencionados en el trabajo, señalan la importancia de modelar la inflación con técnicas no lineales como las redes neuronales. La principal ventaja de esta técnica es que explota la riqueza de su estructura no lineal y la habilidad para aprender en una forma adaptativa del proceso generador de datos subyacente.

Con el fin de mejorar la capacidad de pronóstico de este modelo, algunos elementos adicionales deben considerarse en trabajos futuros, como son la ampliación del conjunto de información tanto en observaciones como en variables. Tkacz y Hu (1999) señalan que el número de observaciones utilizadas en la red se vuelve un factor determinante, dado: i) el número de parámetros que deben estimarse bajo las diferentes especificaciones y ii) la optimización del proceso de aprendizaje, la cual se logra en la medida en que se cuenta con un mayor número de observacio-

nes en el conjunto de información que posibilita una mejor identificación de los patrones y dinámicas inherentes a la relación estudiada<sup>47</sup>. En este sentido, se llevará a cabo un ejercicio con datos mensuales y otras variables explicativas adicionales<sup>48</sup> con el fin de mejorar la capacidad predictiva de la red<sup>49</sup>.

---

<sup>47</sup> Estos autores recomiendan, tener por lo menos, 300 observaciones como período de entrenamiento, en cuyo caso 30 años de información trimestral pueden resultar insuficientes.

<sup>48</sup> Aunque, como se señaló en el trabajo, los *hidden layers* pueden estar modelando y capturando el efecto de algunas variables intermedias o mecanismos de transmisión que no se consideraron directamente como *inputs* del modelo.

<sup>49</sup> Tkacz y Hu (1999) señalan que al utilizar series de alta frecuencia, el pronóstico de la red neuronal debe superar ampliamente el pronóstico de los modelos lineales.

## **REFERENCIAS**

- Altissimo, F.; Gaiotti, E.; Locarno, A. (2001). "Monetary Analysis in the Bank of Italy prior to EMU: The Role of Real and Monetary Variables in the Models of the Italian Economy", en Klöckers H.; Willeke, C. (eds.). *Monetary Analysis: Tools and Applications*, Banco Central Europeo.
- Aiken, M. (1996). "A Neural Network to Predict Civilian Unemployment Rates", en *Journal of International Information Management*, Vol. 5, No. 1.
- Arango, L. E.; González, A. (1998). "Some Evidence of Smooth Transition Non-Linearity in Colombian Inflation", Borradores de Economía, No. 105, *Banco de la República*.
- Azoff, E. M. (1996). *Neural Network. Time Series Forecasting of Financial Markets*, Wiley, A Wiley Finance Edition.
- Ball, L.; Mankiw, G. (1994). "Asymmetric Price Adjustment and Economic Fluctuations", en *The Economic Journal*, Vol. 104, No. 423.
- Banco Central Europeo (2001). *The Monetary Policy of the ECB*.
- Cover, J. (1992). "Asymmetric Effects of Positive and Negative Money-Supply Shocks", en *Quarterly Journal of Economics*, No. 107.
- Draisma, G.; Kaashoek, J.; van Dijk, H. K. (1995). "A Neural Network Applied to Economic Time Series", en *Econometric Institute*, Erasmus University, Rotterdam and Tinbergen Institute Rotterdam, S. F.
- Evans, O. V. D. (1997). "Short-Term Currency Forecasting Using Neural Networks", en *ICL Systems Journal*, Vol. 2, No. 11.
- Fillion, J. F.; Leonard, A. (1997). "La courbe de Phillips au Canada: un examen de quelques hypotheses", Departement des Recherches, Banque du Canada.
- Franses, P. H.; van Dijk, D. (2000). *Non-Linear Time Series Models in Empirical Finance*, Cambridge University Press.
- Friedman, M. (1968). "The Role of Monetary Policy", en *American Economic Review*, No. 58, pp. 1-17.

- Friedman, B. M. (1984). "The Value of Intermediate Targets in Implementing Monetary Policy", en FRB Kansas City (ed.), *Price Stability and Public Policy*.
- Gazely, A.; Binner, J. (2000). "The Application of Neural Networks to the Divisia Index Debate: Evidence from three Countries", en *Applied Economics*, Vol. 10, No.12.
- Gerlach, S.; Svensson, L. (2000). "Money and Inflation in the Euro Area: A case for Monetary Indicators?", en Working Paper, *National Bureau of Economic Research*, No. 8.025.
- Gradojevic, N.; Yang, J. (2000). "The Application of Artificial Neural Networks to Exchange Rate Forecasting: The Role of Market Microstructure Variables", en Working Paper, *Bank of Canada*, No. 2000-23.
- Granger, C. W. J.; Terasvirta, T. (1993). *Modelling Nonlinear Economic Relationships*, Advanced Texts in Econometrics, Oxford University Press.
- Hallman, J.; Porter, R.; Small, D. (1989). "M per Unit of Potential GNP as an anchor for the Price Level", en Staff Study 157, *Board of Governors of the Federal Reserve System*.
- \_\_\_\_\_, \_\_\_\_\_, \_\_\_\_\_ (1991). "Is the Price Level Tied to the M2 Monetary Aggregate in the Long Run", en *American Economic Review*, Vol. 81, No. 4.
- Hauser, A. (2001). "Money and Credit in an Inflation-Targeting Regime: The Bank of England's Quarterly Monetary Assessment", en *Monetary Analysis: Tools and Applications*, Klöckers H. y Willeke C., (eds.), European Central Bank.
- Herbrich, R.; Keilbach, M.; Graepel, T.; Bollmann, P.; K. Obermayer (1999). "Neural Networks in Economics: Background, Applications and New Developments", en *Technische Universität Berlin*.
- Jalil, M.; Melo, L. F. (2000). "Una relación no lineal entre la inflación y los medios de pago", en Borradores de Economía, *Banco de la República*, No. 145.
- Klerfors, D. (1998). "Artificial Neural Networks: What are they?, How do they Work?, In what areas are they used?", Saint Louis University, School of Business & Administration.
- Kuan, C. M.; White, H. (1994). "Artificial Neural Networks: An Econometric Perspective", en *Econometric Reviews*, No. 13.

- Laidler, D. (1993). *The Demand for Money: Theories, Evidence and Problems*, Harper Collins, New York, N. Y.
- Lee, T. H.; White, H.; Granger, C. W. J. (1993). "Testing for neglected nonlinearity in time series models", en *Journal of Econometrics*, No. 56.
- Levin, A.; Leen, T.; Moody, J. (1994). "Fast Pruning Using Principal Components", en *Advances in Neural Information Processing* No. 6, Cowan, J.; Tesauro, G.; Alspector, J. (eds.), Morgan Kaufmann, San Mateo, CA.
- López, E.; Misas, M. (1998). "Un examen empírico de la curva de Phillips en Colombia", en *Ensayos sobre Política Económica*, Banco de la República, No. 34.
- Lütkepohl, H.; Teräsvirta, T.; Wolters, J. (1999). "Investigating Stability and Linearity of a German M1 Money Demand Function", en *Journal of Applied Econometrics*, Vol. 14, No. 5.
- Makridakis, S.; Wheelwright, S. (1989). *Manual de técnicas de pronóstico*, Editorial Limusa.
- Masuch, K.; Pill, H.; Willeke, C. (2001). "Framework and Tools of Monetary Analysis", en *Monetary Analysis: Tools and Applications*, Klöckers, H.; Willeke, C. (eds.), Banco Central Europeo.
- Medeiros, M.; Veiga, A.; Pedreira, C. (2001). "Modelling Exchange Rates: Smooth Transitions, Neural Networks, and Linear Models", en Departamento de Economía de la Pontificia Universidad de Río de Janeiro.
- Misas, M., López, E.; Melo, L. F. (1999). "La inflación desde una perspectiva monetaria: un modelo P\* para Colombia", en *Ensayos sobre Política Económica*, Banco de la República, No. 35.
- Moody, J. (1994). "Prediction Risk and Architecture Selection for Neural Networks", en *Statistics to Neural Networks: Theory and Pattern Recognition Applications*, NATO ASI Series F, Springer-Verlag.
- \_\_\_\_\_ (1995). "Economic Forecasting: Challenges and Neural Network Solutions", en *International Symposium on Artificial Neural Networks*, Taiwan.
- \_\_\_\_\_; Levin, U.; Rehfuss, S. (1993). "Predicting the U. S. Index of Industrial Production", en *Appears in Proceedings of Parallel Applications in Statistic and Economics*, Special Issue of neural Network World, Vol. 3, No. 6.

