

DOCUMENTOS DE TRABAJO

ISSN 2409-1863
DT 036-Noviembre 2013
Banco Central de Nicaragua

Modelos de Serie de Tiempo para Pronóstico del IMAE

Ivonne Acevedo J.



Banco Central de Nicaragua
Emitiendo confianza y estabilidad



Banco Central de Nicaragua

Modelos de Series de Tiempo para Pronósticos del IMAE

Ivonne Acevedo J.

Primera Versión

Noviembre, 2013

La serie de documentos de trabajo es una publicación del Banco Central de Nicaragua que divulga los trabajos de investigación económica realizados por profesionales de esta institución o encargados por ella a terceros. El objetivo de la serie es aportar a la discusión de temas de interés económico y de promover el intercambio de ideas. El contenido de los documentos de trabajo es de exclusiva responsabilidad de su(s) autor(es) y no reflejan necesariamente la opinión del Banco Central de Nicaragua. Los documentos pueden obtenerse en versión PDF en la dirección <http://www.bcn.gob.ni/>

The working paper series is a publication of the Central Bank of Nicaragua that disseminates economic research conducted by its staff or third parties sponsored by the institution. The purpose of the series is to contribute to the discussion of relevant economic issues and to promote the exchange of ideas. The views expressed in the working papers are exclusively those of the author(s) and do not necessarily reflect the position of the Central Bank of Nicaragua. PDF versions of the papers can be found at <http://www.bcn.gob.ni/>.



Modelos de Series de Tiempo para Pronósticos del IMAE

Ivonne Acevedo J.¹

Primera Versión

Noviembre, 2013

Resumen: En este trabajo se evalúa el desempeño de modelos no lineales (SETAR y LSTAR) y modelos lineales de series de tiempo en la generación de predicciones de corto plazo para el IMAE de Nicaragua. Para evaluar el desempeño de los modelos se realizan predicciones fuera de muestra del IMAE para horizontes de 1, 3 y 6 meses hacia adelante. Los resultados dan cuenta que en términos relativos a la suma de errores al cuadrado hay ganancias en utilizar modelos no lineales, como el LSTAR y SETAR, principalmente en horizontes de predicción cortos. Sin embargo, el aporte más relevante es que los modelos no lineales muestran en promedio igual desempeño en términos de predicción fuera de muestra que modelos lineales utilizados como *benchmark*.

Palabras claves: Series de tiempo, Pronósticos, Modelos no lineales

Código JEL: C22, C5, C53

¹ E-mail: jacevedoj@bcn.gob.ni

1. Introducción

El objetivo de este trabajo es evaluar el desempeño de distintos modelos de series de tiempo en la generación de predicciones de corto plazo para la actividad económica de Nicaragua. Específicamente, se pretende investigar si modelos no lineales tienen mayor capacidad, en términos de eficiencia y precisión, para predecir el comportamiento del Índice Mensual de Actividad Económica (IMAE) en comparación con los modelos tradicionales de series de tiempo utilizados en la literatura. El análisis se centra en realizar predicciones fuera de muestra para el IMAE en el período comprendido entre enero 2008 y julio 2013. Las proyecciones de los modelos no lineales son comparadas con modelos univariados simples. La comparación con estos últimos se hace para proyecciones en horizontes de 1, 3 y 6 meses hacia adelante.

Inicialmente, la utilización de modelos ARIMA para realizar predicciones fue introducida a través de los trabajos pioneros de Box y Jenkins (1970). Esta especificación resultó muy efectiva a pesar de la facilidad de estimación y es utilizada frecuentemente como modelo de referencia. Por su parte, Sims (1980) introdujo la utilización de modelos de Vectores Autorregresivos (VAR) en la literatura de pronósticos al aplicarlo para analizar el comportamiento del crecimiento del PIB de Estados Unidos. Posteriormente, Litterman (1986) realizó una extensión a los modelos VAR incorporando estimaciones bayesianas para reducir el número de parámetros a estimar. Asimismo, Engle y Granger (1987) propusieron la utilización del vector de corrección de errores para incorporar la cointegración de las variables macroeconómicas.

Luego, Hamilton (1989) introdujo por primera vez métodos para analizar la evolución del PIB de Estados Unidos tomando en cuenta no linealidades mediante el uso de Modelos de *Markov Switching*. Por otro lado, Clements y Krolzig (1998) utilizan un modelo SETAR para el crecimiento de posguerra de Estados Unidos, del cual concluyen que el desempeño del pronóstico es condicional al régimen. Granger y Teräsvirta (1993) extendieron la utilización de modelos de transición suave, conocidos como STAR, para evaluar la no-linealidad entre diferentes variables económicas y financieras.

Asimismo, recientemente se ha utilizado modelos con fundamentos microeconómicos, conocidos como modelos de equilibrio general dinámico y estocástico (DSGE), para realizar pronósticos. Smets y Wouters (2004) utilizan un DSGE con economía cerrada para la Zona Euro y sus resultados sugieren que estos modelos tienen un desempeño relativamente adecuado en comparación con los modelos VAR. Por su parte, Christoffel, Coenen y Warne (2010) utilizan un DSGE con economía abierta para la Zona Euro y concluyen que también pueden competir bien con modelos de forma reducida.

Con respecto a la aplicación de modelos no lineales para fines predictivos Marcellino (2007) argumenta que los modelos simples de series de tiempo pueden proporcionar un punto de referencia razonable para evaluar proyecciones. Sin embargo, los cambios políticos, sociales y económicos podrían ocasionar que los parámetros de los modelos no sean lineales. En este sentido, el autor hace énfasis en que los modelos no lineales podrían tener una ventaja con respecto a las especificaciones lineales.

La evidencia empírica sobre la mejora en desempeño predictivo de los modelos no lineales es mixta. Por un lado, Tiao y Tsay (1994) utilizando un modelo de umbral encuentran mejoras en la proyección del PIB de EE.UU. En cambio, Clements y Smith (2001) concluyen que los pronósticos SETAR no son más precisos que los obtenidos con un proceso de caminata aleatoria para diversas series de tipo de cambio. Stock y Watson (1999)² consideran más de 200 variables reales y financieras de los EE.UU. y muestran que los métodos LSTAR rara vez mejoran las proyecciones, en comparación con un modelo AR lineal. Sin embargo, señalan que los métodos no lineales tienen más éxito para los salarios, el empleo y el tipo de cambio, especialmente para horizontes de predicción más largos.

Para Nicaragua la evidencia empírica relacionada con proyecciones y evaluación de pronósticos crecimiento no es extensa. Bello (2007) elaboró un modelo macroeconómico para la economía nicaragüense con el fin de proyectar en el corto plazo variables macroeconómicas claves y proveer una estructura dentro de la cual se pueda ejecutar simulaciones de diferentes escenarios de política³. El modelo se estimó en frecuencia trimestral para el período 1994:1 y 2007:1 mediante la metodología de corrección de errores. Asimismo, Espinoza, Iraheta y Sánchez (2012) elaboraron un modelo econométrico para proyectar el crecimiento económico y el ritmo inflacionario considerando las principales variables económicas de la región Centroamericana y República Dominicana.

