

BANCO DE GUATEMALA

Documentos de Trabajo

CENTRAL BANK OF GUATEMALA

Working Papers





BANCO DE GUATEMALA

La serie de Documentos de Trabajo del Banco de Guatemala es una publicación que divulga los trabajos de investigación económica realizados por el personal del Banco Central o por personas ajenas a la institución, bajo encargo de la misma. El propósito de esta serie de documentos es aportar investigación técnica sobre temas relevantes, tratando de presentar nuevos puntos de vista que sirvan de análisis y discusión. Los Documentos de Trabajo contienen conclusiones de carácter preliminar, las cuales están sujetas a modificación, de conformidad con el intercambio de ideas y de la retroalimentación que reciban los autores.

La publicación de Documentos de Trabajo no está sujeta a la aprobación previa de los miembros de la Junta Monetaria del Banco de Guatemala. Por lo tanto, la metodología, el análisis y las conclusiones que dichos documentos contengan son de exclusiva responsabilidad de sus autores y no necesariamente representan la opinión del Banco de Guatemala o de las autoridades de la institución.

*****©*****

The Central Bank of Guatemala Working Papers Series is a publication that contains economic research documents produced by the Central Bank staff or by external researchers, upon the Bank's request. The publication's purpose is to provide technical economic research about relevant topics, trying to present new points of view that can be used for analysis and discussion. Such working papers contain preliminary conclusions, which are subject to being modified according to the exchange of ideas, and to feedback provided to the authors.

The Central Bank of Guatemala Working Papers Series is not subject to previous approval by the Central Bank Board. Therefore, their methodologies, analysis and conclusions are of exclusive responsibility of their authors, and do not necessarily represent the opinion of either the Central Bank or its authorities.

Una aproximación no-lineal a las metas de inflación en Guatemala: pronósticos de un modelo autorregresivo de redes neuronales artificiales con predictores monetarios

Rolando González Martínez

Resumen

El pronóstico de la inflación es importante para cualquier banco central, particularmente para aquél que ha adoptado un régimen de metas explícitas de inflación. Modelos lineales se utilizan convencionalmente para pronosticar la inflación; en esta investigación se propone un modelo no-lineal autorregresivo basado en ecuaciones de redes neuronales artificiales, que emplea la emisión monetaria y la tasa de interés como predictores exógenos. El pronóstico no-lineal de la inflación fue comparado con el pronóstico de un modelo lineal Holt-Winters en un experimento de seudopronóstico fuera de muestra. El pronóstico no-lineal resultó estadísticamente más preciso que el pronóstico lineal. De hecho, el pronóstico no-lineal logró reproducir el incremento abrupto del ritmo inflacionario en Guatemala el año 2008. La presencia de respuestas no-proporcionales de la inflación a los instrumentos monetarios y la posibilidad de obtener pronósticos más precisos en el corto y mediano plazo justifican experimentar con modelos no-lineales durante el diseño del esquema de metas explícitas de inflación, como contraste o como alternativa a los modelos lineales tradicionales.

1. Introducción

Las metas de inflación (inflation targeting) son una estrategia de política monetaria introducida en Nueva

Zelanda en 1990, que ha demostrado ser exitosa para estabilizar tanto la inflación como la economía real (Svensson, 2007).¹

A diferencia de las metas monetarias y cambiarias, las metas de inflación comprometen al banco central con el objetivo primario de la estabilidad de precios a través del anuncio de una meta numérica de inflación. Luego de identificar esta meta en base a modelos de predicción, el banco central diseña, ejecuta y evalúa su política monetaria utilizando instrumentos monetarios que se ajustan en la medida necesaria para alcanzar la meta inflacionaria.² Por tanto, en este esquema los bancos centrales tienen libertad para decidir qué instrumentos utilizar para alcanzar la meta, pero están forzados a pronosticar el comportamiento futuro de la inflación (Loayza y Soto, 2002). Por este motivo, un elemento clave del régimen de metas inflacionarias es la habilidad de

¹ La meta de inflación puede ser un pronóstico de inflación puntual, o un rango de inflación (un intervalo), en el que el banco central tiene como objetivo la mitad del rango.

² Debido a que existe un rezago entre las acciones de política monetaria y el impacto en los objetivos del banco central, la política monetaria es más efectiva si es guiada por pronósticos. De esta manera se ajustan los instrumentos de forma que los pronósticos de los objetivos condicionales a los instrumentos aproximen las metas de inflación (Svensson, 2007).

predecir la inflación.³ Usualmente métodos lineales se utilizan para el pronóstico de la inflación; en esta investigación en cambio se propone métodos no-lineales⁴ basados en una ecuación autorregresiva de redes neuronales artificiales con predictores exógenos monetarios.

El uso de ecuaciones basadas en redes neuronales artificiales como herramienta de predicción se justifica porque este tipo de modelos, cuando están correctamente especificados, producen pronósticos más precisos que mejoran la reputación y la credibilidad del banco central.⁵ Adicionalmente, las ecuaciones de redes neuronales artificiales son no-lineales, por lo que serían más adecuadas para analizar una respuesta no-proporcional (no-lineal) de la inflación respecto a cambios en los instrumentos monetarios.^{6,7} Serju (2000) también señaló dos ventajas

de los modelos neuronales: 1) la propiedad de aproximación universal, por lo que a pesar de que se desconozca la relación funcional entre los instrumentos monetarios y la inflación, los modelos de redes neuronales pueden aproximar arbitrariamente la relación no-lineal desconocida; y (2) los modelos de redes neuronales han probado ser mejores que otros métodos para pronósticos de mediano plazo, produciendo a la vez buenos pronósticos en horizontes de corto plazo.⁸

El objetivo de este estudio es pronosticar específicamente la inflación en Guatemala con un modelo Autorregresivo de Redes Neuronales Artificiales con X-predictores exógenos monetarios (ARNAX) y comparar el pronóstico ARNAX con el de un modelo lineal.