- \_\_\_\_\_; Utans, J. (1991). "Principled Architecture Selection for Neural Networks: Application to Corporate Bond Rating Prediction", en *Advances in Neural Information Processing Systems*, No. 4, Morgan Kaufmann Publishers, San Mateo, CA.
- Morgan, D. P. (1993). "Asymmetric Effects of Monetary Policy", en *Economic Review*, Federal Reserve Bank of Kansas City, No. 78.
- Moshiri, S.; Cameron, N. (1998). "Neural Networks vs. Econometric Models in Forecasting Inflation", Department of Economics, *University of Manitoba*.
- Nicoletti Altimari S. (2001). "Does Money Lead Inflation in the Euro Area", en WP-No. 63, Working Papers Series, *Banco Central Europeo*.
- Orphanides A.; Porter, R. (2001). "Money and Inflation the Role of Information Regarding the Determination of M2 Behaviour", en *Monetary Analysis: Tools and Applications*, Klöckers, H.; Willeke, C. (eds.), *Banco Central Europeo*.
- Pill, H. (2001). "Monetary Analysis: Tools and Applications", en *Monetary Analysis: Tools and Applications*, Klöckers, H.; Willeke, C. (eds.), *Banco Central Europeo*.
- Plummer, E. (2000). "Time Series Forecasting with Feed-Forward Neural Networks: Guidelines and Limitations", Department of Computer Science, Graduate School of The University of Wyoming.
- Rhee, W.; Rich, R. W. (1995). "Term Structure Forecasts of Inflation", en *Economic Journal*, No. 102.
- Ricketts, N.; Rose, D. (1995). "Inflation, Learning and Monetary Policy in the G7 economies", en Working Paper, *Bank of Canada*, pp. 95-7.
- Pindyck, R.; Rubinfeld, D. (1997). *Econometric Models and Economic Forecasts*, McGraw-Hill International Editions, 4<sup>a</sup>. ed.
- Soto R. (1997). "Non-linearities in the Demand for Money: A Neural Network Approach", en Documento de Investigación, *Ilades/Georgetown University*, No. 107.
- Swanson, N. R.; White, H. (1995). "A Model-Selection Approach to Assessing the Information in the Term Structure Using Linear Models and Artificial Neural Networks", en *Journal of Business & Economic Statistics*, Vol. 13, No .3.



\_\_\_\_\_, \_\_\_\_\_ (1997a). "A model Selection Approach to Real-Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks", en *The Review of Economics and Statistics*, No. 79.

\_\_\_\_\_, \_\_\_\_\_ (1997 b). "Forecasting economic time series using flexible versus fixed specification and linear versus nonlinear econometric models", en *International Journal of Forecasting*, No. 13.

Svensson, Lars (1999). "Monetary Policy Issues for the Eurosystem", en *Carnegie-Rochester Conferences Series on Public Policy*, No. 71, pp. 79-136, marzo.

Tkacz, G. (2000). "Non-Parametric and Neural Networks Models of Inflation Changes", en Working Paper, *Bank of Canada*, 2000-7.

Tkacz, G.; Hu, S. (1999). "Forecasting GDP Growth Using Artificial Neural Networks", en Working Paper, *Bank of Canada*, pp. 99-3.

**ANEXO 1**

Cuadro 1  
Evaluación de la red neuronal dentro de muestra: modelo 1  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$$

<i>Inputs</i>	<i>Q</i>	<i>AIC</i>	<i>BIC</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>
$X_t$	0	-0,5207	-0,4208	0,7425	8,8670	0,5547	2,3881	80,1887
	1	-0,5601	-0,4852	0,7348	8,0033	0,5489	2,4358	80,1887
$X_t$	2	-0,5289	-0,3790	0,7258	7,8699	0,5401	2,3363	81,1321
$Z_t = \{y_{t-2}\}$	3	-0,4896	-0,2647	0,7197	9,2940	0,5303	2,4657	83,9623
	4	-0,4424	-0,1426	0,7165	10,8654	0,5253	2,7302	83,9623
	1	-0,6142	-0,5143	0,7086	10,9761	0,5370	3,1547	79,2453
$X_t$	2	-0,5891	-0,3892	0,6912	9,2798	0,5284	2,8439	82,0755
$Z_t = \{y_{t-2}, y_{t-4}\}$	3	-0,6018	-0,3021	0,6616	11,8206	0,5029	3,3014	80,1887
	4	-0,8152	-0,4155	0,5729	8,2815	0,4337	2,1901	83,9623
	1	-0,6052	-0,4803	0,7051	11,7873	0,5293	2,8649	81,1321
$X_t$	2	-0,7547	-0,5049	0,6245	7,5984	0,4845	2,0646	81,1321
$Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	3	-0,8857	-0,5110	0,5582	9,7283	0,4324	2,8461	81,1321
	4	-0,9491	-0,4495	0,5161	6,3064	0,3863	2,0763	83,0189

Cuadro 1A  
Evaluación de la red neuronal fuera de muestra: modelo 1  
1969:02 - 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	1,1193	3,4192	0,9986	1,9075	84,6154	0,4368
	1	1,2038	3,3321	1,0883	1,9663	84,6154	0,4256
$X_t$	2	1,1918	3,4899	1,0841	2,0428	100,0000	0,4458
$Z_t = \{y_{t-2}\}$	3	1,1729	3,5078	1,0475	1,9601	100,0000	0,4481
	4	1,0376	4,2706	0,9565	2,2729	100,0000	0,5455
	1	1,1057	4,1373	0,9473	2,2236	76,9231	0,5285
$X_t$	2	1,0914	2,6964	0,9599	1,6207	76,9231	0,3444
$Z_t = \{y_{t-2}, y_{t-4}\}$	3	1,6855	3,1905	1,3024	2,0149	38,4615	0,4075
	4	0,9790	3,0070	0,8586	1,5474	84,6154	0,3841
	1	1,1372	4,5496	0,9571	2,4278	76,9231	0,5811
$X_t$	2	1,0808	2,7868	0,9560	1,6487	92,3077	0,3560
$Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	3	1,1544	3,6217	1,0362	2,0098	76,9231	0,4626
	4	1,2595	1,3902	1,0392	1,1312	53,8462	0,1776

Cuadro 2  
Evaluación de la red neuronal dentro de muestra: modelo 1  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,5079	-0,4124	0,7492	25,0201	0,5561	4,1579	81,5789
	1	-0,5530	-0,4814	0,7389	18,0961	0,5503	3,6112	79,8246
$X_t$	2	-0,5341	-0,3909	0,7267	15,8042	0,5378	3,4644	81,5789
$Z_t = \{y_{t-2}\}$	3	-0,5168	-0,3020	0,7141	17,0295	0,5261	3,6196	84,2105
	4	-0,4789	-0,1925	0,7091	15,6497	0,5163	3,4573	84,2105
	1	-0,6319	-0,5364	0,7042	21,1881	0,5359	4,5703	78,9474
$X_t$	2	-0,5837	-0,3928	0,6967	18,7814	0,5237	4,3199	80,7018
$Z_t = \{y_{t-2}, y_{t-4}\}$	3	-0,7488	-0,4623	0,6196	24,6474	0,4736	3,8286	84,2105
	4	-0,8149	-0,4330	0,5789	22,6112	0,4507	3,7354	81,5789
	1	-0,6205	-0,5011	0,7021	20,4006	0,5274	4,2705	83,3333
$X_t$	2	-0,8141	-0,5754	0,6102	19,4882	0,4614	3,3204	78,0702
$Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	3	-0,6896	-0,3315	0,6217	15,2846	0,4783	3,8174	83,3333
	4	-0,8834	-0,4060	0,5403	6,5983	0,4182	1,9970	85,9649

Cuadro 2A  
Evaluación de la red neuronal fuera de muestra: modelo 1  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$$

<i>Inputs</i>	<i>Q</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>	<i>U-THEIL</i>	
$X_t$	0	0,8252	1,8791	0,7751	1,4616	100,0000	0,3795	
	1	0,7567	1,1981	0,6947	1,0053	100,0000	0,2420	
	$X_t$ $Z_t = \{y_{t-2}\}$	2	0,7226	1,2408	0,6543	0,9207	80,0000	0,2506
		3	0,7515	1,4800	0,6851	1,0291	80,0000	0,2989
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}\}$	4	0,7286	1,4044	0,6638	0,9891	100,0000	0,2836	
	1	0,7291	1,9929	0,6870	1,4754	100,0000	0,4025	
	2	0,6698	1,6579	0,6173	1,2408	80,0000	0,3348	
	3	0,7541	1,1050	0,6813	0,9756	100,0000	0,2232	
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	4	0,6439	1,0220	0,5900	0,8854	100,0000	0,2064	
	1	0,6746	2,0899	0,6226	1,4874	100,0000	0,4221	
	2	0,9689	1,9668	0,8362	1,5462	100,0000	0,3972	
	3	0,9308	3,7951	0,7758	1,9457	80,0000	0,7665	
4	1,0971	2,1748	0,9661	1,6824	80,0000	0,4392		