Acevedo (2013) utilizando la metodología de análisis factorial desarrollada por Stock y Watson (1989 y 1991) elaboró un sistema de indicadores de alerta temprana para el IMAE de Nicaragua. Los resultados de los indicadores de alerta temprana para la economía nicaragüense prevén estabilidad relativa en el corto plazo, en el sentido que existe una probabilidad elevada de que la economía se mantenga con un crecimiento similar al promedio histórico. Sin embargo, en estos trabajos no se evalúa el desempeño de los pronósticos, lo cual es relevante para determinar si un modelo y/o método posee mayor capacidad predictiva que otro, o si se podría generar ganancias en la combinación de pronósticos de diversas fuentes.

De tal forma que este trabajo constituye un primer esfuerzo en el campo de evaluación de las proyecciones de crecimiento de Nicaragua. La comparación de pronósticos se realiza con proyecciones fuera de muestra para datos mensuales del IMAE, generados por 4 modelos univariados⁴. Como *benchmark* se utiliza dos especificaciones de modelos AR lineales y estos se comparan con modelos autorregresivos de transición (SETAR) y de transición suave (LSTAR). Los resultados de la investigación muestran que los modelos no lineales pueden ser una forma adecuada para mejorar las proyecciones. Los resultados dan cuenta que en términos relativos a

² Citado en Marcellino (2007).

³ Bello (2009) implementó diferentes técnicas de combinación de pronósticos con diversos modelos para la inflación de Nicaragua, evaluando la habilidad predictiva mediante pruebas de abarcamiento.

⁴ Ferrara, Marcellino y Mogliani (2012) señalan que para realizar proyecciones las especificaciones de modelos no lineales univariadas son más adecuadas que las especificaciones no lineales multivariadas, como el VAR no lineal, ya que estos últimos pueden conllevar a un exceso de parametrización que podría sesgar las proyecciones.

la suma de errores al cuadrado hay ganancias en utilizar modelos no lineales, como el LSTAR y SETAR, principalmente en horizontes de predicción cortos. Adicionalmente, el aporte más relevante es que los modelos no lineales muestran en promedio igual desempeño en términos de predicción fuera de muestra que el modelo lineal de referencia para los horizontes considerados.

Lo que resta del documento está estructurado de la siguiente manera. En la segunda sección se describe los modelos de series de tiempo que se implementarán con fines de predicción. En la tercera sección se presenta la metodología para obtener la especificación de estos modelos, resaltando los criterios utilizados para determinar el rezago óptimo. Los resultados se muestran en la sección 4 y finalmente la sección 5 concluye.

2. Modelos de proyección

En esta sección se discute brevemente las características de los modelos, así como los métodos de estimación, que se utilizarán para proyectar el crecimiento del IMAE. Las especificaciones que se utilizan corresponden a modelos univariados de series de tiempo lineales (AR) y no lineales, como el SETAR, STAR y redes neuronales.

2.1 AR

Los modelos autorregresivos (AR) parten de identificar qué tipo de proceso estocástico genera la serie de tiempo utilizando rezagos de la misma variable sin recurrir a variables explicativas exógenas. Estos modelos fueron aplicados con fines de pronóstico por Box y Jenkins (1970) y se han desempeñado adecuadamente en comparación con otros modelos más complejos.

Pincheira y García (2009) señalan que es importante contar con modelos de referencia adecuados para realizar una evaluación exigente de las proyecciones provenientes de nuevos modelos que surgen en la literatura. Los modelos univariados de series de tiempo son utilizados frecuentemente como referencia debido a la facilidad de generar proyecciones en plazos razonables de tiempo. No obstante, los autores resaltan que a pesar de que estos modelos han sido usados extensamente en la literatura todavía no hay consenso en torno a su especificación.

Los modelos $AR(p)$ se describen de la siguiente manera:

$$y_t = \beta_0 + \sum_{i=1}^p \beta_i y_{t-i} + \epsilon_t \quad (1)$$

En (1) p indica el orden autorregresivo, β_i son los parámetros del modelo y ϵ_t es el error estocástico. Para realizar las predicciones con el modelo AR el primer paso consiste en

seleccionar el orden p . Para ello se utiliza el criterio de Hannan-Quinn, ya que la selección del modelo es consistente y parsimoniosa⁵.

2.2 SETAR

Los modelos TAR (por sus siglas en inglés, *Threshold Autoregressive Models*) constituyen una rama de los modelos no lineales de series de tiempo, y fueron propuestos inicialmente por Tong (1978). Estos modelos suponen un cambio de régimen que sigue esta representación:

$$y_t = \left(\beta_0 + \sum_{i=1}^p \beta_i y_{t-i} \right) I(y_{t-d} \leq q) + \left(\alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} \right) I(y_{t-d} > q) + \epsilon_t \quad (2)$$

En (2) β y α son los parámetros asociados a los regímenes que sigue y_t en función del valor que adopte la función indicador $I(\cdot)$. Esta función es dicotómica y toma el valor de 1 si se cumple la condición y 0 en caso contrario. La variable de umbral está representada por y_{t-d} y q es el parámetro de umbral. Cuando la variable de umbral toma el valor rezagado de la variable dependiente, al modelo se le denomina SETAR (por su siglas en inglés, *Self-exciting Threshold Autorregressive Model*).

Leyva (2008) describe detalladamente el proceso de estimación de modelos SETAR. Éste implica la estimación adicional de los parámetros de umbral (d y q), los cuales se estiman de manera conjunta por medio de mínimos cuadrados. El algoritmo que se emplea consiste en estimar los parámetros de (2) mediante mínimos cuadrados ordinarios, calculando para cada una la suma de residuos al cuadrado. Los valores estimados de los parámetros de umbral se encuentran resolviendo:

$$\{\hat{q}, \hat{d}\} = \min_{q \in Q; d \in D} \frac{1}{n} \sum_{t=1}^T (y_t - x_t(q)' \hat{\theta}(q))^2 \quad (3)$$

Para detectar la presencia del umbral se realiza un test, donde la hipótesis nula es linealidad, $H_0: \beta = \alpha$. Hansen (1996) propone un procedimiento basado en *bootstrap* para generar la distribución empírica de una test LM mediante el cual se obtienen las probabilidades exactas que permiten realizar un análisis de inferencia adecuado.

2.3 STAR

Los modelos STAR (por sus siglas en inglés, *Smooth Transition Autoregressive Model*) permiten el cambio endógeno de un régimen a otro asociado a condiciones económicas particulares o al comportamiento de una variable en específico (Carpio y Mendoza, 2007). En los modelos

⁵ Para seleccionar el modelo las comparaciones se realizaron con el mismo tamaño de muestra para un rezago máximo de 6.

regresivos con transición suave la no linealidad es descrita a través del comportamiento de una variable denominada variable de transición.