La hipótesis del estudio es que los pronósticos de la inflación basados en ecuaciones basadas de redes neuronales artificiales pueden ser mejores que los pronósticos realizados con algunos modelos lineales convencionales.^{9, 10, 11}

³ Valle y Morán (2003) establecieron que los pronósticos de inflación son de capital importancia para cualquier banco central, pero en particular para aquél que ha adoptado un esquema de inflation targeting.

⁴ La no-linealidad se refiere a las variables, no a los parámetros. Véase Granger (2008).

⁵ La credibilidad del banco central es un elemento indispensable cuando se decide adoptar un régimen de metas de inflación, dado que este régimen se fundamenta en crear expectativas en los agentes económicos respecto al estado futuro de la inflación. Si el banco central carece de credibilidad, los agentes no considerarán las metas de inflación anunciadas y tomarán sus decisiones económicas de acuerdo a sus propias expectativas de inflación.

⁶ Para Franses (1998) una serie de tiempo puede considerarse no-lineal cuando un shock de gran magnitud tiene un impacto diferente que un shock leve en el sentido de que el impacto del shock no es proporcional a su magnitud.

⁷ Los modelos lineales (como e. g. vectores autorregresivos) asumen implícitamente que la relación entre la inflación y los instrumentos de política monetaria son proporcionales (lineales). Aristizábal (2006) afirmó adecuadamente que: "las funciones de impulso-respuesta derivadas de este análisis son simétricas, implicando que un choque monetario positivo y uno negativo de igual magnitud, conducirán a efectos idénticos, pero con signo opuesto. Adicionalmente, son lineales, de tal forma que los efectos serán siempre proporcionales a la magnitud del choque y, finalmente, son independientes del momento en el que éste ocurre, es decir, que les es indiferente si el choque ocurre en un momento de baja o elevada inflación. Claramente, estos tres rasgos van en contravía de la forma en la que realmente opera la relación entre dinero e inflación. En primer lugar, los agentes económicos son menos sensibles a estímulos de política positivos que negativos, luego el valor absoluto de los efectos de dichos choques no es de la misma magnitud." También para Solera (2005) el supuesto de relación lineal entre variables podría no justificarse dados los trabajos como e. g. Friedman (1968) que sugieren una asimetría en los efectos de la política monetaria.

⁸ Para el diseño de metas de inflación, normalmente se cuenta con dos modelos: 1) un modelo lineal de pronósticos de muy corto plazo que por construcción es ineficiente para realizar pronósticos en el mediano plazo; y 2) un modelo estructural que se utiliza para pronósticos de mediano plazo (multianuales). El hecho de que los modelos basados en ecuaciones de redes neuronales artificiales sean eficientes para el pronóstico tanto en el corto como en el mediano plazo es particularmente interesante, porque sólo un modelo sería necesario para el diseño de metas de inflación y la distinción entre horizontes temporales no dependería de la capacidad predictiva del modelo de pronóstico.

⁹ Modelos de pronóstico lineal de la inflación pueden encontrarse en Razzak (2002) y en Stock y Watson (1999), ambos en el contexto de la curva de Phillips. Interesantemente, Stock y Watson (1999) señalan que en la medida que la relación entre la inflación y las variables candidatas sea no-lineal, los resultados de los modelos lineales subestiman las mejoras en el pronóstico que podrían obtenerse.

¹⁰ Una investigación sobre pronósticos de la inflación en Guatemala con métodos lineales como e. g. vectores autorregresivos es Valle y Morán (2003). Pronósticos de la inflación con redes neuronales artificiales pueden encontrarse en Bukhari y Nadeem (2007), Nakamura (2005), Solera (2005), Aristizábal (2006) y Chen et al (2001). Particularmente, Chen et al (2001) utilizaron redes neuronales artificiales con componentes autorregresivos y variables exógenas para pronosticar la inflación.

¹¹ Kajitani et al (2005) concluyen que los modelos de redes neuronales artificiales pueden ser tan exitosos en la predicción como otros modelos estadísticos, e incluso superar a estos modelos cuando las series a pronosticar contienen características no-lineales y no-gaussianas.

La comprobación de esta hipótesis se realizó con un experimento de seudopronóstico fuera de muestra¹² en el que se comparó los pronósticos de un modelo (lineal) Holt-Winters y los de un modelo no-lineal autorregresivo de redes neuronales artificiales con predictores exógenos (ARNAX). Para contrastar la hipótesis de la investigación, se calculó el estadígrafo Diebold-Mariano de exactitud de pronóstico que evalúa la hipótesis nula de que el pronóstico del modelo ARNAX no es superior al pronóstico del modelo lineal.¹³ Si se rechaza esta hipótesis, implicaría que el modelo no-lineal produce pronósticos más precisos, y debe ser considerado como una herramienta alternativa opcional o de contraste a los modelos lineales al momento de pronosticar el ritmo inflacionario en un régimen de metas explícitas de inflación. Esta investigación está estructurada: la sección 2 describe el modelo ARNAX y explica la metodología de pronóstico; la sección 3 ajusta el modelo ARNAX y evalúa la hipótesis de la investigación; la sección 4 concluye.

2. Modelo ARNAX y metodología de pronóstico

2.1. Redes neuronales artificiales y el modelo ARNAX

Los modelos de redes neuronales artificiales son un tipo de ecuaciones paramétricas no-lineales originalmente diseñadas en ciencias neurológicas para intentar aproximar la forma en la que funciona el cerebro (Franses, 1998, Bukhari y Naddem, 2007). Existe una gran variedad de estos modelos; en esta sección se describirá solamente el perceptrón multicapa utilizado en esta investigación para pronosticar la inflación.