Cuadro 3  
Evaluación de la red neuronal dentro de muestra: modelo 2  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMI_t^*$$

$$X_t = \{m_{t-1}, m_{t-2}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,6035	-0,5318	0,7137	4,5009	0,5415	1,8800	77,0642
	1	-0,5852	-0,5127	0,7268	6,5148	0,5399	2,1174	78,5714
$X_t$	2	-0,5734	-0,4286	0,7119	7,5537	0,5361	2,2302	77,6786
$Z_t = \{m_{t-1}\}$	3	-0,5511	-0,3338	0,7010	8,5148	0,5160	2,3097	78,5714
	4	-0,5228	-0,2332	0,6924	7,8720	0,5092	2,2169	77,6786
	1	-0,7349	-0,6383	0,6684	6,7338	0,5206	2,1327	76,7857
$X_t$	2	-0,7990	-0,6059	0,6248	7,4446	0,4893	2,2671	78,5714
$Z_t = \{m_{t-1}, m_{t-2}\}$	3	-0,8840	-0,5944	0,5780	6,1407	0,4544	2,1174	79,4643
	4	-0,9034	-0,5172	0,5525	7,3827	0,4427	2,2256	79,4643

Cuadro 3A  
Evaluación de la red neuronal dentro de muestra: modelo 2  
1969:02 - 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMI_t^*$$

$$X_t = \{m_{t-1}, m_{t-2}\}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	1,1159	4,9296	0,9289	2,8071	100,0000	0,6297
	1	1,1698	5,7603	0,9573	2,9766	100,0000	0,9718
$X_t$	2	1,1625	5,8963	0,9419	3,0069	100,0000	0,9657
$Z_t = \{m_{t-1}\}$	3	1,1788	6,2891	0,9615	3,4235	100,0000	0,9792
	4	1,1854	6,3972	0,9955	3,1691	100,0000	0,9847
	1	1,1482	5,7500	0,9718	2,8953	100,0000	0,9538
$X_t$	2	1,7271	5,2579	1,2820	2,9947	92,3077	1,4347
$Z_t = \{m_{t-1}, m_{t-2}\}$	3	1,1064	5,6706	0,9375	3,0097	100,0000	0,9191
	4	1,4015	11,5745	1,1693	4,7926	92,3077	1,1643

Cuadro 4  
Evaluación de la red neuronal dentro de muestra: modelo 2  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM1_t^*$$

$$X_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,6462	-0,5757	0,7057	4,3544	0,5389	1,8465	78,6325
	1	-0,6918	-0,6213	0,6898	28,5850	0,5182	4,2404	79,4872
$X_t$	2	-0,6691	-0,5282	0,6802	27,1352	0,5137	4,0869	77,7778
$Z_t = \{m_{t-1}\}$	3	-0,6481	-0,4368	0,6701	28,5232	0,5014	4,4355	77,7778
	4	-0,6135	-0,3318	0,6647	28,0877	0,4859	4,2442	78,6325
	1	-0,7774	-0,6834	0,6554	16,1416	0,4872	3,6844	79,4872
$X_t$	2	-0,8407	-0,6529	0,6138	27,1769	0,4771	4,0232	80,3419
$Z_t = \{m_{t-1}, m_{t-2}\}$	3	-0,8715	-0,5898	0,5842	15,9586	0,4486	3,5025	80,3419
	4	-0,8132	-0,4375	0,5815	17,7798	0,4477	3,4436	80,3419
	1	-0,7682	-0,6508	0,6528	28,3387	0,4926	4,1935	80,3419
$X_t$	2	-0,8511	-0,6163	0,6003	22,5813	0,4611	3,6086	79,4872
$Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$	3	-0,9343	-0,5821	0,5520	27,2421	0,4387	3,9898	80,3419
	4	-0,9750	-0,5054	0,5184	6,8500	0,3881	1,8350	78,6325



Cuadro 4A  
Evaluación de la red neuronal dentro de muestra: modelo 2  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMI_t^*$$

$$X_t = \{ m_{t-1}, m_{t-2}, m_{t-3} \}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	1,4427	5,6104	1,3969	3,7558	100,0000	1,1331
	1	1,4814	5,5623	1,4311	3,7559	100,0000	1,3050
$X_t$	2	1,4385	5,4389	1,3919	3,6699	100,0000	1,2672
	$Z_t = \{m_{t-1}\}$	3	1,5021	5,5483	1,4401	3,7618	100,0000
4		1,5128	5,7463	1,4174	3,8567	100,0000	1,3326
$X_t$	1	1,4584	5,6363	1,4063	3,7589	100,0000	1,2847
	2	1,4300	5,2416	1,3936	3,5893	100,0000	1,2597
$Z_t = \{m_{t-1}, m_{t-2}\}$	3	1,4505	5,5288	1,4125	3,7376	100,0000	1,2777
	4	1,0260	3,3534	0,8914	2,0796	80,0000	0,9038
$X_t$	1	1,3975	4,7008	1,3492	3,2807	100,0000	1,2310
	2	1,2274	4,6343	1,0823	3,0558	80,0000	1,0812
$Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$	3	1,3699	5,5559	1,3187	3,6384	80,0000	1,2067
	4	1,2237	5,6798	1,1682	3,6546	80	1,0780

Cuadro 5  
Evaluación de la red neuronal dentro de muestra: modelo 3  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM3_t^*$$

$$X_t = \{ m_{t-1}, m_{t-2}, m_{t-3}, m_{t-3} \}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,2935	-0,1953	0,8327	7,6428	0,6258	2,1332	65,1376
$X_t$ $Z_t = \{m_{t-1}\}$	1	-0,3729	-0,2992	0,8076	5,7700	0,6025	1,9319	74,3119
	2	-0,3839	-0,2366	0,7815	5,8149	0,5781	1,8812	71,5596
	3	-0,3320	-0,1110	0,7805	6,5083	0,5770	1,9582	69,7248
	4	-0,3482	-0,0536	0,7534	5,9897	0,5547	1,9391	73,3945
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}\}$	1	-0,3552	-0,2570	0,8074	6,2892	0,6069	2,1164	71,5596
	2	-0,4267	-0,2303	0,7512	5,9954	0,5675	1,8423	73,3945
	3	-0,5189	-0,2243	0,6917	5,2377	0,5158	1,7438	77,0642
	4	-0,5061	-0,1133	0,6713	6,2590	0,4983	1,9671	77,0642
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$	1	-0,4589	-0,3361	0,7597	6,5113	0,5866	2,2672	74,3119
	2	-0,5113	-0,2658	0,7071	3,2931	0,5123	1,4464	76,1468
	3	-0,6490	-0,2807	0,6307	5,2259	0,4636	1,9516	78,8991
	4	-0,5882	-0,0972	0,6213	7,3041	0,4562	2,3449	76,1468
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}, m_{t-3}\}$	1	-0,4978	-0,3505	0,7383	7,6244	0,5764	2,5946	74,3119
	2	-0,4988	-0,2042	0,6987	4,5141	0,5553	1,9126	74,3119
	3	-0,5176	-0,0757	0,6555	2,4067	0,4873	1,2163	77,9817
	4	-0,5986	-0,0094	0,5960	11,5622	0,4529	2,4795	73,3945

Cuadro 5A  
Evaluación de la red neuronal dentro de muestra: modelo 3  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM3_t^*$$

$$X_t = \{m_{t-1}, m_{t-2}, m_{t-3}, m_{t-5}\}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	0,5558	1,8394	0,5071	1,0988	92,3077	0,2350
$X_t$ $Z_t = \{m_{t-1}\}$	1	0,7160	2,2485	0,6427	1,3158	84,6154	0,5947
	2	0,6671	2,3326	0,6079	1,3263	84,6154	0,5542
	3	0,6620	2,1902	0,5989	1,2648	84,6154	0,5499
	4	0,7573	2,0390	0,6681	1,2309	84,6154	0,6291
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}\}$	1	0,6215	2,5240	0,5535	1,2438	84,6154	0,5163
	2	0,5524	3,3601	0,4950	1,6386	84,6154	0,4589
	3	0,7341	2,3146	0,6571	1,3441	76,9231	0,6098
	4	1,7368	3,7251	0,9209	1,9896	76,9231	1,4428
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$	1	0,5893	5,1514	0,4442	2,2856	84,6154	0,4896
	2	0,6206	1,1931	0,5259	0,8590	84,6154	0,5155
	3	0,4607	3,2021	0,3794	1,5265	100,0000	0,3827
	4	0,5417	3,4494	0,4241	1,7065	76,9231	0,4500
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}, m_{t-5}\}$	1	0,6167	4,9076	0,4787	2,2558	76,9231	0,5123
	2	0,6240	4,6766	0,5074	2,1795	100,0000	0,5183
	3	0,8668	8,4975	0,7987	3,2762	61,5385	0,7201
	4	0,5588	2,4812	0,4699	1,1735	76,9231	0,4642