El modelo genérico se describe de la siguiente manera:

$$y_t = \left(\beta_0 + \sum_{i=1}^p \beta_i y_{t-i} \right) F(y_{t-d}; \gamma, q) + \left(\alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} \right) (1 - F(y_{t-d}; \gamma, q)) + \epsilon_t \quad (4)$$

En (4) β y α son los parámetros del modelo, $F(\cdot)$ representa la función de transición y el parámetro γ regula la transición del régimen. En la literatura empírica tradicionalmente se han utilizado dos especificaciones para la función $F(\cdot)$, las funciones logística y exponencial⁶. Para la función logística la forma funcional es:

$$F(y_{t-d}, q, \gamma) = (1 + \exp(-\gamma(y_{t-d} - q)))^{-1} \quad \forall \gamma > 0 \quad (5)$$

En tanto, la función exponencial es:

$$F(y_{t-d}, q, \gamma) = 1 - \exp(-\gamma(y_{t-d} - q)^2) \quad \forall \gamma > 0 \quad (6)$$

Para estimar un modelo STAR, Granger y Teräsvirta (1993) recomiendan tres etapas. En la primera etapa, se estima el modelo lineal. En la segunda, se aplica la prueba de linealidad para los modelos STAR, siguiendo el procedimiento de la prueba de aproximación de Taylor introducido por Luukkonen, Saikkonen y Teräsvirta (1988). Por último, si la linealidad es rechazada, se elige entre el modelo de regresión que admite una transición suave logística (LSTAR) y el modelo de regresión que admite una transición suave exponencial (ESTAR), mediante la comprobación de una secuencia de hipótesis⁷.

2.4 Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN, siglas en inglés) constituyen un instrumento para la aproximación de funciones no lineales. En la literatura empírica Swanson y White (1997) y White (2006) son algunos que han empleado esta técnica con fines de pronósticos de variables económicas. Para la región, Leyva (2008) y Esquivel (2009) utilizan esta metodología para realizar pronósticos de inflación para Guatemala y Costa Rica, respectivamente.

Los modelos ANN toman un conjunto de *inputs* y producen un set de *outputs* según una relación de correspondencia, que puede clasificarse en términos generales como mapa vectorial. El diseño de una ANN incluye un conjunto de nodos y capas ocultas. La representación de un tipo de modelo de red neuronal puede expresarse como:

⁶ Para mayores detalles sobre modelos STAR ver Granger y Teräsvirta (1993) y Teräsvirta (1994).

⁷ Existen pruebas estadísticas ideadas para escoger entre las dos funciones utilizadas en la literatura. Véase Escribano y Jordá (1997) para mayores detalles.

$$y_t = \beta_o + \sum_{j=1}^p \beta_j y_{t-j} + \sum_{i=1}^L \gamma_i F \left(\beta_{0,i} + \sum_{j=1}^p \beta_{j,i} y_{t-j} \right) + \epsilon_t \quad (7)$$

En (7), $F(\cdot)$ es la función logística $F(x) = 1/(1 + e^x)$. En este caso, los *inputs* son los p rezagos de la variable y_t , y L son las unidades ocultas dentro de solo una capa oculta. Para la estimación de modelos ANN se utiliza la metodología propuesta por White (2006). Primero, se elige el orden autorregresivo de una especificación lineal, luego se prueba especificaciones de manera secuencial hasta un número máximo arbitrario de unidades ocultas L . La regla de decisión para elegir el número de unidades ocultas consiste en la especificación de red neuronal que produzca la menor suma de residuos al cuadrado.

3. Resultados

En esta sección se presenta los resultados de la evaluación de pronósticos que se realiza sobre la base de los modelos expuestos en la sección anterior. Para este fin, primeramente se detalla la muestra que se emplea para realizar las estimaciones y el período de tiempo. Luego, se realiza una explicación del proceso de estimación de cada modelo, el cual incluye una breve descripción de la aplicación de la metodología para seleccionar el rezago óptimo de las especificaciones. Posteriormente, se presenta la evaluación de la capacidad de predicción, tanto incondicional como condicional, de los modelos. Finalmente, se realiza una combinación de pronósticos de los modelos no-lineales con el *benchmark* tradicional.

Para realizar este ejercicio se utiliza la tasa de crecimiento interanual de la serie mensual del IMAE de enero 1994 a julio 2013. Para efectos de estimación y evaluación de pronósticos fuera de muestra se divide el período total en dos. La ventana de estimación corresponde a 1994.01-2006.12, para un total de 144 observaciones. Mientras que el resto de la muestra es utilizada para realizar evaluación de pronósticos fuera de muestra (79 observaciones). Las proyecciones se realizan en horizontes de 1, 3 y 6 meses hacia adelante.

En la tabla 1 se resume las estadísticas descriptivas para las dos sub-muestras. Para la ventana de evaluación la tasa de crecimiento interanual oscila entre -8 y 26.2 y para la ventana de estimación -8.5 y 11 por ciento. De acuerdo a Leyva (2008) el amplio rango de oscilación de la serie podría ser un indicio de la presencia efectos asimétricos o no-lineales. Por otro lado, el test de Jarque-Bera rechaza la hipótesis nula de normalidad, lo que indica que la serie no presenta evidencia de que el proceso generador de datos del IMAE siga una distribución normal.

Tabla 1. Estadísticas descriptivas, tasa de crecimiento interanual del IMAE

Estadístico	Ventana de Estimación 1994.01-2006.12	Ventana de evaluación 2007.01-2013.07
N	144	79
Media	5.5	3.5
Mediana	5.6	4.0
Mínimo	-8.0	-8.5
Máximo	26.2	11.8
Desviación Estándar	5.8	4.1
Jarque-Bera ^{1/}	8.1	15.6
Asimetría	0.3	-1.0
Kurtosis	3.9	4.0

1/: Se rechaza la hipótesis nula de normalidad. El *p-value* es significativo al 5% para ambas muestras.

Fuente: Cálculos del autor.

3.1 Estimación de modelos

Antes de estimar los modelos para realizar pronósticos es necesario realizar pruebas que respalden la aplicación de modelos no lineales, así como seleccionar el orden autorregresivo para cada una de las especificaciones⁸.

Para la selección del rezago óptimo en el modelo AR se utilizó el criterio de información Hannan-Quinn (HQC) por ser consistente y parsimonioso. En el anexo A.1a se presenta los resultados para los tres criterios de información utilizados en la literatura. De acuerdo a HQC el modelo lineal corresponde a un $AR(3)$. Cabe destacar que para realizar la selección de la mejor especificación se realizaron combinaciones hasta un máximo de 6 rezagos con el mismo tamaño de la muestra, de tal forma que los resultados puedan ser comparables⁹. Asimismo, para efectos de evaluación y combinación de pronósticos se utilizó un modelo $AR(1)$ por ser un *benchmark* tradicional en la literatura de pronósticos.