Sea $\{Y_t\}_{t=1}^T$ la serie de tiempo a pronosticar (la inflación), y considérese una representación genérica del modelo de redes neuronales:

$$Y_t = w_0 + \sum_{h=1}^i w_h f(x) + e_t$$

que contiene h -unidades ocultas de funciones no-lineales $f(x)$ que pueden adoptar diferentes formas, como e. g. una función tangente hiperbólica o una función sigmoideal. Las ecuaciones con función sigmoideal:

$$Y_t = w_0 + \sum_{h=1}^i w_h \frac{1}{1 + e^{-\left[q_{h,0} + \sum_{n=1}^j q_{h,n} x_{t,n} + \sum_{m=1}^k q_{h,n+m} y_{t-m} \right]}} + e_t$$

tienen la *propiedad de aproximación universal*, que permite a los modelos de redes neuronales aproximar arbitrariamente bien cualquier tipo de función no-lineal desconocida, dadas las x -variables de entrada (Franses, 1998, Nakamura, 2005). Esto implica que si no se conoce la forma funcional que relaciona los instrumentos de política monetaria con la inflación, pero se considera que existe una relación no-lineal entre estas variables, los modelos de redes neuronales con función sigmoideal en la capa oculta pueden ajustar perfectamente la información de la inflación en base a la información de los x -instrumentos de política monetaria.¹⁴ Si a esta especificación se añaden componentes autorregresivos, se tiene un modelo Autorregresivo de Redes Neuronales Artificiales con X -variables exógenas (ARNAX):

predictores (instrumentos monetarios y componentes autoregresivos)

$$Y_t = w_0 + \sum_{h=1}^i w_h \frac{1}{1 + e^{-\left[q_{h,0} + \sum_{n=1}^j q_{h,n} x_{t,n} + \sum_{m=1}^k q_{h,n+m} y_{t-m} \right]}} + e_t$$

Modelo Autorregresivo de Redes Neuronales Artificiales con X-variables exógenas (ARNAX)

donde,

y_t es la inflación,

$x_{t,n}$ son los n -predictores exógenos (instrumentos de política monetaria),

e_t son los residuos del modelo de ARNAX,¹⁵

¹² Como en Nakamura (2005) y Kajitani et al (2005).

¹³ Este enfoque-comparar estadísticamente la capacidad predictiva entre modelos lineales y no lineales con el estadígrafo Diebold-Mariano- es utilizado también en McNelis y McAdam (2004).

¹⁴ Solera (2005) asocia las capas ocultas con variables latentes (intermedias), i.e. los mecanismos de propagación entre los instrumentos monetarios y la inflación.

¹⁵ Los modelos de redes neuronales artificiales en general no requieren supuestos acerca de los residuos.

y los parámetros del modelo son:¹⁶

- w_0 sesgo de la capa de salida,
- w_h pesos sinápticos de las funciones de activación de las h-capas ocultas,
- q_0 sesgo de la capa de entrada,
- q_n pesos sinápticos de los instrumentos de política monetaria (variables exógenas),
- q_{n+m} pesos sinápticos de los componentes autorregresivos.

Los parámetros (conectores sinápticos) se modifican durante el ajuste del modelo ARNAX hasta minimizar la suma de errores cuadrática mediante un algoritmo de propagación hacia atrás (*backpropagation*);¹⁷ este proceso de ajuste y estimación de los parámetros se denomina entrenamiento.

2.2 Metodología de pronóstico y simulación

Para ajustar y evaluar el poder predictivo del modelo ARNAX se dividió la serie de tiempo de la inflación en tres partes (véase también el gráfico 1):

Entrenamiento:	enero 1996 a diciembre 2007
Pronóstico <i>expost</i> :	enero 2008 a noviembre 2008
Pronóstico <i>exante</i> :	diciembre 2008 a diciembre 2009

El objetivo de la partición es evaluar la capacidad predictiva del modelo ARNAX, ya que un modelo no-lineal de redes neuronales artificiales puede lograr un ajuste perfecto a los datos y sin embargo tener una pobre capacidad predictiva. Un modelo de pronóstico

de inflación adecuado, además del ajuste, tiene que tener una capacidad de generalización a períodos no observados por el modelo (i. e. períodos de pronósticos *expost* y *exante*):¹⁸

- El rango enero 1996 a diciembre 2007 se utiliza para especificar la arquitectura y estimar los parámetros (entrenar) del modelo ARNAX. Este período de estimación se subdividió en un segmento de entrenamiento y otro de validación, porque es común que las redes neuronales ajusten perfectamente los datos en -muestra pero pierden capacidad de generalización cuando se utilizan para pronóstico fuera de muestra- una patología denominada *sobreajuste*. Por tanto, durante la estimación se ajusta el modelo neuronal al período de entrenamiento y el algoritmo de estimación se detiene cuando el error en el período de validación comienza a incrementarse.
- En el período de evaluación de pronóstico *expost* (enero 2008 a noviembre 2008) se predice la inflación más allá del período de estimación de los pesos sinápticos (parámetros), y ya que las observaciones de la variable endógena inflación y las variables explicativas monetarias se conocen con certeza durante el período *expost*, es posible evaluar la especificación matemática del modelo ARNAX respecto a su capacidad de predecir la variable endógena, dado que los valores predictibles se comparan con datos existentes. Éste es el período utilizado en el experimento de pronóstico *seudo-fuera-de-muestra*, i. e. en este segmento se realizan pronósticos con el modelo ARNAX calibrado y se compara con la información existente de la inflación y con el pronóstico Holt-Winters.

Dado el pronóstico de la inflación \hat{y}_t a h -pasos y los datos reales de la inflación y_t , para evaluar la precisión de los pronósticos entre modelos se calculó medidas de precisión de pronóstico ampliamente utilizadas:

$$\text{Raíz del error cuadrático medio} = \sqrt{h^{-1} \sum_{t=T+1}^{T+h} \mathbf{a}^0 (\hat{y}_t - y_t)^2}$$

¹⁶ Las ecuaciones de redes neuronales artificiales tienen típicamente tres capas: capa de entrada (variables de entrada), capas ocultas y capa de salida. En este estudio se utiliza una función identidad para la capa de salida.

¹⁷ Básicamente, en este algoritmo existe una fase inicial en la que la red neuronal se alimenta de las entradas y produce una salida con pesos sinápticos fijos; en una siguiente fase los pesos sinápticos son ajustados de acuerdo a una señal de error en el ajuste mediante una propagación hacia atrás. Para una descripción detallada y didáctica del algoritmo de propagación hacia atrás puede verse Aristizábal (2006).