Cuadro 6  
Evaluación de la red neuronal dentro de muestra: modelo 3  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM3_t^*$$

$$X_t = \{m_{t-1}, m_{t-2}, m_{t-3}, m_{t-5}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,371	-0,277	0,803	12,968	0,607	2,989	66,67
$X_t$ $Z_t = \{m_{t-1}\}$	1	-0,435	-0,364	0,784	14,596	0,590	3,021	72,65
	2	-0,453	-0,312	0,758	15,545	0,566	3,115	71,79
	3	-0,413	-0,201	0,754	13,129	0,562	2,789	70,94
	4	-0,362	-0,080	0,754	13,734	0,560	2,869	72,65
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}\}$	1	-0,441	-0,347	0,775	6,799	0,583	2,083	71,79
	2	-0,511	-0,323	0,724	19,887	0,545	3,213	72,65
	3	-0,517	-0,235	0,698	21,300	0,528	3,309	77,78
	4	-0,467	-0,091	0,691	6,031	0,519	1,879	72,65
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$	1	-0,548	-0,430	0,729	26,279	0,555	4,286	74,36
	2	-0,526	-0,291	0,706	26,579	0,532	4,170	76,07
	3	-0,677	-0,325	0,628	19,341	0,470	3,015	75,21
	4	-0,685	-0,216	0,599	13,722	0,446	3,221	78,63
$X_t$ $Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}, m_{t-5}\}$	1	-0,535	-0,394	0,727	22,039	0,565	3,837	70,09
	2	-0,582	-0,300	0,675	4,688	0,500	1,638	72,65
	3	-0,616	-0,193	0,631	4,098	0,472	1,773	74,36
	4	-0,748	-0,185	0,561	11,980	0,430	3,050	80,34

Cuadro 6A  
Evaluación de la red neuronal dentro de muestra: modelo 3  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM3_t^*$$

$$X_t = \{ m_{t-1}, m_{t-2}, m_{t-3}, m_{t-5} \}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	0,400	1,820	0,321	0,966	100,00	0,368
$X_t$	1	0,554	2,257	0,484	1,355	80,00	0,488
	2	0,513	2,161	0,439	1,274	100,00	0,452
$Z_t = \{m_{t-1}\}$	3	0,370	1,900	0,254	0,989	100,00	0,326
	4	3,209	3,132	1,602	2,055	80,00	2,827
$X_t$	1	0,416	1,160	0,396	0,844	100,00	0,366
	2	0,578	2,923	0,484	1,698	80,00	0,509
$Z_t = \{m_{t-1}, m_{t-2}\}$	3	0,588	2,904	0,510	1,713	80,00	0,518
	4	1,434	8,091	0,838	3,819	80,00	1,263
$X_t$	1	0,733	3,615	0,615	2,175	100,00	0,646
	2	0,690	3,721	0,523	2,178	80,00	0,608
$Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}\}$	3	0,555	2,122	0,527	1,362	100,00	0,489
	4	0,405	1,436	0,297	0,807	100,00	0,357
$X_t$	1	0,869	4,062	0,772	2,498	100,00	0,765
	2	0,786	4,049	0,647	2,498	60,00	0,693
$Z_t = \{m_{t-1}, m_{t-2}, m_{t-3}, m_{t-5}\}$	3	0,655	2,713	0,604	1,746	60,00	0,577
	4	0,825	4,421	0,658	2,657	60,00	0,727

Cuadro 7

Evaluación de la red neuronal dentro de muestra: modelo 4  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMI_t^*$$

$$X_t = \{y_{t-2}, y_{t-8}, m_{t-1}, m_{t-2}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,6776	-0,5777	0,6865	5,6872	0,5020	2,1233	80,1887
$X_t$ $Z_t = \{y_{t-2}\}$	1	-0,7337	-0,6588	0,6738	5,9158	0,4886	2,1419	79,2453
	2	-0,7205	-0,5706	0,6595	4,5781	0,4866	1,9368	83,0189
	3	-0,6834	-0,4586	0,6532	5,4526	0,4869	2,1059	82,0755
	4	-0,6596	-0,3598	0,6428	4,6836	0,4616	1,8531	84,9057
$X_t$ $Z_t = \{y_{t-2}, y_{t-8}\}$	1	-0,7462	-0,6463	0,6633	5,4814	0,4898	2,0322	79,2453
	2	-0,7070	-0,5071	0,6517	5,0829	0,4706	1,9039	79,2453
	3	-0,8037	-0,5039	0,5981	7,2091	0,4381	2,3897	83,9623
	4	-0,6886	-0,3888	0,6335	5,8688	0,4737	1,9358	83,0189
$X_t$ $Z_t = \{y_{t-2}, y_{t-8}, m_{t-1}\}$	1	-0,7505	-0,6256	0,6557	5,5065	0,4703	2,1416	81,1321
	2	-0,7645	-0,5147	0,6215	6,3598	0,4483	2,1867	84,9057
	3	-0,8439	-0,4693	0,5700	11,3043	0,4288	2,9172	82,0755
	4	-1,0027	-0,5031	0,5024	2,2839	0,3795	1,1833	84,9057
$X_t$ $Z_t = \{y_{t-2}, y_{t-8}, m_{t-1}, m_{t-2}\}$	1	-0,7986	-0,6488	0,6342	4,1588	0,4589	1,7491	80,1887
	2	-0,9049	-0,6051	0,5686	7,1340	0,4359	2,0057	80,1887
	3	-0,9487	-0,4991	0,5259	9,8449	0,3964	2,6259	81,1321
	4	-1,0897	-0,4902	0,4634	7,4156	0,3596	1,8377	81,1321

Cuadro 7A  
Evaluación de la red neuronal dentro de muestra: modelo 4  
1969:02 – 1997:04

**Modelo general:**

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$


---

$y_t = \Delta LIPC_t$

$m_t = \Delta LMI_t$

$X_t = \{y_{t-2}, y_{t-8}, m_{t-1}, m_{t-2}\}$

---

<i>Inputs</i>	<i>Q</i>	<i>RMSE</i>	<i>RMSPE</i>	<i>MAE</i>	<i>MAPE</i>	<i>SR</i>	<i>U-THEIL</i>
$X_t$	0	1,0685	5,8738	0,9132	3,1183	100,0000	0,7503
$X_t$ $Z_t = \{y_{t-2}\}$	1	1,0525	5,5035	0,8963	2,9823	100,0000	0,7030
	2	1,0813	7,2215	0,9253	3,5553	100,0000	0,9225
	3	1,0174	6,3747	0,8639	3,2673	100,0000	0,8143
	4	1,2379	6,8298	0,9984	3,4866	100,0000	0,8724
$X_t$ $Z_t = \{y_{t-2}, y_{t-8}\}$	1	1,0002	6,0665	0,8556	3,1317	100,0000	0,7749
	2	0,9963	5,6594	0,8469	2,9839	100,0000	0,7229
	3	1,1122	5,5692	0,9232	3,0145	100,0000	0,7114
	4	1,1997	6,6676	0,9857	3,4128	69,2308	0,8517
$X_t$ $Z_t = \{y_{t-2}, y_{t-8}, m_{t-1}\}$	1	1,0549	4,8970	0,9015	2,7622	100,0000	0,6255
	2	1,1341	5,7475	0,9251	3,1449	100,0000	0,7342
	3	3,5696	4,2586	1,7762	2,7133	76,9231	0,5440
	4	0,8108	3,9655	0,7030	2,0295	100,0000	0,5065
$X_t$ $Z_t = \{y_{t-2}, y_{t-8}, m_{t-1}, m_{t-2}\}$	1	1,1798	6,6500	1,0446	3,2796	100,0000	0,8494
	2	1,2743	8,2147	1,0433	3,6678	100,0000	1,0493
	3	1,1425	5,7102	0,9380	3,0987	100,0000	0,7294
	4	0,9035	3,3191	0,8116	1,7446	100,0000	0,4240

Cuadro 8  
Evaluación de la red neuronal dentro de muestra: modelo 4  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMI_t^*$$

$$X_t = \{y_{t-1}, y_{t-8}, m_{t-1}, m_{t-2}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,7176	-0,5983	0,6688	17,4226	0,4851	3,7016	79,8246
$X_t$ $Z_t = \{y_{t-1}\}$	1	-0,8322	-0,7606	0,6426	16,5296	0,4685	3,7111	78,0702
	2	-0,9252	-0,7820	0,5976	8,5668	0,4463	2,3106	78,0702
	3	-0,8887	-0,6739	0,5930	4,6121	0,4470	1,7833	78,9474
	4	-0,8881	-0,6017	0,5779	7,4661	0,4359	2,1861	80,7018
$X_t$ $Z_t = \{y_{t-1}, y_{t-8}\}$	1	-0,8185	-0,7230	0,6415	14,1471	0,4707	3,6363	82,4561
	2	-0,8958	-0,7048	0,5960	7,9442	0,4438	2,1975	78,0702
	3	-1,0931	-0,8067	0,5216	9,7241	0,4073	2,6986	80,7018
	4	-1,1300	-0,7481	0,4945	11,5594	0,3788	2,5935	78,9474
$X_t$ $Z_t = \{y_{t-1}, y_{t-8}, m_{t-1}\}$	1	-0,8505	-0,7311	0,6258	16,4857	0,4504	3,7547	78,9474
	2	-0,9761	-0,7374	0,5627	9,9525	0,4133	2,5861	78,9474
	3	-0,9571	-0,5991	0,5439	14,7626	0,4079	3,6528	76,3158
	4	-1,0908	-0,6134	0,4871	4,6424	0,3509	1,4633	79,8246
$X_t$ $Z_t = \{y_{t-1}, y_{t-8}, m_{t-1}, m_{t-2}\}$	1	-0,8826	-0,7394	0,6105	19,3160	0,4649	4,0556	80,7018
	2	-0,9559	-0,6695	0,5586	27,9471	0,4326	4,7221	82,4561
	3	-1,1502	-0,7205	0,4811	23,4688	0,3792	4,4244	83,3333
	4	-1,1408	-0,5680	0,4588	12,3336	0,3517	2,9655	85,9649