El orden p del modelo SETAR se obtuvo mediante la aplicación de la prueba de linealidad propuesta por Hansen (1997), al igual que el modelo lineal se optó por realizar la prueba para un máximo de 6 rezagos. De acuerdo a los resultados de la prueba, para un $p = 6$ se rechaza la hipótesis nula de linealidad. En el anexo A.1b se muestra los resultados detallados de la prueba y los *p-values*.

⁸ Para la estimación de modelos SETAR y STAR se realizaron modificaciones a los códigos de Bruce Hansen.

⁹ Debido al tamaño de la muestra se optó por un máximo de rezagos de 6 para tener un número razonable de grados de libertad en las estimaciones de los modelos.

Para determinar el orden del STAR se utilizó la prueba de linealidad propuesta por Luukkonen et al. (1998) y aplicada en experimentos por Teräsvirta (1994). Según esta prueba el orden autorregresivo es $p = 2$, rechazando para este orden la hipótesis nula de linealidad con la aproximación de primer orden. La selección de la forma funcional de $F(\cdot)$ se realiza con base en la teoría, la cual sugiere el uso de un modelo logístico para capturar posibles comportamientos asimétricos para valores extremos de la variable de estudio (Carpio y Mendoza, 2007). De esta manera, se estima una especificación LSTAR con un orden autorregresivo igual a 2. En el anexo A.1c se presenta los resultados para esta especificación.

Siguiendo el procedimiento establecido por White (2006), en el anexo A.1d se presenta el resultado del *quicknet* realizado para identificar el número de unidades ocultas para un $AR(1)$. Para seleccionar si la serie puede modelarse como una red neuronal se escoge la capa oculta que minimice la suma de errores al cuadrado (SSR). Según los resultados obtenidos, la menor SSR corresponde a cero, por lo que no se utilizará una especificación de red neuronal para modelar la tasa de crecimiento interanual del IMAE.

En la siguiente tabla se resume el orden del rezago para los modelos AR, SETAR y STAR obtenidos bajo estas metodologías.

Tabla 2. Especificaciones seleccionadas para modelos

p	AR	SETAR	STAR
1	3.4753	0.418	0.352
2	3.4425	0.289	0.088
3	3.4355	0.549	0.335
4	3.4610	0.414	0.262
5	3.4821	0.830	0.154
6	3.5101	0.011	0.364

Nota: Para el modelo AR se muestra el criterio de información HQC; para SETAR se muestra el *p-value bootstrap*; en la columna del STAR se muestra el *p-value* de la aproximación de Taylor de primer orden. En negrita se presenta el orden del proceso autorregresivo seleccionado.

Fuente: Cálculos del autor.

Con base en estas especificaciones se estimaron los modelos lineales y no lineales para realizar pronósticos fuera de muestra de la tasa de crecimiento interanual del IMAE. Los resultados de los pronósticos obtenidos fuera de muestra se presentan en el anexo A.2. Los gráficos contienen

la trayectoria de la tasa de crecimiento interanual del IMAE para horizontes de 1, 3 y 6 meses adelante, así como la serie observada en el período 2007.1-2013.7¹⁰.

A partir de la inspección visual de los gráficos se observa que para el horizonte de un mes hacia adelante, los modelos lineales $AR(1)$ y $AR(3)$, parecieran tener un mejor desempeño que los modelos no lineales. Para los horizontes de 3 y 6 meses hacia adelante los modelos no lineales siguen en cierta medida la trayectoria observada de la serie. En cambio, los modelos lineales convergen a una línea recta.

No obstante, para determinar si un modelo y/o método es superior en términos de habilidad predictiva se debe evaluar su desempeño de acuerdo a una métrica. En el siguiente apartado se realiza este ejercicio.

3.2 Evaluación de Pronósticos

Para determinar si un modelo o método de proyección es superior a otro existen diversos criterios de evaluación, como pruebas de encompassamiento o el tamaño relativo de la función de pérdida. En este trabajo, se utiliza el error cuadrático medio (ECM) como función de pérdida. Para evaluar si las diferencias en ECM entre dos métodos son estadísticamente significativas se utilizará la prueba de evaluación predictiva propuesta por Giacomini y White (2006). El marco analítico propuesto por estos autores está en línea con los aportes realizados previamente por Diebold y Mariano (1995) y West (1996).

La prueba propuesta por Giacomini y White (2006) está orientada a evaluar un método de proyección y no un modelo de proyección. En este aspecto, la prueba considera la incertidumbre asociada a la estimación de los parámetros y permite comparar pronósticos obtenidos con ventanas de pronósticos distintas así como pronósticos de modelos anidados. Asimismo, los autores también proponen una variación para evaluar la habilidad predictiva condicional a información que se cree tiene alguna relevancia para determinar entre la capacidad predictiva de diversos modelos¹¹.

En los anexos A.3-A.5 se presenta los resultados de la evaluación de pronósticos incondicional y en A.6-A.8 los resultados para la evaluación condicional para los horizontes de predicción de

¹⁰ En la literatura de pronósticos existe una discusión sobre los métodos más adecuados para realizar comparaciones de modelos y proyecciones, las cuales incluyen si la estimación de los parámetros debe ser fija o recursiva; si se debe evaluar pronósticos dentro o fuera de muestra; y si los pronósticos deben ser de un horizonte o múltiples horizontes. Para más detalles ver Clements y Hendry (2003).

¹¹ Leyva (2008) señala que se utiliza la prueba incondicional si se desea evaluar si un modelo es mejor que otro en predecir una variable en promedio. Mientras que si se desea evaluar si un modelo tiene mayor capacidad para predecir la variable de interés en un determinado período, lo adecuado es utilizar la prueba de habilidad predictiva condicionales

1, 3 y 6 meses hacia adelante. Asimismo, en las tablas se presenta los resultados para combinaciones de pronósticos, los cuales serán detallados en la siguiente sub-sección¹².

Para la evaluación de pronósticos incondicional, la tabla (a) contiene los *p-values* de la prueba Giacomini y White, en donde la hipótesis nula es la igualdad de desempeño de pronósticos. En la tabla (b) se muestra la razón de la suma de errores de pronóstico al cuadrado para los modelos de la fila y columna. Es decir, que se muestra la suma de errores de pronóstico al cuadrado relativo al modelo de la columna, tal que un valor menor a uno implica que el pronóstico de la fila se desempeña mejor que el pronóstico de la columna en términos de EMC en ese horizonte.

En la evaluación de pronósticos condicional, los resultados para cada uno de los horizontes de predicción en la tabla (a) presentan los *p-values* para la prueba de Giacomini y White; y en la tabla (b) se muestra el resultado de comparación de pronósticos siguiendo la regla de Giacomini y White¹³.

Los resultados de la inferencia con respecto a la habilidad predictiva incondicional para el horizonte de predicción de 1 mes hacia adelante indican que el desempeño del modelo *benchmark AR(1)* es similar en promedio al del resto de modelos. Asimismo, en la comparación del modelo *AR(3)* con el LSTAR se rechaza la hipótesis nula de igualdad de pronósticos, lo que indica que el modelo LSTAR supera en habilidad predictiva al *AR(3)*. En cuanto a la suma de errores de pronósticos al cuadrado, se observa que existen ganancias en utilizar modelos no lineales en comparación con el modelo lineal de referencia.