¹⁸ La distinción entre pronóstico *exante* y *expost* se basa en la expuesta en Pindyck y Rubinfeld (1998).

$$\text{Error promedio absoluto} = h^{-1} \mathbf{a} \sum_{t=T+1}^{T+h} |\hat{y}_t - y_t|,$$

$$\text{Coeficiente de Theil} = \frac{\sqrt{h^{-1} \mathbf{a} \sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2}}{\sqrt{h^{-1} \mathbf{a} \sum_{t=T+1}^{T+h} \hat{y}_t^2} + \sqrt{h^{-1} \mathbf{a} \sum_{t=T+1}^{T+h} y_t^2}}$$

Para decidir si los errores cuadráticos de los dos modelos son significativamente diferentes, se calculó el estadígrafo Diebold-Mariano (1995) como se encuentra en Franses (1998). Para calcular este estadígrafo, se crea una nueva variable $\{d_j\}_{j=T+1}^h$ que será igual a 1 cuando el error cuadrático del modelo Holt-Winters exceda al error cuadrático del modelo ARNAX, y cero en otros casos. El estadígrafo Diebold-Mariano (S) será entonces:

$$S = \frac{h}{4} \sum_{j=T+1}^h \mathbf{a} d_j - \frac{h}{2} \mathbf{0} : N(0,1)$$

que se distribuye con una densidad gaussiana estándar, por lo que podrá concluirse que el modelo ARNAX produce pronósticos más precisos cuando el estadígrafo Diebold-Mariano sea mayor a los valores críticos de la densidad normal estándar a niveles de confianza convencionales.

- En el pronóstico ex ante (diciembre 2008 a diciembre 2009) se predice los valores de la inflación más allá del período de entrenamiento y del período expost. El pronóstico ex ante es un pronóstico condicional porque los valores de las variables explicativas monetarias se desconocen y deben utilizarse pronósticos o suposiciones de estas variables para producir un pronóstico de la variable dependiente (inflación), que será condicional a los pronósticos del comportamiento futuro de los instrumentos monetarios.

3. Aplicación a la inflación en Guatemala

La serie de tiempo mensual de la inflación en Guatemala tiene tres períodos diferenciados:¹⁹ i) en 1996 se observa una inflación promedio de dos dígitos que alcanzó el 11.06 por ciento; ii) durante 1997 la inflación desciende y durante los años 1998 a 2007 se observa una inflación promedio de 6.89 por ciento; iii) sin embargo, en 2008 la inflación en Guatemala tuvo un incremento importante y alcanzó un 11.35 por ciento de promedio anual, que contrasta notoriamente con los bajos niveles de inflación promedio anual de los años 2006 (6.59 por ciento) y 2007 (6.81 por ciento). En julio de 2008 se observa de hecho una inflación de 14.16 por ciento, que es el valor máximo histórico de la inflación desde el año 1996. Como se verá más adelante, la especificación final ARNAX es capaz de reproducir la historia de la inflación, pero además aproxima bastante bien el incremento inflacionario del año 2008.

3.1 Especificación del modelo ARNAX

Existen diferentes teorías sobre las causas de la inflación, pero no existe una teoría universal que explique la inflación en todos los países (Serju, 2002). Por este motivo, el proceso de selección de variables candidatas como posibles predictoras estuvo guiado por investigaciones empíricas previas sobre el pronóstico de la inflación en Guatemala, específicamente por algunas de las variables adoptadas en Valle y Morán (2003). En la arquitectura del modelo ARNAX, se evaluó el poder predictivo de las variables:²⁰

- Índice Mensual de Actividad Económica (IMAE)
- Tasa de interés pasiva (promedio ponderado de las tasas pasivas de las entidades que componen el sistema financiero en Guatemala)
- Base monetaria
- Emisión monetaria

¹⁹ El comportamiento mensual de la inflación en Guatemala puede observarse en los gráficos 1 y 3.

²⁰ Los datos de estas variables y del ritmo inflacionario se obtuvieron del banco central de Guatemala en <http://www.banguat.gob.gt> (información económica y financiera, estadísticas económicas). Las series de tiempo tienen una periodicidad mensual, en el rango enero 1996 a noviembre 2008.

De este conjunto de variables, las variables con mayor poder predictivo resultaron ser la emisión monetaria y la tasa de interés pasiva. Adicionalmente, se utilizó la inflación rezagada un período (Y_{t-1}) como variable predictora. Nótese que el ritmo inflacionario y su rezago (componente autorregresivo) están expresados en niveles, en tanto que la tasa de interés pasiva y la emisión monetaria están expresadas en diferencias logarítmicas. La selección del número de unidades ocultas se realizó con el algoritmo de selección experta de arquitectura²¹ y se obtuvieron dos especificaciones intermedias, la primera con una capa oculta y la segunda con dos capas ocultas. Debido a la longitud limitada de las series de tiempo, se restringió la estimación a una capa oculta.

La especificación final del modelo ARNAX es un modelo con una capa oculta compuesta de dos nodos (dos funciones sigmoideas):

$$Y_t = w_0 + w_1 \frac{1}{1 + e^{-\{q_{1,1} + q_{1,2}i_t + q_{1,3}m_t + q_{1,4}y_{t-1}\}}} + w_2 \frac{1}{1 + e^{-\{q_{2,1} + q_{2,2}i_t + q_{2,3}m_t + q_{2,4}y_{t-1}\}}} + e_t,$$

donde Y_{t-1} es el retardo de la inflación en un período, i_t es la tasa de interés pasiva y m_t es la emisión monetaria. La arquitectura gráfica de la especificación final del modelo ARNAX puede verse en el gráfico 2, y los valores de los parámetros estimados se encuentran en la tabla 1. El modelo tiene un buen ajuste a los datos de la inflación en el segmento de entrenamiento (la raíz de la suma de errores cuadráticos es 5.7198 para el segmento de estimación) pero el ajuste es mucho mejor en el período de validación del entrenamiento (la raíz de la suma de errores cuadráticos es 2.4917 en este segmento).