Cuadro 8A  
Evaluación de la red neuronal dentro de muestra: modelo 4  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMI_t^*$$

$$X_t = \{y_{t-1}, y_{t-8}, m_{t-1}, m_{t-2}\}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	1,1395	5,6767	0,9405	3,4430	80,0000	1,1465
$X_t$ $Z_t = \{y_{t-1}\}$	1	1,3956	4,7374	1,3149	3,3061	100,0000	0,9568
	2	1,2335	4,1654	1,1684	2,8985	100,0000	0,8413
	3	1,2635	3,8758	1,1735	2,7026	100,0000	0,7828
	4	1,2294	3,9986	1,1633	2,8111	100,0000	0,8076
$X_t$ $Z_t = \{y_{t-1}, y_{t-8}\}$	1	1,3130	3,7239	1,2241	2,7076	100,0000	0,7521
	2	1,2399	4,0908	1,1822	2,8717	100,0000	0,8262
	3	1,4851	3,9920	1,3314	2,9117	80,0000	0,8063
	4	1,4196	5,3194	1,3184	3,6092	100,0000	1,0744
$X_t$ $Z_t = \{y_{t-1}, y_{t-8}, m_{t-1}\}$	1	1,3791	4,5960	1,2986	3,2227	100,0000	0,9283
	2	1,2703	4,2585	1,1943	2,9682	100,0000	0,8601
	3	1,6135	4,9487	1,5178	3,5078	80,0000	0,9995
	4	1,4400	5,2996	1,3470	3,5471	80,0000	1,0704
$X_t$ $Z_t = \{y_{t-1}, y_{t-8}, m_{t-1}, m_{t-2}\}$	1	1,0096	4,7869	0,9274	3,0704	100,0000	0,9668
	2	1,2491	4,3763	1,1218	2,9672	100,0000	0,8839
	3	1,0468	4,6304	0,8695	2,5427	80,0000	0,9352
	4	1,0773	4,4930	0,9330	2,6742	80,0000	0,9074

Cuadro 9  
Evaluación de la red neuronal dentro de muestra: modelo 5  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM3_t^*$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,5798	-0,4799	0,7209	5,6904	0,5238	1,9558	81,1321
$X_t$ $Z_t = \{y_{t-2}\}$	1	0,7119	0,7868	1,3880	12,4324	1,1628	3,7598	29,2453
	2	0,7341	0,8839	1,3647	12,4119	1,1383	3,6724	30,1887
	3	0,7394	0,9642	1,3305	11,3499	1,1083	3,4700	32,0755
	4	0,7415	1,0413	1,2951	9,9993	1,0659	3,2252	33,9623
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}\}$	1	-0,2781	-0,1782	0,8382	6,7910	0,6401	2,1638	66,9811
	2	0,1570	0,3569	1,0038	6,5523	0,8303	2,5777	55,6604
	3	0,3238	0,6235	1,0510	9,2730	0,8477	2,9594	48,1132
	4	0,5428	0,9425	1,1296	13,5578	0,9131	3,8295	41,5094
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	1	-0,2765	-0,1516	0,8311	7,1640	0,6351	2,2572	68,8679
	2	0,0615	0,3113	0,9392	5,4591	0,7431	2,0090	56,6038
	3	-0,3891	-0,0144	0,7155	6,7607	0,5806	1,9689	78,3019
	4	0,0423	0,5419	0,8472	9,2330	0,6856	2,8585	61,3208
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}\}$	1	-0,2656	-0,1158	0,8279	5,7338	0,6524	2,1107	71,6981
	2	0,0002	0,3000	0,8940	5,5612	0,7089	2,0477	56,6038
	3	-0,3912	0,0584	0,6950	8,5849	0,5253	2,6131	78,3019
	4	-0,2858	0,3137	0,6927	7,3999	0,5558	2,2812	66,9811

Cuadro 9A  
Evaluación de la red neuronal dentro de muestra: modelo 5  
1969:02 – 1997:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t$$

$$m_t = \Delta LM3_t$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}\}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	0,8622	2,9610	0,7875	1,6881	84,6154	0,3782
$X_t$ $Z_t = \{y_{t-2}\}$	1	0,9557	4,1363	0,8811	2,0752	38,4615	0,5284
	2	0,9345	3,8224	0,8546	1,9166	53,8462	0,4883
	3	0,9523	4,5127	0,8905	2,2039	46,1538	0,5764
	4	0,9377	2,9497	0,8573	1,6475	61,5385	0,3768
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}\}$	1	0,8043	1,3527	0,7214	1,0296	76,9231	0,1728
	2	1,0437	5,4534	0,9087	2,1520	53,8462	0,6966
	3	1,3704	3,0135	1,2610	2,0773	61,5385	0,3849
	4	1,0126	4,3880	0,9804	2,4161	46,1538	0,5605
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	1	0,8376	1,4521	0,7521	1,0857	76,9231	0,1855
	2	0,8933	1,0983	0,7830	0,9617	61,5385	0,1403
	3	1,0228	1,4296	0,8617	1,0706	76,9231	0,1826
	4	1,1907	9,5047	1,1319	4,1412	38,4615	1,2141
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}\}$	1	1,1707	1,6526	1,0478	1,3962	69,2308	0,2111
	2	2,0704	1,7678	1,2369	1,3211	61,5385	0,2258
	3	1,1869	2,6666	1,0267	1,6159	69,2308	0,3406
	4	1,0224	1,2566	0,9044	1,0854	53,8462	0,1605

Cuadro 10  
Evaluación de la red neuronal dentro de muestra: modelo 5  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LM3_t^*$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}, m_{t-2}\}$$

Inputs	Q	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR
$X_t$	0	-0,6284	-0,4852	0,6933	10,5464	0,5099	2,6813	83,3333
$X_t$ $Z_t = \{y_{t-2}\}$	1	-0,6986	-0,6270	0,6870	9,9896	0,5055	2,6830	83,3333
	2	-0,6660	-0,5227	0,6803	12,8556	0,5028	3,0454	84,2105
	3	-0,6281	-0,4133	0,6755	10,8271	0,4990	2,8204	85,0877
	4	-0,5937	-0,3073	0,6695	9,0988	0,4879	2,5028	85,0877
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}\}$	1	-0,7871	-0,6916	0,6516	11,7115	0,4828	3,0785	80,7018
	2	-0,7967	-0,6057	0,6263	15,4645	0,4719	3,6573	81,5789
	3	-0,9087	-0,6222	0,5720	14,8434	0,4282	3,1173	84,2105
	4	-0,8110	-0,4291	0,5800	7,7694	0,4208	1,8281	84,2105
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	1	-0,8044	-0,6851	0,6404	12,5409	0,4911	3,2908	83,3333
	2	-0,8231	-0,5844	0,6074	6,1237	0,4514	1,8657	82,4561
	3	-0,8916	-0,5336	0,5620	7,1244	0,4339	2,3678	85,0877
	4	-0,8940	-0,4166	0,5374	6,3384	0,4001	2,0966	84,2105
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}\}$	1	-0,8058	-0,6626	0,6344	12,8441	0,4797	3,2731	83,3333
	2	-0,8660	-0,5796	0,5843	12,6014	0,4533	3,1363	85,9649
	3	-0,9282	-0,4986	0,5376	20,1254	0,4102	3,9495	83,3333
	4	-1,1852	-0,6123	0,4488	16,1427	0,3279	3,3875	78,0702
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}, m_{t-2}\}$	1	-0,7786	-0,6115	0,6375	16,2655	0,4754	3,5016	83,3333
	2	-1,0437	-0,7096	0,5254	12,8725	0,3921	2,7820	85,0877
	3	-1,0597	-0,5585	0,4904	11,4929	0,3755	2,3584	85,0877
	4	-1,3126	-0,6442	0,4067	13,5146	0,3107	2,4637	79,8246

Cuadro 10A

Evaluación de la red neuronal dentro de muestra: modelo 5  
1969:02 – 1999:04

Modelo general:

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t$$

$$G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_t = \Delta LMS_t^*$$

$$X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}, m_{t-2}\}$$

Inputs	Q	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$X_t$	0	0,4429	0,8343	0,3678	0,6208	100,0000	0,1685
$X_t$ $Z_t = \{y_{t-2}\}$	1	0,3820	0,5718	0,3208	0,4376	100,0000	0,1155
	2	0,4875	1,2123	0,4112	0,8690	100,0000	0,2449
	3	0,4211	0,6646	0,3642	0,5431	100,0000	0,1342
	4	0,3911	0,4275	0,3383	0,4012	100,0000	0,0863
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}\}$	1	0,3626	1,1786	0,3076	0,8042	100,0000	0,2381
	2	0,4310	0,5464	0,3225	0,4584	100,0000	0,1104
	3	0,5827	1,3857	0,5441	1,0667	80,0000	0,2799
	4	1,4371	1,5355	0,8628	1,1846	100,0000	0,3101
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}\}$	1	0,3504	0,6583	0,2951	0,5234	100,0000	0,1330
	2	0,7217	1,7046	0,5587	1,0885	60,0000	0,3443
	3	0,4849	1,0953	0,4056	0,7123	100,0000	0,2212
	4	4,4314	3,5721	2,4632	2,3088	40,0000	0,7214
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}\}$	1	0,3135	0,6642	0,2682	0,5144	100,0000	0,1341
	2	0,6204	1,4967	0,5054	0,8893	100,0000	0,3023
	3	0,3758	1,0255	0,3560	0,7401	100,0000	0,2071
	4	0,6912	1,2948	0,5713	0,9933	80,0000	0,2615
$X_t$ $Z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{t-1}, m_{t-2}\}$	1	0,4190	0,6221	0,3533	0,5285	100,0000	0,1256
	2	1,0065	1,7483	0,8483	1,4227	80,0000	0,3531
	3	0,4922	0,6946	0,2953	0,5118	80,0000	0,1403
	4	0,9964	2,4962	0,8037	1,7648	60,0000	0,5042

**ANEXO 2<sup>1</sup>****MEDIDAS DE EVALUACIÓN DE PRONÓSTICO**

$$AIC(k) = \ln(\hat{\sigma}^2) + \frac{2k}{n}$$

$$BIC(k) = \ln(\hat{\sigma}^2) + \frac{k \ln(n)}{n}$$

$$\hat{\sigma}^2 = \frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{n}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2}$$

$$RMSPE = \sqrt{\frac{1}{n} \sum_{t=1}^n \left( \frac{\hat{y}_t - y_t}{y_t} \right)^2}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |(\hat{y}_t - y_t)|$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{(\hat{y}_t - y_t)}{y_t} \right|$$

$$U-THEIL = \sqrt{\frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{\sum_{t=1}^n (y_t - y_{t-1})^2}}$$

$$SRP = \frac{1}{n} \sum_{t=1}^n I_t[\{(y_t - y_{t-1}) \cdot (\hat{y}_t - \hat{y}_{t-1})\} > 0]$$

<sup>1</sup> Véanse, Franses y van Dick (2000), Pindyck y Rubinfeld, (1997), y Makridakis y Wheelwright (1989).

$$SRN = \frac{1}{n} \sum_{t=1}^n I_t [\{(y_t - y_{t-1}) \cdot (\hat{y}_t - \hat{y}_{t-1})\} < 0]$$

$$SR = SRP + SRN$$

donde:

$n$  es el número de observaciones consideradas

$\hat{\epsilon}_t$  residuales obtenidos a partir de la red neuronal

$k$  número de parámetros de la red neuronal

$\hat{y}_t$  valor estimado por la red neuronal.

### ANEXO 3

En este anexo se reportan los resultados de la prueba de sensibilidad de Franses y van Dijk (2000) en la cual, a diferencia de la prueba desarrollada por Draisma *et al.* (1995), se mantienen únicamente las conexiones de la variable de interés y se rompen las conexiones con las demás variables.

Cuadro 1 Análisis de sensibilidad sobre la red neuronal seleccionada: modelo 4 1969:02 – 1997:04													
$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t, \quad G(z) = (1 + \exp(-z))^{-1}$													
$y_t = \Delta LIPC_t^*$ $m_{1t} = \Delta LM1_t^*$ $Inputs: X_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}, \quad z_t = \{y_{t-2}, y_{t-8}, m_{1t-1}, m_{1t-2}\}$ $Q=4$													
Dentro de muestra							Fuera de muestra						
Única conexión	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$y_{t-2}$	0,970	1,570	1,298	23,600	0,978	5,657	61,3	1,021	2,155	0,880	1,409	46,2	0,275
$y_{t-8}$	0,874	1,474	1,237	14,102	0,981	4,768	50,9	0,964	3,860	0,925	2,120	30,8	0,493
$m_{1t-1}$	0,512	1,112	1,032	18,218	0,835	4,897	68,9	1,125	1,141	0,877	0,988	69,2	0,146
$m_{1t-2}$	1,694	2,293	1,864	44,832	1,534	12,74	51,9	2,241	7,907	1,893	4,678	46,2	1,010



Cuadro 2  
 Análisis de sensibilidad sobre la red neuronal seleccionada: modelo 5  
 1969:02 – 1999:04

$$y_t = X_t' \Phi + \sum_{j=1}^Q \beta_j G(Z_t' \gamma_j) + \varepsilon_t, \quad G(z) = (1 + \exp(-z))^{-1}$$

$$y_t = \Delta LIPC_t^*$$

$$m_{3t} = \Delta LM3_t^*$$

Inputs:  $X_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$ ,  $z_t = \{y_{t-2}, y_{t-4}, y_{t-8}, m_{3t-1}, m_{3t-2}\}$   
 $Q=3$

Única conexión	Dentro de muestra							Fuera de muestra					
	AIC	BIC	RMSE	RMSPE	MAE	MAPE	SR	RMSE	RMSPE	MAE	MAPE	SR	U-THEIL
$y_{t-2}$	0,227	0,728	0,933	13,946	0,754	3,088	65,8	1,194	1,050	1,015	0,988	100	0,212
$y_{t-4}$	0,328	0,830	0,982	13,718	0,782	3,030	55,3	0,965	1,969	0,921	1,593	100	0,398
$y_{t-8}$	0,510	1,011	1,075	16,890	0,901	4,434	42,1	1,394	2,323	1,270	1,815	80	0,469
$m_{3t-1}$	0,690	1,191	1,176	18,500	0,933	4,996	57,0	0,531	1,450	0,496	1,055	80	0,293
$m_{3t-2}$	1,407	1,908	1,683	67,848	1,392	15,51	50,0	1,516	7,061	1,313	4,521	40	1,426

## ANEXO 4

### 1. MODELO CURVA DE PHILLIPS<sup>1</sup>

Este modelo está basado en el modelo triangular convencional de Phillips, el cual tiene en cuenta los cambios en las expectativas influenciados por el desarrollo de la política monetaria. La estimación de este modelo incorpora además de los choques de demanda y de oferta, los regímenes de inflación basados en los resultados de un modelo de Markov-Switching, a través de una variable que mide la probabilidad de estado de mayor media de inflación. A nivel internacional, este procedimiento fue propuesto por Ricketts y Rose (1995) y Fillion y Leonard<sup>2</sup>. En la actualidad, este modelo utiliza como variables explicativas la inflación rezagada, la inflación de los bienes importados, una estimación de la brecha del producto y una variable que recoge la probabilidad de cambio de estado.

$$\pi_t = \beta_0 + \beta_1 \pi_{t-4} + \beta_2 \pi_{t-6} + \beta_3 \pi_{t-2}^m + \beta_4 y_{t-1} + \beta_5 P_{1t} + \delta S_{it} + \beta_6 \delta_{1t} + \varepsilon_t$$

#### Definiciones

$\pi_t$  es la primera diferencia del logaritmo del *IPC*, fin de período.

$y_t$  es la brecha del producto calculado por el modelo de mecanismos de transmisión a partir de una función de producción para el *PIB* potencial.

$\pi_t^m$  es la primera diferencia del logaritmo de los precios de los bienes importados.

$P_{1t}$  es la probabilidad de estado de mayor media de inflación, según el modelo de Switching de Hamilton.

$\delta_{1t}$  es una variable dicótoma que toma el valor de uno en el segundo trimestre de 1986 y cero en el resto.

$S_{it}$  son las variables *dummies* estacionales.

<sup>1</sup> López y Misas (1998).

<sup>2</sup> Ricketts y Rose (1995) y Fillion, J. F. y A. Leonard (1997).

## 2. MODELO P ESTRELLA

El modelo *P* estrella original para la inflación fue propuesto por Hallman *et al.* (1989, 1991)<sup>3</sup>, el cual está basado en la teoría cuantitativa del dinero. En él se asume un ajuste lento de los precios ante cambios no anticipados de la oferta de dinero, de tal forma que las desviaciones de los precios de su nivel de largo plazo generan presiones inflacionarias.

El *P\** tradicional asume que la velocidad de circulación del dinero es estacionaria, por lo que el nivel de precios depende de la brecha de la velocidad del agregado monetario, en este caso *M1*, y de la brecha del producto (calculado por el filtro de Holdrick-Prescott del *PIB*).