Para horizontes de predicción más largos ($h = 3, h = 6$), no se rechaza la hipótesis nula de igualdad de pronósticos de los modelos no lineales con el *benchmark*, lo que implica que en promedio la habilidad predictiva del *AR(1)* es similar que los otros modelos. No obstante, a medida que incrementa el horizonte de predicción se observa que hay ganancias relativas en la suma de errores de pronósticos al cuadrado de los modelos no lineales en comparación con el de referencia. Para $h = 3$, ésta se reduce hasta 0.65 y 0.60, para el SETAR y LSTAR, respectivamente. En cambio, para $h = 6$ la suma de errores al cuadrado pasa a 0.63 y 0.59, respectivamente.

El análisis de los resultados de la habilidad predictiva condicional de las tablas A.6-A.8 dan cuenta que en todos los horizontes considerados el desempeño del modelo *AR* es similar en promedio al de los otros modelos, ya que no se rechaza la hipótesis nula de igualdad de pronósticos. Por otro lado, cuando se analiza la regla establecida por Giacomini y White se observa que para $h = 1$ el modelo SETAR supera 55 por ciento de las veces el modelo lineal de referencia, mientras que el LSTAR lo supera 51 por ciento de las veces en el período fuera de

¹² La prueba Giacomini y White se realizó modificando los códigos en Matlab de Raffaella Giacomini, 2003.

¹³ Siguiendo a Giacomini y White (2006) se utiliza los rezagos de la función de pérdida de pronóstico para realizar las pruebas de habilidad predictiva condicionales.

muestra. Para los horizontes más largos, los modelos no lineales superan en mayor medida al modelo $AR(1)$. Por ejemplo, para $h=6$ el modelo LSTAR supera 83 por ciento de las veces al modelo $AR(1)$ en el horizonte fuera de muestra.

3.3 Combinación de pronósticos

Timmermann (2006) señala que pueden existir ganancias en términos de evaluación de pronósticos cuando se combinan pronósticos que provienen de diversas fuentes. Para complementar los resultados anteriores en este apartado se muestra los resultados de 3 metodologías de combinación de pronósticos para combinar los modelos no lineales presentados anteriormente con el modelo *benchmark*. Las técnicas de combinación utilizadas consisten en un promedio simple, ponderaciones de acuerdo al error cuadrático medio y ponderaciones óptimas¹⁴.

Para la evaluación de pronósticos incondicionales, en la tabla A.3 se observa que para el horizonte de predicción $h = 1$ no se rechaza la hipótesis de igualdad de pronósticos, lo que indica que en promedio los pronósticos combinados tienen desempeño similar a los pronósticos sin combinar. Sin embargo, para las combinaciones de pronósticos con ponderaciones óptimas se muestra que se rechaza la hipótesis nula en casi todas las comparaciones señalando que el pronóstico combinado es superior en habilidad predictiva¹⁵.

Asimismo, a medida que aumenta el horizonte de los pronósticos obtenidos fuera de muestra se observa que en promedio los pronósticos combinados se desempeñan mejor que el modelo lineal de referencia (fila [4] de las tablas A.4 y A.5). Nuevamente, para $h = 3$ y $h = 6$ la combinación obtenida con ponderadores óptimos es superior en habilidad predictiva que las otras combinaciones.

La inferencia de los resultados de predicción condicional muestra que bajo ningún horizonte de proyección se rechaza la hipótesis nula de igual de pronósticos, lo cual indica que no hay evidencia de ganancias adicionales de las combinaciones de los pronósticos bajo el escenario condicional. Esto podría estar explicado por el instrumento que se utilizó para realizar este análisis, pues el error cuadrático medio podría ser poco informativo sobre de la capacidad predictiva relativa entre modelos.

4. Consideraciones finales

En este trabajo se evalúa el desempeño de modelos no lineales en la generación de predicciones de corto plazo para el IMAE de Nicaragua en comparación con los modelos tradicionales de series de tiempo utilizados en la literatura. Para evaluar el desempeño de los

¹⁴ Ver Kışınbay (2007), Leyva (2008) o Bello (2009) para detalles sobre métodos de combinación de pronósticos.

¹⁵ En el anexo A.9 se presenta los datos de pronósticos resultantes de las diversas metodologías de combinación de pronósticos.

modelos se realizaron predicciones fuera de muestra del IMAE para horizontes de 1, 3 y 6 meses hacia adelante.

Los resultados dan cuenta que en términos relativos a la suma de errores al cuadrado hay ganancias en utilizar modelos no lineales, como el LSTAR y SETAR, principalmente en horizontes de predicción cortos. Sin embargo, el aporte más relevante es que los modelos no lineales muestran en promedio igual desempeño en términos de predicción que el modelo lineal de referencia.

Por otro lado, los resultados de la combinación de pronósticos por ponderaciones óptimas de los modelos no lineales en $h = 1$ muestran un desempeño superior al modelo de referencia lineal y al resto de pronósticos compuestos. Esto podría dar indicios de que los modelos no lineales podrían identificar ciertas asimetrías en la serie del IMAE, que pueden ser relevante al momento de realizar proyecciones de crecimiento en el corto plazo. Asimismo, se observa que para horizontes de predicción más largos las proyecciones resultantes de la combinación de pronósticos muestran un desempeño similar al de los modelos lineales.

Asimismo, los resultados de la evaluación de la habilidad predictiva condicional, tanto de las proyecciones individuales como de las combinaciones, dan cuenta que en todos los horizontes considerados el desempeño del modelo AR es similar en promedio al de los otros modelos, ya que no se rechaza la hipótesis nula de igualdad de pronósticos. En este sentido, es relevante que se continúe investigando con otros instrumentos que si pudieran aportar información sobre la capacidad predictiva de los modelos, de tal forma que los resultados obtenidos sean robustos.

Finalmente, este trabajo constituye un aporte a la evidencia empírica sobre evaluación de pronósticos de crecimiento del IMAE de Nicaragua, lo cual es relevante para contar con información que pueda contribuir a tomar decisiones de política. Por esta razón, es importante que se continúe una agenda de investigación que complementa estos resultados mediante otros métodos o modelos, como VAR estructurales o DSGE, así como otras metodologías de combinación de pronósticos que contribuyan a mejorar las proyecciones de crecimiento del BCN.