3.2 Evaluación de la capacidad predictiva del modelo ARNAX en el período de pronóstico incondicional expost

Además del alto ajuste del modelo neuronal en el segmento de estimación, el poder de generalización del modelo es sorprendente, porque puede reproducir los puntos de inflexión y la tendencia ascendente del

²¹La descripción detallada de este algoritmo puede encontrarse en SPSS Inc. (2008).

ritmo inflacionario en el año 2008, a pesar de que ésta no es la dinámica general de la inflación en el período de estimación enero 1996-diciembre 2007.²² El modelo ARNAX predijo una inflación anual promedio de 10.57 por ciento para el año 2008, muy cercana a la inflación que se registró en Guatemala ese año (11.35 por ciento), sobre todo si se considera que el error estándar de los datos del pronóstico ARNAX es de ± 1.60 por ciento. Este resultado muestra la capacidad del modelo ARNAX de reproducir situaciones de respuestas no-proporcionales a la dinámica histórica de la inflación.

El poder predictivo del modelo ARNAX se evaluó comparando el pronóstico ARNAX con el pronóstico lineal de un modelo Holt-Winters, que es un método de extrapolación ampliamente utilizado en el contexto del pronóstico. El pronóstico del modelo ARNAX supera claramente al del modelo Holt-Winters, dado que los valores de las medidas de evaluación de pronóstico del modelo ARNAX son menores en todos los casos a las del pronóstico Holt-Winters: la raíz del error cuadrático medio del pronóstico ARNAX es igual a 1.3182, mientras que la del modelo Holt-Winters es 3.5121; el error promedio absoluto del pronóstico ARNAX es 1.1426, menor al valor de 2.9163 del modelo Holt-Winters; y el coeficiente de Theil es 0.0588 para el pronóstico ARNAX, menor al valor de 0.1724 del pronóstico lineal Holt-Winters.

Por último, para contrastar estadísticamente la hipótesis nula de que el pronóstico del modelo ARNAX no es superior al del modelo lineal Holt-Winters, se calculó el estadígrafo Diebold-Mariano y se obtuvo un valor de 2.7136, que permite rechazar la hipótesis nula a un nivel de significancia menor al 1% (el nivel de significancia exacto es 0.003327, véase la tabla 2).²³ Por tanto, y dado que puede rechazarse la hipótesis nula a niveles convencionales, *puede concluirse estadísticamente que el pronóstico del modelo neuronal ARNAX es significativamente más preciso que el pronóstico lineal Holt-Winters.*

²²Como señalaron Tkacz y Hu (1999), ésta es una ventaja de los modelos de redes neuronales artificiales: son capaces de incorporar movimientos inusuales en los datos.

²³Ilustrativamente, en la tabla 2 se colocaron también los valores críticos de la distribución estándar de Gauss al 1% y al 5%. Como puede observarse, el estadígrafo calculado de 2.7136 es mayor a los valores críticos al 5% (1.64) e incluso al 1% (2.32), por lo que puede rechazarse la hipótesis nula del test Diebold-Mariano.

3.3 Pronóstico ARNAX ex ante

Con base en el modelo ARNAX calibrado se pronosticó la inflación para el año 2009 condicional a los pronósticos de los instrumentos monetarios de emisión monetaria y de tasa de interés. Los valores fuera de muestra para el año 2009 de la emisión monetaria y la tasa de interés se obtuvieron con modelos ARIMA-EGARCH (modelos autorregresivos integrados de promedios móviles con aproximación al segundo momento mediante extensiones autorregresivas de heteroscedasticidad condicional generalizada exponencial):^{24, 25}

Modelo ARIMA([1,5,12],1,[1,4,5,12])-EGARCH(2,0,1) para la emisión monetaria:

$$m_t = \frac{a + (1 + Y_1 I + Y_2 I^2 + Y_3 I^3 + Y_4 I^4 + Y_5 I^5 + Y_{12} I^{12})e_{m,t}}{(1 - f_1 I - f_2 I^2 - f_3 I^3 - f_4 I^4 - f_5 I^5 - f_{12} I^{12})}$$

$$\log(s_{m,t}^2) = b + d_1 \left| \frac{e_{m,t-1}}{s_{m,t-1}} \right| + \sum_{k=1}^2 g_k \frac{e_{m,t-k}}{s_{m,t-k}}$$

Modelo ARIMA([1,2,3,4],1,1)-EGARCH(2,1,1) para la tasa de interés pasiva:

$$i_t = \frac{a + (1 + Y_1 I) e_{i,t}}{(1 - f_1 I - f_2 I^2 - f_3 I^3 - f_4 I^4)}$$

$$\log(s_{i,t}^2) = b + d_1 \log(s_{i,t-1}^2) + d_2 \left| \frac{e_{i,t-1}}{s_{i,t-1}} \right| + \sum_{k=1}^2 g_k \frac{e_{i,t-k}}{s_{i,t-k}}$$

donde,

m_t es la emisión monetaria (expresada en diferencias logarítmicas),

$s_{m,t}^2$ es la varianza condicional de la emisión monetaria,

i_t es la tasa de interés pasiva (expresada en diferencias logarítmicas),

$s_{i,t}^2$ es la varianza condicional de la tasa de interés pasiva,

$I^k Y_t = Y_{t-k}$ es el operador de rezagos,

$e_{m,t}$ son los residuos de la regresión biecualcional para la emisión monetaria,

$e_{i,t}$ Son los residuos de la regresión biecualcional para la tasa de interés pasiva,

y se obtuvo,²⁶

$$e_{m,t} \stackrel{i.i.d.}{\sim} N(m_t, s_{m,t}^2),$$

$$e_{i,t} \stackrel{i.i.d.}{\sim} N(i_t, s_{i,t}^2).$$

Con base en los pronósticos condicionales de los instrumentos monetarios, se calculó la inflación para el año 2009. El resultado puede verse en la tabla 4 y en los gráficos 3 y 4. El modelo ARNAX predice una inflación promedio anual para el año 2009 de 9.76 por ciento (con un error estándar de 0.33 por ciento), condicional tanto a que la tasa de interés pasiva se incremente en promedio en 0.44 por ciento durante el año 2009 (con un error estándar de 0.18 por ciento), como a que la emisión monetaria se incremente en

²⁴ Una descripción de los modelos ARIMA puede verse en Enders (1995). Los modelos Autorregresivos de Heteroscedasticidad Condicional (ARCH) fueron introducidos por Engle (1982) y generalizados (GARCH) por Bollerslev (1986). La representación asimétrica exponencial (EGARCH) fue desarrollada en Nelson (1991).