### *P* estrella tradicional:

$$\pi_t = \beta_0 + \beta_1 \pi_{t-1} + \beta_2 \pi_{t-4} + \beta_3 \pi_{t-6} + \beta_4 y_{t-1} + \beta_5 \eta_{t-1} + \delta s_{it} + \beta_6 \delta_{1t} + \beta_7 \delta_{2t}$$

### Definiciones:

$y_t$  es la brecha del producto obtenida a través del filtro de Hodrick-Prescott.

$\eta_t$  es la brecha de la velocidad del agregado monetario *M1* obtenido a través del filtro de Hodrick-Prescott.

$\delta_{2t}$  es una variable dicótoma que toma el valor de uno en los trimestres primero y segundo de 1985 y cero en el resto.

## 3. MODELO DE PRECIO RELATIVO DE ALIMENTOS

Este modelo busca capturar los efectos del choque de oferta más común como es el de los precios de los alimentos, así como controlar los choques de demanda, utilizando una estimación de la brecha del producto y de la oferta monetaria. La proyección del precio de los alimentos se considera exógena y se construye con otro modelo que proyecta la inflación de alimentos en función de su dinámica pasa-

---

<sup>3</sup> Véanse, Hallman, J.; Porter R. y Small, D. (1989, 1991).

da y de la probable evolución de la cantidad de lluvias. El modelo está complementado con la evolución de la cantidad de dinero definido como  $M1$ , con la brecha del producto y con rezagos de la inflación.

$$\pi_t = \beta_0 + \beta_1 \pi_{t-1} + \beta_2 \pi_{t-4} + \beta_3 \pi_{t-6} + \beta_4 \pi_t^R + \beta_5 \pi_{t-5}^R + \beta_6 y_t + \beta_7 M_{1t-3} + \delta_{3t} + \beta_8 \delta_{1t} + \beta_9 \delta_{2t} + \beta_{10} \delta_{3t}$$

### Definiciones:

$\pi_t^R$  es la primera diferencia del logaritmo del precio relativo de alimentos (*IPC alimentos/ IPC total*).

$M_{1t}$  es la primera diferencia del logaritmo de  $M1$ .

$\delta_{3t}$  es una variable dicótoma que toma el valor de uno en el primero y segundo trimestres de 1999 y cero en el resto.

### 4. MODELO ESCANDINAVO:

Este modelo sigue la tradición “escandinava”, en donde la inflación de una economía abierta y pequeña está determinada principalmente por factores de costo como el crecimiento de los salarios reales y por la devaluación real.

$$\pi_t = \beta_0 + \beta_1 \pi_{t-1} + \beta_2 \pi_{t-4} + \beta_3 \pi_{t-6} + \beta_4 \chi_{t-3} + \beta_5 \omega_t + \beta_6 \omega_{t-1} + \beta_7 \omega_{t-3} + \beta_8 \delta_{1t} + \beta_9 \delta_{2t} + \beta_{10} \delta_{3t}$$

### Definiciones

$\chi_t$  es el crecimiento trimestral de la tasa de cambio real.

$\omega_t$  es el crecimiento trimestral del salario real de la industria.

## INSTRUCCIONES A LOS AUTORES

Ensayos Sobre Política Económica (ESPE) es una publicación periódica sobre economía, cuyo objetivo es difundir artículos y notas de carácter técnico de alta calidad. El tipo de documentos que ESPE busca publicar se caracteriza por ser: i) interesante, ii) original y iii) técnicamente correcto. Así, ESPE considerará para publicación aquellos trabajos originales, tanto teóricos como aplicados, que sean de relevancia para el mejor entendimiento de los problemas económicos y de las políticas necesarias para su solución. ESPE hace énfasis en los problemas económicos colombianos, pero no se limita a trabajos aplicados al caso colombiano: cualquier documento del cual se extraigan lecciones acerca de los problemas y políticas económicas podrá ser sometido al proceso editorial, con la salvedad de que ESPE no considerará para publicación los trabajos de tipo puramente coyuntural.

ESPE es una publicación de la Subgerencia de Estudios Económicos del Banco de la República, pero esto no implica que en ESPE sólo sean publicados trabajos producidos en dicha entidad, ni tampoco que la revista presente opiniones oficiales del Banco de la República. ESPE es una publicación de carácter científico dirigida y abierta a todos los miembros de la comunidad académica, colombiana e internacional, con interés en temas económicos. En esta medida, ESPE no considerará trabajos puramente de opinión, sino sólo aquellos con una fundamentación técnica acorde con los estándares actuales de la profesión económica.

En la actualidad, ESPE se distribuye a unos 169 destinatarios en Colombia y 125 en el exterior, y cuenta con más de 359 acuerdos de canje. Como parte de su objetivo de cubrir tan ampliamente como sea posible a la comunidad económica, ESPE cuenta además con un website, [www.banrep.gov.co/ensayos/ESPE.htm](http://www.banrep.gov.co/ensayos/ESPE.htm), en el que las ediciones más recientes de la revista están disponibles sin costo alguno.

Dentro de este propósito, ESPE invita a los autores en Colombia y en el exterior a someter sus trabajos para consideración editorial, siguiendo los requerimientos definidos a continuación. Debe anotarse que ESPE no requiere ningún pago de un autor, ni su suscripción a la revista, para considerar su(s) trabajo(s).

1. La presentación de un documento a ESPE implica la declaración por parte del(os) autor(es) de que:
  - a. El trabajo es original suyo.
  - b. El trabajo no ha sido publicado anteriormente.
  - c. El trabajo no se está considerando para publicación por otra u otras revistas.
  - d. En caso de ser aceptado, el(los) autor(es) transferirá(n) los derechos de autor a ESPE.
  - e. Entiende(n) que, en ningún caso, la aceptación de un trabajo para consideración en el proceso editorial de ESPE implica un compromiso de ESPE de publicar el documento.
2. El documento deberá estar escrito en su totalidad en español o en inglés.
3. Los documentos originales pueden ser sometidos por medio electrónico o físico, aunque ESPE invita a los autores a utilizar el primer método para hacer el proceso editorial más expedito.
  - a. Por medio electrónico, el(los) autor(es) debe(n) enviar al Editor una carta de presentación y el archivo que contiene el documento a la siguiente dirección electrónica: [espe@banrep.gov.co](mailto:espe@banrep.gov.co) o [acarvaes@banrep.gov.co](mailto:acarvaes@banrep.gov.co).

Archivos tipo PDF, Word o LaTeX (incluye Scientific Word y Workplace) son aceptables. El archivo debe contener todo el material que hace parte del artículo, incluyendo gráficos, cuadros y anexos. El(los) autor(es) deberá(n) conservar una copia del archivo electrónico que contiene la versión del documento que se envió.

- b. Por medio físico, el(los) autor(es) debe(n) enviar al Editor una carta de presentación y tres copias del documento, a la siguiente dirección:

Andrés Carvajal  
 Editor,  
 Ensayos Sobre Política Económica.  
 Subgerencia de Estudios Económicos  
 Banco de la República  
 Carrera 7 No. 14-78 piso 11.

Cada copia del documento debe contener todo el material que hace parte del artículo, incluyendo gráficos, cuadros y anexos. El(los) autor(es) deberá(n) conservar una copia de la versión del documento que fue enviada y el archivo electrónico que contiene esta versión.

4. Cualquiera que sea el método por el cual el trabajo es sometido al proceso editorial, en el caso de varios autores estos deberán designar, en la carta de presentación, a un autor corresponsal con quien ESPE se encargará de realizar todas las comunicaciones que hagan parte del proceso editorial. En adelante, en estos lineamientos, “el autor” querrá decir el autor corresponsal cuando se trate de documentos escritos por varios autores.
5. En la primera página del documento, deberá incluirse únicamente:
  - a. El título completo del documento.
  - b. El nombre de cada uno de los autores.
  - c. La afiliación institucional de cada uno de los autores.
  - d. La dirección postal de cada uno de los autores.
  - e. La dirección de correo electrónico de cada uno de los autores.
  - f. Resúmenes en español e inglés de los aspectos más importantes del trabajo, los cuales no deberán sobrepasar las 100 palabras (cada uno). El resumen en el idioma diferente al del resto del documento deberá incluir al comienzo el título del documento, pero éste no contará para el límite de palabras.
  - g. Al menos tres “palabras clave” relevantes, en español e inglés.
  - h. Al menos tres “clasificaciones JEL” relevantes.
  - i. Cualquier agradecimiento a personas o instituciones.

**Nota:** los nombres de los autores **no** deberán aparecer más en el trabajo.

6. Para el cuerpo del documento:
  - a. El documento deberá estar escrito utilizando Times New Roman 11 ó 12, a doble espacio y con márgenes convencionales.
  - b. Los gráficos y cuadros podrán estar dentro del texto o, alternativamente, anexos, todos ellos, al final del mismo.
  - c. La numeración debe ser consecutiva en toda la obra o artículo, con ordenadores numéricos (e. g.: 1. Sección, 1.1. Subsección, 1.1.1. Subsubsección, etc.).