Referencias

- Acevedo, I. (2013). *Indicadores cíclicos del IMAE*. Banco Central de Nicaragua, Documento de Trabajo.
- Bello, O. (2007). *Modelo Macroeconómico de Proyección de Corto Plazo para Nicaragua*, Documento de Trabajo. Banco Central de Nicaragua.
- Bello, O. (2009). *Combinación de Pronósticos de Inflación en Nicaragua*. Documento de Trabajo. Banco Central de Nicaragua.
- Box, G., & Jenkins, G. (1970). *Time Series Analysis: Forecasting and Control*. Holden Day, San Francisco.
- Bruce, H. (1997). Inference in TAR Models. *Studies in Nonlinear Dynamics and Econometrics*, Vol. 2, No. 1.
- Carpio, E., & Mendoza, O. (2007). *El pass trough en Guatemala: Evidencia a través de un modelo regresivo con transición suave*. Banco Central de Venezuela, Documento de Trabajo No. 82.
- Christoffel, K., Coenen, G., & Warne, A. (2010). *Forecasting with DSGE models*. European Central Bank, Working Paper Series No 1185.
- Clark, T. E., & McCracken, M. W. (2000). *Tests of Equal Forecast Accuracy and Encompassing for Nested Models*. Federal Reserve Bank of Kansas City.
- Clements, M. P., & Hendry, D. F. (2003). *Evaluating a Model by Forecast Performance*. Documento de Trabajo.
- Diebold, F., & Mariano, R. (1995). Comparing Predictive Accuracy. *Journal of Business and Economic Statistics*, 13: 253-263.
- Engle, R., & Granger, C. (1987). Co-integration and error correction: Representation, Estimation, and Testing. *Econometrica*, 55, 251-276.
- Espinoza, E., Iraheta, M., & Sánchez, A. (2012). *Modelo Económico para el Crecimiento Económico y la Inflación en Centroamérica y República Dominicana*. Documento de Trabajo, SECMCA 01-2012.
- Esquivel, M. (2009). *Performance of Artificial Neural Networks in Forecasting Costa Rican Inflation*. Banco Central de Costa Rica, DEC-DIE-029-2009-DI.
- Ferrara, L., Marcellino, M., & Mogliani, M. (2012). *Macroeconomic forecast during the great recession: The return of non-linearity?* Banque de France, Documento de Trabajo No. 383.

- Giacomini, R., & White, H. (2006). Tests of Conditional Predictive Ability. *Econometrica*, Vol. 74.
- Granger, C., & Terasvirta, T. (1993). *Modelling nonlinear economic relationships*. Oxford: Oxford University Press.
- Hamilton, J. D. (1994). *Times Series Analysis*. Princeton, New Jersey: Princeton University Press.
- Kışınbay, T. (2007). *The Use of Encompassing Tests for Forecast Combinations*. International Monetary Fund, WP/07/264.
- Leyva, G. (2008). *Prediciendo la inflación en Guatemala: ¿es útil la información contenida en la encuesta de expectativas de inflación?* Banco de Guatemala, Documento de Trabajo No. 105.
- Litterman, R. (1986). Forecasting with Bayesian vector autoregressions, five years of experience. *Journal of Business Economic Statistics*, 4, 25-38.
- Luukkonen, R., Saikkonen, P., & Teräsvirta, T. (1988). Testing linearity against smooth transition autoregressive models. *Biometrika*, Vol. 75, No. 3, 491-499.
- Marcellino, M. (2007). *A comparison of time series models for forecasting GDP growth and inflation*. IEP-Università Bocconi, IGIER and CEPR.
- Pincheira, P., & García, Á. (2009). En Búsqueda de un Buen Benchmark Predictivo para la Inflación. Banco Central de Chile, Documento de Trabajo No. 514.
- Sims, C. (1980). Macroeconomics and reality. *Econometrica*, 48, 1-48.
- Smets, F., & Wouters, R. (2004). Forecasting with a Bayesian DSGE model: An application to the Euro area. *Journal of Common Market Studies*, 42, 841-867.
- Stock, J., & Watson, M. (1991). A Probability model of the coincident economic indicators. *Cambridge University Press*, 63-85.
- Stock, J., & Watson, M. (1989). New indexes of coincident and leading economic indicators. National Bureau of Economic Research.
- Teräsvirta, T. (1994). Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models. *Journal of the American Statistical Association*, Vol. 89, No. 425, 208-218.
- Timmermann, A. (2006). Forecast Combinations. En G. Elliot, C. Granger, & A. Timmermann, *Handbook of Economic Forecasting*. Volume 1, Capítulo 4.
- West, K. (1996). Asymptotic Inference about Predictive Ability. *Econometrica*, Vol. 64, No. 5, 1067-1084.

Anexos

A.1 Pruebas para especificaciones de modelos

(a) Criterios de Selección para el modelo $AR(p)$

p	AIC	BIC	HQC
1	3.4580	3.5004	3.4753
2	3.4166	3.4803	3.4425
3	3.4010	3.4858	3.4355
4	3.4179	3.5239	3.4610
5	3.4303	3.5576	3.4821
6	3.4497	3.5982	3.5101

Nota: AIC=Criterio Akaike, BIC=Criterio Schwarz y HQC=Hannan-Quinn.

(b) Prueba de Linealidad para SETAR

p	F	F-Test	Crítico	P-value
1	0.975	15.965	24.210	0.418
2	9.383	17.376	23.990	0.289
3	7.545	14.409	24.457	0.549
4	7.960	15.941	24.214	0.414
5	11.883	11.160	23.386	0.830
6	6.792	31.167	22.035	0.011

Nota: El p-value se obtuvo mediante 1000 replicaciones de *bootstrap*.

(c) Prueba de Linealidad para STAR

p	Aproximación de Taylor 1er orden	Aproximación de Taylor de 3er orden
1	0.352	0.524
2	0.088	0.202
3	0.335	0.603
4	0.262	0.522
5	0.154	0.561
6	0.364	0.147