²⁵ Los resultados de la estimación de ambos modelos se encuentran en la tabla 3. El proceso de especificación de los modelos estuvo guiado por la minimización de los criterios de Akaike, Schwarz y Hannan-Quin, comparados entre modelos con residuos que aproximen ruido blanco estricto (residuos esféricos). El coeficiente de determinación (y el coeficiente de determinación ajustado) sugieren que la regresión de las primeras diferencias logarítmicas de la emisión tiene un mejor ajuste que la regresión de las primeras diferencias logarítmicas de la tasa de interés.

²⁶ Puede concluirse esfericidad aproximada de los residuos a partir de los resultados de las pruebas de autocorrelación, heteroscedasticidad y normalidad aplicados a los residuos: i) no se puede rechazar la hipótesis nula de no heteroscedasticidad condicional del test ARCH-LM de Engle a niveles convencionales; ii) la hipótesis nula de normalidad del test Jarque-Bera no se rechaza para los residuos de la regresión para la variable de tasa de interés, y se rechaza al 10% pero no al 5% para los residuos de la regresión de la emisión monetaria; iii) la hipótesis nula de no autocorrelación del test Q de Ljung-Box no puede rechazarse a niveles convencionales para los residuos de ambas regresiones, considerando doce o veinticuatro rezagos. Véase la tabla 3.

promedio en un 0.99 por ciento (error estándar de 2.67 por ciento) en la misma gestión.

Si bien la inflación promedio pronosticada para el año 2009 es menor que la inflación promedio del año 2008, los valores de la inflación se encuentran aún por encima del promedio histórico del ritmo inflacionario en Guatemala, igual a 7.74 por ciento. No debe olvidarse que el pronóstico de la inflación 2009 es condicional a los pronósticos de los instrumentos monetarios, por lo que las desviaciones significativas de la tasa de interés pasiva y de la emisión monetaria alterarían los pronósticos de inflación.

4. Conclusiones

De un conjunto de variables candidatas predictoras exógenas, la emisión monetaria y la tasa de interés resultaron más relevantes para el pronóstico no-lineal de la inflación en Guatemala con el modelo ARNAX.²⁷ En un experimento de seudopronósticos fuera de muestra basado en medidas de precisión de pronóstico y en el estadígrafo Diebold-Mariano, el modelo ARNAX demostró producir pronósticos más exactos que un modelo lineal Holt-Winters, pudiendo incluso reproducir el abrupto incremento del ritmo inflacionario el año 2008, que se desmarcó del comportamiento de la serie histórica de la inflación en Guatemala. Para el año 2009, el modelo ARNAX calibrado predice una inflación promedio de 9.76 por ciento, condicional a los pronósticos de los instrumentos monetarios.

Tanto la posibilidad de producir pronósticos de inflación más exactos, como la oportunidad de modelizar la respuesta no-proporcional (no-lineal) de la inflación a las variaciones de los instrumentos monetarios, justifican experimentar la utilización de

modelos no-lineales similares al modelo ARNAX presentado en esta investigación para contrastar estadísticamente el poder predictivo de los modelos lineales o como herramientas analíticas alternativas en un régimen de metas de inflación. Mejoras a la precisión y adecuabilidad teórica del modelo ARNAX pueden realizarse incluyendo otras variables exógenas, empleando pronósticos con métodos de *rolling*²⁸ y, dado que un pronóstico que subestime la inflación es más costoso que uno que la sobrestime, también puede calibrarse el modelo neuronal de forma que el pronóstico *ex post* minimice una función de costo asimétrica.

²⁷ Si bien la elección de las variables con mayor poder predictivo fue completamente dependiente de los datos y no se fundamentó en la teoría económica, existen posiciones teóricas que respaldan el uso de estas variables: Solera (2005) señaló que la inflación, en el mediano y largo plazo, tiene un origen estrictamente monetario, razón por la cual es de esperar que los agregados monetarios contengan información útil acerca de la dirección futura de la inflación; en tanto que Razzak (2002) resaltó la importancia de las tasas de interés en el pronóstico de la inflación.

²⁸ En el método *rolling* se pronostica la inflación a un paso y una vez que se cuenta con nueva información se re-estiman los parámetros del modelo y se realiza un nuevo pronóstico; de esta manera los estimadores de los parámetros no son fijos sino que se actualizan cada vez que se cuenta con una nueva observación.