- d. Cuadros y gráficos (si los hubiere) deben ser numerados de manera independiente y consecutiva (e. g.: Cuadro 1, Gráfico 1, Cuadro 2...).
  - e. Las fórmulas deben estar centradas y numeradas consecutivamente al margen derecho.
  - f. Las notas a pie de página deberán utilizarse lo menos posible. Cuando se utilicen, deberán estar numeradas consecutivamente a través del texto y deberán ser sólo de carácter aclaratorio.
7. Las referencias bibliográficas deben comprender únicamente las referencias incluidas en el texto, siguiendo este formato:
- a. Cuando se refiere a un artículo de revista:
    - En el texto, autor (año); e. g.: "... Villar (1985) demuestra que la elasticidad-ingreso de las importaciones es...".
    - En la bibliografía, autor (año). "Nombre del artículo", *Nombre de la revista*, mes, volumen, número páginas; e. g.:  
Villar, L. (1985). "Determinantes de las importaciones en Colombia: un análisis econométrico", *Ensayos Sobre Política Económica*, diciembre, No. 8, pp. 15-39.
  - b. Cuando se refiere a un libro:
    - En el texto, autor (año); e.g.: "... Banco de la República (1987) analiza los principales determinantes..."
    - En la bibliografía, autor (año). *Nombre-libro*, Editorial; e.g.:  
Banco de la República (1987). *Colombia: 20 años del Régimen de Cambios y de Comercio Exterior*, Departamento Editorial.
8. Una vez recibido por el editor, el documento podrá ser rechazado en dos momentos:
- a. Antes de pasar por la evaluación técnica, el documento podrá ser rechazado por el Editor, cuando se considere que el trabajo no se enmarca en el propósito de la revista, o cuando se encuentre que éste no se ajusta a los requerimientos de forma aquí definidos. En el segundo caso, el autor podrá someter el documento nuevamente, una vez haya hecho los ajustes necesarios. Normalmente, el editor dará a conocer un rechazo de este tipo en la semana posterior a la recepción del trabajo.
  - b. Si el Editor considera que el documento puede comenzar el proceso editorial, comunicará este hecho al autor en la semana posterior a su recepción. El proceso editorial consta principalmente de la evaluación por uno o dos miembros del Comité de Evaluación Técnica y de la decisión sobre publicación hecha de manera conjunta por el Consejo Editorial. De este proceso saldrá una de tres decisiones: publicación, rechazo o exigencia de modificaciones. En el caso de rechazo, las razones técnicas para esta decisión serán comunicadas por el Editor al autor. En el caso en que se exijan correcciones, éstas serán comunicadas al autor y se informará la fecha de cierre de la siguiente edición de ESPE, con el fin de indicar el tiempo que hay disponible para la realización de las correcciones. Bajo circunstancias normales, el proceso editorial no debe tomar más de tres meses desde el momento en que el documento es recibido, hasta el momento en que el autor recibe respuesta. ESPE se compromete a realizar este proceso en un máximo de cuatro meses.
9. ESPE valora el tiempo de las personas que aceptan en el Comité de Evaluación Técnica, pero también espera de ellos prontitud en sus evaluaciones. Es por esto que ESPE no espera que sus

evaluadores descifren un documento confuso o pobremente escrito. En esta medida, es responsabilidad del autor que el trabajo sea claro y entendible para un economista con formación académica, pues un documento podrá ser rechazado sobre la base de estar pobremente escrito. De la misma forma, el Editor podrá requerir del autor el envío de las derivaciones matemáticas del documento, con el fin de facilitar la labor editorial.

10. Cuando se exijan modificaciones al documento, el Consejo Editorial determinará cuándo éstas han sido realizadas de manera satisfactoria. Cuando esto haya ocurrido, el autor será modificado de la decisión de publicación del documento.
11. Una vez un documento es aceptado para publicación, el autor deberá enviar a ESPE un archivo electrónico con el documento completo, tal y como fue aprobado por el consejo editorial. Únicamente se aceptarán documentos cuyo texto se encuentre en Word o LaTeX (incluye Scientific Word y Workplace). En el caso de cuadros elaborados por fuera del texto, se aceptará Excel. En el caso de Gráficos, se aceptará cualquier editor compatible con Power Point. Sobre esta versión, un corrector de estilo de ESPE realizará sugerencias al autor para la mejor presentación del documento. El autor podrá desestimar estas sugerencias, pero ESPE se reserva el derecho de exigir un mínimo de uniformidad en los estilos de los documentos. Antes de pasar a la imprenta, el autor deberá aprobar las pruebas de impresión creadas por ESPE. El periodo de aprobación de estas sugerencias será de dos semanas. Es responsabilidad del autor la revisión del documento en cuanto a su conformidad con la versión aceptada por ESPE.
12. Una vez el documento es aceptado por ESPE para publicación, los derechos de copia del mismo pasan a ser propiedad de la revista. Una vez publicado, el documento podrá ser reproducido libremente para uso académico, siempre y cuando nadie obtenga lucro por esta reproducción y siempre y cuando cada copia incluya la referencia bibliográfica de ESPE. El(los) autor(es) del documento podrá(n) además colocar en su propio website una versión electrónica del documento, siempre y cuando ésta incluya la referencia bibliográfica de ESPE. La reproducción del documento para cualquier otro fin, o su colocación en cualquier otro website, requerirá autorización del Editor de ESPE.



COMITÉ TÉCNICO

- Olga Lucía Acosta, Ph. D. (c)*  
*Universidad del Rosario*
- Veneta Andonova, Ph. D.*  
*ITAM, México*
- Cristina Arango, M. A.*  
*Ministerio de Hacienda*
- Mauricio Avella, Ph. D.*  
*Banco de la República*
- Felipe Barrera, Ph. D. (c)*  
*Fedesarrollo*
- Ximena Cadena, M. A.*  
*Ministerio de Hacienda*
- Maria del Pilar Castillo, D. E. A.*  
*Universidad del Valle*
- Carlos Castro, M. A.*  
*Departamento Nacional de Planeación*
- Andrés Escobar, Ph. D. (c)*  
*Universidad de los Andes*
- Leopoldo Fergusson, M. A.*  
*Universidad de los Andes*
- Mario García, Ph. D.*  
*Universidad Nacional*
- Javier Gómez, Ph. D.*  
*Banco de la República*
- Orlando Gracia, M. Sc.*  
*Departamento Nacional de Planeación*
- Juan Carlos Guataquí, M. Sc.*  
*Universidad del Rosario*
- Franz Hamann, Ph. D. (c)*  
*Banco de la República*
- Ana María Iregui, Ph. D.*  
*Banco de la República*
- Flavio Jácome, Ph. D.*  
*Universidad Javeriana*
- Juan Manuel Julio, M. Sc.*  
*Banco de la República*
- Enrique López, D. E. A.*  
*Banco de la República*
- Hernán Maldonado, M. A.*  
*Ministerio de Hacienda*
- Marcela Meléndez, Ph. D.*  
*Universidad de los Andes*
- Ligia Melo Becerra, Ph. D. (c)*  
*Banco de la República*
- Luis Fernando Melo, M. Sc.*  
*Banco de la República*
- Sergio Monsalve, Ph. D.*  
*Universidad Nacional*
- Fabio Nieto, Ph. D. (c)*  
*Universidad Nacional*
- Carlos H. Ortiz, Ph. D.*  
*Universidad del Valle*
- Jesus Otero, Ph. D.*  
*Universidad del Rosario*
- Carlos Esteban Posada, Ph. D. (c)*  
*Banco de la República*
- William Prieto, Ph. D. (c)*  
*Banco de la República*
- Pablo Querubin, M. A.*  
*Universidad de los Andes*
- María Teresa Ramírez, Ph. D.*  
*Banco de la República*
- Juan Mauricio Ramírez, Ph. D.*  
*Banco de la República*
- Jorge Enrique Restrepo, Ph. D.*  
*Banco Central de Chile*
- Alejandro Reveiz, Ph. D.*  
*Banco de la República*
- Álvaro Riascos, Ph. D.*  
*Banco de la República*
- Marla Patricia Ripoll, Ph. D.*  
*Pittsburgh University*
- Norberto Rodríguez, M. Sc.*  
*Banco de la República*
- Almudena Sevilla-Sanz, Ph. D. (c)*  
*Brown University*
- Rodrigo Suescún, Ph. D.*  
*Banco Mundial*
- José Ignacio Uribe, Ph. D.*  
*Universidad del Valle*
- Hernán Vallejo, Ph. D.*  
*Universidad de los Andes*
- Diego Mauricio Vásquez, M. A. (c)*  
*Banco de la República*
- Juan Pablo Zárate, M. A. (c)*  
*Banco de la República*
- Hernando Zuleta, Ph. D.*  
*ITAM, México*