Nota: Los valores corresponden a los p-values de la hipótesis nula de linealidad

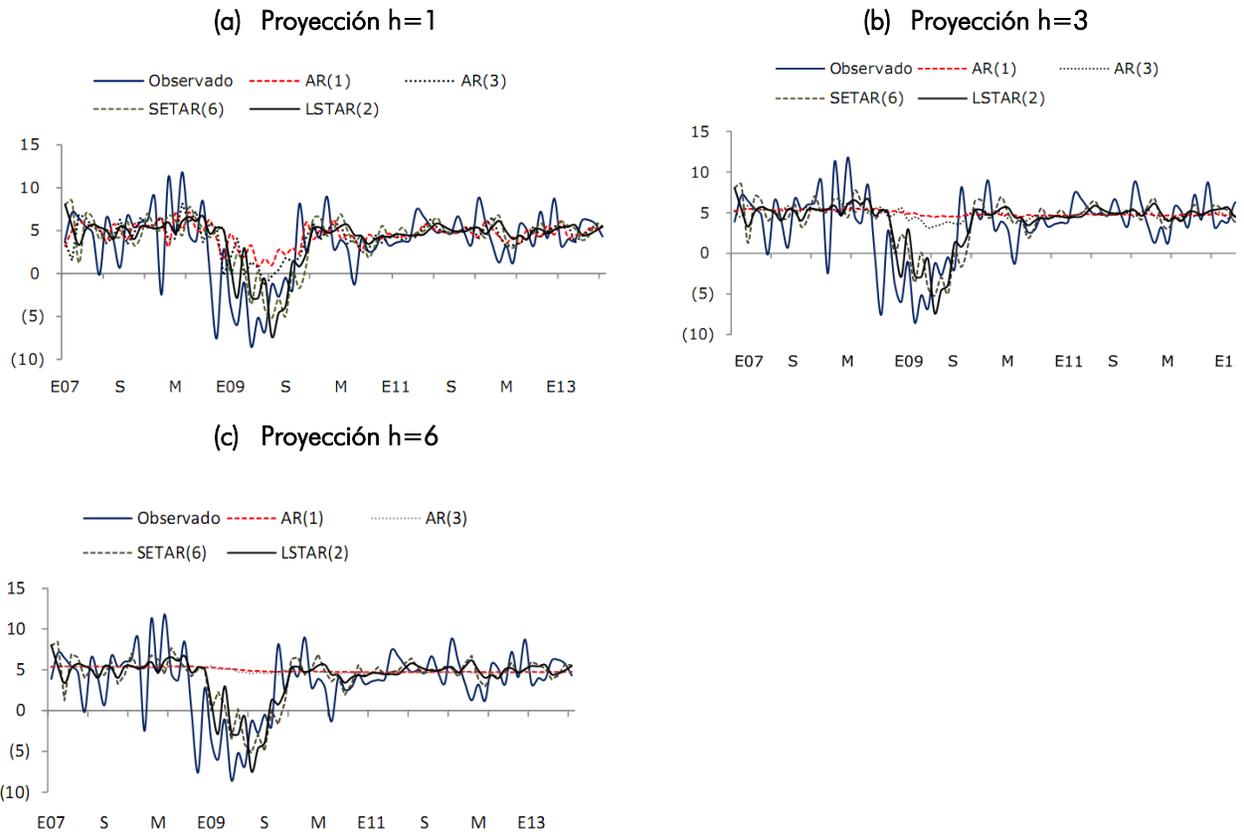
Fuente: Cálculos del autor.

(d) Número de unidades ocultas para modelo ANN

Unidades Ocultas	SSR
0	67.944
1	8.30E+15
2	61092.692

Nota: SSR se refiere a la suma de Errores al Cuadrado.

A.2 Pronóstico de la tasa de crecimiento interanual del IMAE para diversos horizontes



Fuente: Cálculos del autor.

A.3 Capacidad predictiva incondicional para h=1

(a) Test Giacomini y White para diversas especificaciones, Proyección de 1 mes hacia adelante: *P-values* de la hipótesis nula

		h=1	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.18	0.08	0.88	0.72	0.07	0.07	0.99	0.96	0.89	0.62	0.09	0.05
	SETAR	[2]	-	0.24	0.91	0.85	0.54	0.47	0.95	0.99	0.95	0.84	0.22	0.27
	LSTAR	[3]	-	-	0.97	0.94	0.78	0.77	0.99	1.00	1.00	0.92	0.69	0.55
	AR(1)	[4]	-	-	-	0.05	0.01	0.00	0.63	0.76	0.39	0.18	0.04	0.01
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.02	0.02	1.00	0.98	0.92	0.38	0.07	0.02
	SETAR-AR(1)	[6]	-	-	-	-	-	0.37	1.00	1.00	1.00	0.92	0.29	0.15
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	1.00	1.00	1.00	0.91	0.44	0.08
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.69	0.28	0.05	0.02	0.00
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.09	0.08	0.00	0.00
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.18	0.01	0.00
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.09	0.05
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.32
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

(b) Razón de Suma de Error Cuadrático Medio (ECM)

		h=1	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	1.13	1.22	0.90	0.97	1.12	1.15	0.89	0.86	0.91	0.99	1.16	1.21
	SETAR	[2]	-	1.08	0.79	0.86	0.99	1.01	0.78	0.76	0.80	0.88	1.02	1.07
	LSTAR	[3]	-	-	0.74	0.80	0.92	0.94	0.73	0.71	0.75	0.81	0.95	0.99
	AR(1)	[4]	-	-	-	1.08	1.25	1.27	0.99	0.96	1.01	1.10	1.29	1.35
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	1.15	1.18	0.91	0.89	0.94	1.02	1.19	1.25
	SETAR-AR(1)	[6]	-	-	-	-	-	1.02	0.79	0.77	0.81	0.88	1.03	1.08
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.78	0.75	0.80	0.87	1.01	1.06
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.97	1.03	1.12	1.31	1.37
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	1.06	1.15	1.35	1.40
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	1.09	1.27	1.33
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	1.17	1.22
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	1.04
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

Nota: En la tabla (a) la hipótesis nula corresponde a igual de desempeño estadístico del pronósticos de los modelos que se están comparando (el de la fila y la columna). El rechazo de la hipótesis nula sugiere que el modelo de la fila es superado en habilidad predictiva por el modelo de la columna. En la tabla (b) se presenta la razón de la suma del error cuadrático del modelo de la fila relativo al modelo de la columna. De tal forma que un valor menor a uno implica que el pronóstico de la fila se desempeña mejor que el pronóstico de la columna en términos de EMC en ese horizonte.

Fuente: Cálculos del autor.

A.4 Capacidad predictiva incondicional para h=3

(a) Test Giacomini y White para diversas especificaciones, Proyección de 3 meses hacia adelante: P-valores de la hipótesis nula

		h=3	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.04	0.02	0.98	0.98	0.01	0.01	0.99	0.84	0.48	0.34	0.02	0.01
	SETAR	[2]	-	0.24	0.98	0.97	0.79	0.69	0.97	0.99	0.97	0.95	0.38	0.29
	LSTAR	[3]	-	-	0.99	0.99	0.90	0.91	0.99	1.00	0.99	0.95	0.75	0.64
	AR(1)	[4]	-	-	-	0.01	0.00	0.00	0.04	0.45	0.06	0.21	0.01	0.00
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.00	0.00	1.00	0.69	0.19	0.27	0.02	0.01
	SETAR-AR(1)	[6]	-	-	-	-	-	0.36	1.00	1.00	1.00	0.93	0.13	0.07
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	1.00	1.00	1.00	0.90	0.26	0.04
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.62	0.13	0.25	0.02	0.01
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.03	0.21	0.00	0.00
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.35	0.01	0.00
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.04	0.04
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.30
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

(b) Razón de Suma de Error Cuadrático Medio (ECM)

		h=3	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	1.43	1.54	0.93	0.97	1.30	1.33	0.95	0.94	1.00	1.06	1.44	1.52
	SETAR	[2]	-	1.08	0.65	0.68	0.91	0.93	0.67	0.66	0.70	0.74	1.01	1.06
	LSTAR	[3]	-	-	0.60	0.63	0.85	0.86	0.62	0.61	0.65	0.69	0.93	0.99
	AR(1)	[4]	-	-	-	1.04	1.40	1.43	1.03	1.01	1.08	1.14	1.55	1.63
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	1.35	1.38	0.99	0.97	1.04	1.10	1.49	1.57
	SETAR-AR(1)	[6]	-	-	-	-	-	1.02	0.73	0.72	0.77	0.81	1.11	1.17
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.72	0.70	0.75	0.80	1.08	1.14
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.98	1.05	1.11	1.51	1.59
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	1.07	1.13	1.54	1.62
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	1.06	1.43	1.51
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	1.36	1.43
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	1.05
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

Nota: En la tabla (a) la hipótesis nula corresponde a igual de desempeño estadístico del pronósticos de los modelos que se están comparando (el de la fila y la columna). El rechazo de la hipótesis nula sugiere que el modelo de la fila es superado en habilidad predictiva por el modelo de la columna. En la tabla (b) se presenta la razón de la suma del error cuadrático del modelo de la fila relativo al modelo de la columna. De tal forma que un valor menor a uno implica que el pronóstico de la fila se desempeña mejor que el pronóstico de la columna en términos de EMC en ese horizonte.