- Aristizábal, María Clara (2006). *Evaluación asimétrica de una red neuronal artificial: aplicación al caso de la inflación en Colombia*. Lecturas de Economía, 65 (julio-diciembre). pp. 73-116.
- Bollerslev, Tim (1986). *Generalized Autoregressive Conditional Heteroscedasticity*. Journal of Econometrics 31, pp. 307-327.
- Bukhari, S. Adnan, H. A. S. Bukhari, Muhammad Nadeem Hanif (2007). *Inflation forecasting using artificial neural networks*. Munich Personal RePEc Archive Paper No. 8898.
- Chen, Xiaohong, Jeffrey Racine, Norman Swanson (2001). *Semiparametric ARX neural network models with an application to forecasting inflation*. Department of Economics, London School of Economics.
- Diebold, Francis X., Robert S. Mariano (1995). *Comparing predictive accuracy*. Journal of Business & Economic Statistics, July, Vol. 13, No. 3, pg. 253, American Statistical Association.
- Enders, Walter (1995). *Applied econometric time series*. Ed. Jhon Wiley & Sons, Inc.
- Engle, Robert F. (1982). *Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation*. Econometrica Vol. 50, No. 4, pp. 987-1007.
- Franses, Philip Hans (1998). *Time series models for business and economic forecasting*. Cambridge University Press, pp. 280.
- Friedman, Milton (1968). *The role of monetary policy*. The American Economic Review, Volume LVIII, March, Number 1.
- Granger, Clive (2008). *Non-linear models: where do we go next - time varying parameter models?* Studies in Nonlinear Dynamics & Econometrics, Volume 12, Issue 3. Article 1, pp. 1-9.
- Kajitani, Yoshio, Keith W. Hipel, A. Ian McLeod (2005). *Forecasting nonlinear time series with feed-forward neural networks: a case study of canadian Lynx Dara*. Journal of Forecasting, 24, pp. 105-117.
- McNelis, Paul, Peter McAdam (2004). *Forecasting inflation with tick models and neural networks*. European Central Bank, Working Paper Series No. 352.
- Nakamura, Emi (2005). *Inflation forecasting using a neural network*. Department of Economics, Harvard University.
- Nelson, Daniel B. (1991). *Conditional heteroscedasticity in asset returns: a new approach*. Econometrica, Volume 59, Issue 2, pp. 347-370
- Norman Loayza, Raimundo Soto (2002). *Inflation targeting: design, performance, challenges*. Banco Central de Chile.
- Pindyck, Robert S., Daniel Rubinfeld (1998). *Econometría: modelos y pronósticos*. 4a. edición, McGraw-Hill, 661 páginas.
- Razzak, WA (2002). *Monetary policy and forecasting inflation with and without the output gap*. Reserve Bank of New Zealand, Discussion Paper Series DP2002/03.
- Serju, Prudence (2002). *Monetary conditions & core inflation: an application of neural networks*. Research Services Department, Bank of Jamaica.
- Solera Ramírez, Álvaro (2005). *Pronóstico de inflación en Costa Rica: una estimación con redes neuronales artificiales*. División Económica, Departamento de Contabilidad Social DCS-155-2005.

- Stock, James H., Mark W. Watson (1999). *Forecasting inflation*. Journal of Monetary Economics, Elsevier, vol. 44(2). pages 293-335.
- Svensson, Lars E. O. (2007). *Inflation targeting*, The New Palgrave Dictionary of Economics. 2nd edition, edited by Larry Blum and Steven Durlauf.
- Tkacz, Greg, Sarah Hu (1999). *Forecasting GDP growth using artificial neural networks*. Working Paper 99-3, Bank of Canada.
- Valle Samayoa, Héctor Augusto, Hilcias Estuardo Morán Samayoa (2003). *Estimación y evaluación de modelos alternativos de pronósticos de inflación en Guatemala*. VII Reunión de la Red de Investigadores de Bancos Centrales del Continente Americano, Centro de Estudios Latinoamericanos.
- SPSS Inc. (2008). *SPSS Statistics 17.0 Algorithms*, 233 South Wacker Drive, Chicago.




Gráfico 1. Partición de la serie de tiempo de la inflación para el ajuste y pronóstico ARNAX

Gráfico 2. Arquitectura del modelo ARNAX

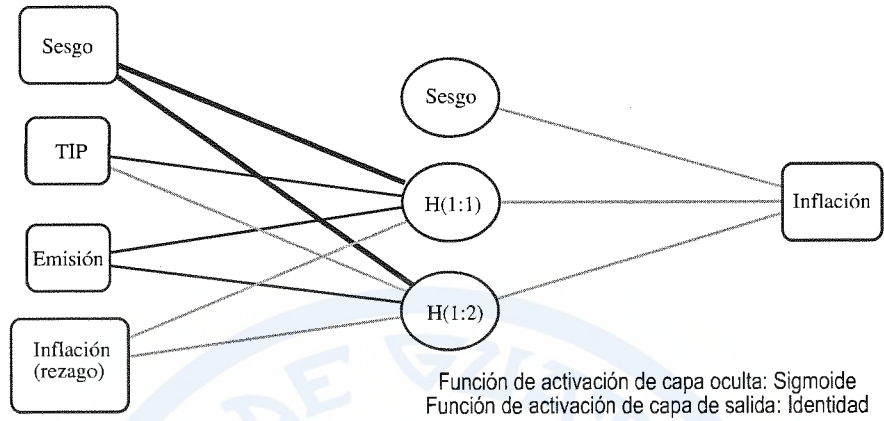


Gráfico 3. Inflación y pronóstico de la inflación ARNAX ex ante y ex post

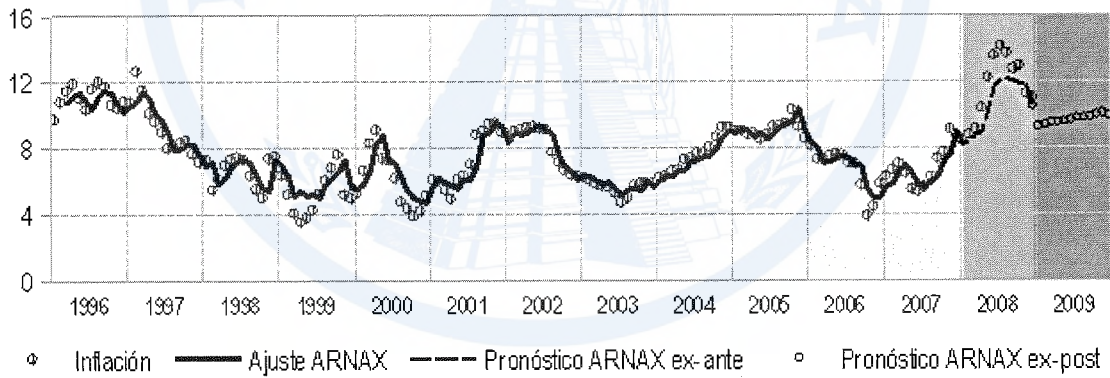


Gráfico 4. Pronóstico de los instrumentos monetarios y su varianza condicional (expost para la gestión 2008 y exante para la gestión 200)

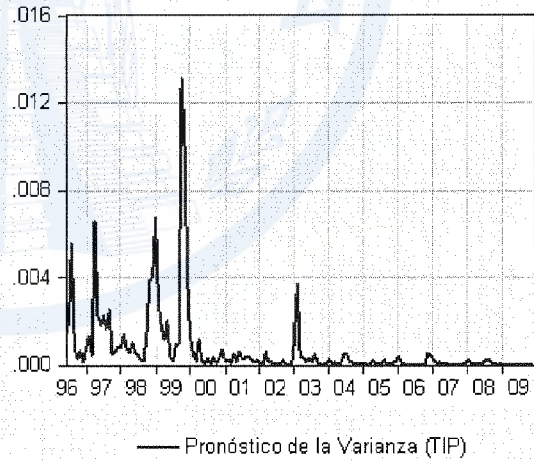


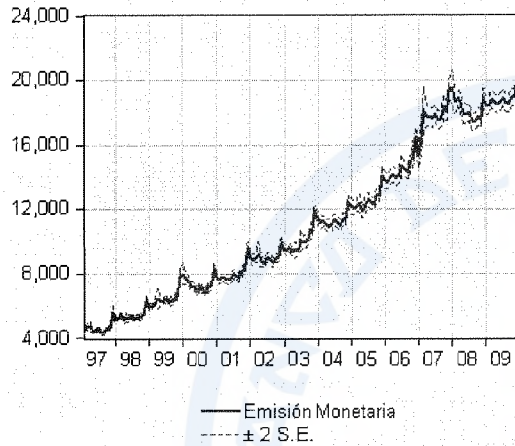


Tabla 1. Estimación de los parámetros del modelo ARNAX y ajuste en el segmento de entrenamiento y validación

Capa de Salida		Capa oculta nodo I		Capa oculta nodo II	
Parámetros	Estimadores	Parámetros	Estimadores	Parámetros	Estimadores
ω_0	5.107	$\theta_{1,1}$	-5.179	$\theta_{2,1}$	0.345
ω_1	7.384	$\theta_{1,2}$	0.595	$\theta_{2,2}$	-0.324
ω_2	-1.231	$\theta_{1,3}$	-0.007	$\theta_{2,3}$	-0.086
		$\theta_{1,4}$	0.047	$\theta_{2,4}$	0.544
Raíz de la suma de cuadrados de los errores					
Segmento de entrenamiento			5.7198		
Segmento de validación			2.4917		

Tabla 2. Validación ex post de la capacidad predictiva del modelo ARNAX y comparación con el pronóstico Holt-Winters. Período: enero a noviembre 2008

	Inflación	Pronóstico Holt-Winters	Pronóstico ARNAX
Enero	8.39	8.74	8.23
Febrero	8.76	8.72	8.32
Marzo	9.10	8.71	8.79
Abril	10.37	8.70	8.96
Mayo	12.24	8.69	10.27
Junio	13.56	8.67	11.66
Julio	14.16	8.66	12.08
Agosto	13.69	8.65	12.18
Septiembre	12.75	8.64	12.10
Octubre	12.93	8.62	11.86
Noviembre	10.85	8.61	11.92

Evaluación de los Pronósticos (ex post)

Raíz del error cuadrático medio	3.5121	1.3182
Error promedio absoluto	2.9163	1.1426
Coefficiente de Theil	0.1724	0.0588

Estadígrafo Diebold- Mariano para comparar la exactitud del pronóstico

Estadígrafo	2.713602	Valores críticos:	
p-value	0.003327	nivel del 1%	2.32
		nivel del 5%	1.64

Tabla 3. Regresiones para los pronósticos ex ante de los instrumentos monetarios (predictores ARNAX)

Período de estimación: enero 1996-diciembre 2008

Regresión para la Emisión Monetaria		Regresión para la Tasa de Interés Pasiva	
Parámetro	Estimador	Parámetro	Estimador
Y_1	-0.01148	Y_1	-0.69212
Y_5	0.02021	Y_2	0.45827
Y_{12}	0.91275	Y_3	0.41059
f_1	0.09233	Y_4	0.25338
f_4	0.21821	f_1	0.96458
f_5	-0.11618		
f_{12}	-0.90176		
Ecuación de la varianza		Ecuación de la varianza	
b	-8.49998	b	-2.38394
s_1	0.57033	s_1	1.27339
g_1	0.18904	s_2	-0.15559
g_2	0.11203	g_1	0.39567
		g_2	0.82867

Ajuste de la regresión

R^2	0.794659	R^2	0.344628
R^2 (ajustado)	0.779103	R^2 (ajustado)	0.298905

Criterios de información

Akaike	-5.02588	Akaike	-5.19995
Schwarz	-4.79797	Schwarz	-4.98840
Hannan-Quin	-4.93332	Hannan-Quin	-5.11372

Test ARCH-LM de Engle (residuos)*

Estadígrafo F	1.35743	Estadígrafo F	0.398272
	(0.2460)		(0.5290)

Test de normalidad (residuos)*

Jarque-Bera	5.009576	Jarque-Bera	2.763680
	(0.081693)		(0.251116)

Test de Autocorrelación Q de Ljung-Box (residuos)*

Q(12)	8.1024	Q(12)	11.653
	(0.151)		(0.113)
Q(24)	14.220	Q(24)	26.326
	(0.651)		(0.121)

(*) p-values entre paréntesis

Tabla 4. Pronóstico ex ante de la inflación condicional a los pronósticos de los instrumentos monetarios. Período: diciembre 2008 a diciembre 2009

	Pronóstico TIP	Pronóstico emisión	Pronóstico ARNAX
Diciembre	0.75	6.45	10.53
Enero	0.73	-2.50	9.31
Febrero	0.60	0.08	9.37
Marzo	0.53	2.17	9.48
Abril	0.57	-0.74	9.52
Mayo	0.39	-1.08	9.54
Junio	0.47	1.05	9.66
Julio	0.31	1.10	9.78
Agosto	0.39	-1.50	9.78
Septiembre	0.24	-0.26	9.86
Octubre	0.32	2.17	9.99
Noviembre	0.18	0.02	10.08
Diciembre	0.27	5.91	9.94
Est. Descriptivas (anuales)			
Promedio	0.44	0.99	9.76
Error estándar	0.18	2.67	0.33