Fuente: Cálculos del autor.

A.5 Capacidad predictiva incondicional para $h=6$

(a) Test Giacomini y White para diversas especificaciones, Proyección de 6 meses hacia adelante: P-valores de la hipótesis nula

		h=6	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.02	0.01	0.96	0.96	0.00	0.00	0.97	0.52	0.08	0.25	0.01	0.00
	SETAR	[2]	-	0.23	0.98	0.98	0.81	0.71	0.98	0.99	0.98	0.97	0.39	0.29
	LSTAR	[3]	-	-	0.99	0.99	0.91	0.91	0.99	1.00	0.99	0.99	0.75	0.65
	AR(1)	[4]	-	-	-	0.04	0.00	0.00	0.05	0.44	0.06	0.22	0.01	0.00
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.00	0.00	1.00	0.48	0.07	0.23	0.01	0.00
	SETAR-AR(1)	[6]	-	-	-	-	-	0.36	1.00	1.00	1.00	0.99	0.12	0.06
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	1.00	1.00	1.00	0.99	0.24	0.04
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.47	0.07	0.23	0.01	0.00
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.03	0.25	0.00	0.00
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.57	0.01	0.00
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.02	0.01
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.30
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

(b) Razón de Suma de Error Cuadrático Medio (ECM)

		h=6	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	1.55	1.68	0.99	0.99	1.41	1.44	0.99	1.00	1.07	1.06	1.57	1.65
	SETAR	[2]	-	1.08	0.63	0.64	0.90	0.92	0.64	0.64	0.69	0.68	1.01	1.06
	LSTAR	[3]	-	-	0.59	0.59	0.84	0.86	0.59	0.59	0.64	0.63	0.93	0.98
	AR(1)	[4]	-	-	-	1.01	1.42	1.46	1.01	1.01	1.09	1.07	1.59	1.68
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	1.41	1.45	1.00	1.00	1.08	1.06	1.58	1.66
	SETAR-AR(1)	[6]	-	-	-	-	-	1.02	0.71	0.71	0.76	0.75	1.11	1.18
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.69	0.69	0.75	0.74	1.09	1.15
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	1.00	1.08	1.06	1.58	1.67
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	1.07	1.06	1.57	1.66
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.99	1.46	1.54
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	1.48	1.57
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	1.06
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

Nota: En la tabla (a) la hipótesis nula corresponde a igual de desempeño estadístico del pronósticos de los modelos que se están comparando (el de la fila y la columna). El rechazo de la hipótesis nula sugiere que el modelo de la fila es superado en habilidad predictiva por el modelo de la columna. En la tabla (b) se presenta la razón de la suma del error cuadrático del modelo de la fila relativo al modelo de la columna. De tal forma que un valor menor a uno implica que el pronóstico de la fila se desempeña mejor que el pronóstico de la columna en términos de EMC en ese horizonte.

Fuente: Cálculos del autor.

A.6 Capacidad predictiva condicional para h=1

(a) Test Giacomini y White para diversas especificaciones, Proyección de 1 mes hacia adelante: *P-values* de la hipótesis nula

		h=1	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.12	0.75	0.58	0.65	0.84	0.84	0.33	0.87	0.93	0.68	0.14	0.90
	SETAR	[2]	-	0.35	0.45	0.24	0.66	0.23	0.24	0.41	0.28	0.12	0.82	0.35
	LSTAR	[3]	-	-	0.20	0.27	0.69	0.15	0.23	0.34	0.23	0.85	0.68	0.32
	AR(1)	[4]	-	-	-	0.49	0.38	0.40	0.73	0.75	0.29	0.61	0.43	0.37
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.31	0.55	0.01	0.76	0.91	0.67	0.23	0.43
	SETAR-AR(1)	[6]	-	-	-	-	-	0.26	0.15	0.06	0.42	0.93	0.56	0.85
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.19	0.14	0.18	0.81	0.32	0.10
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.96	0.71	0.45	0.22	0.31
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.31	0.84	0.36	0.37
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.84	0.26	0.27
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.20	0.80
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.31
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

(b) Regla de desempeño de Pronóstico

		h=1	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.53	0.59	0.44	0.48	0.56	0.56	0.44	0.45	0.48	0.52	0.56	0.59
	SETAR	[2]	-	0.42	0.55	0.45	0.51	0.49	0.42	0.47	0.47	0.42	0.47	0.45
	LSTAR	[3]	-	-	0.51	0.52	0.55	0.47	0.40	0.38	0.36	0.37	0.55	0.47
	AR(1)	[4]	-	-	-	0.53	0.59	0.66	0.56	0.52	0.55	0.52	0.52	0.59
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.71	0.67	0.04	0.42	0.48	0.53	0.56	0.59
	SETAR-AR(1)	[6]	-	-	-	-	-	0.53	0.21	0.22	0.23	0.40	0.48	0.51
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.14	0.18	0.14	0.48	0.51	0.49
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.52	0.49	0.52	0.67	0.68
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.42	0.52	0.67	0.78
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.51	0.63	0.82
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.55	0.58
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.48
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

Nota: En la tabla (a) la hipótesis nula corresponde a igual de desempeño estadístico del pronósticos de los modelos que se están comparando (el de la fila y la columna). El rechazo de la hipótesis nula sugiere que el modelo y/o método de la fila es superado en habilidad predictiva por el modelo de la columna. En la tabla (b) se presenta la regla descrita por Giacomini y White (2006), indicado la proporción en la que el modelo de la fila es superado por el modelo de la columna.

Fuente: Cálculos del autor.

A.7 Capacidad predictiva condicional para h=3

(a) Test Giacomini y White para diversas especificaciones, Proyección de 3 meses hacia adelante: P-valores de la hipótesis nula

		h=3	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.58	0.72	0.67	0.66	0.57	0.57	0.67	0.67	0.59	0.60	0.56	0.79
	SETAR	[2]	-	0.62	0.64	0.61	0.68	0.82	0.61	0.69	0.66	0.32	0.64	0.65
	LSTAR	[3]	-	-	0.60	0.64	0.79	0.63	0.64	0.58	0.64	0.69	0.77	0.59
	AR(1)	[4]	-	-	-	0.67	0.65	0.76	0.66	0.49	0.66	0.62	0.63	0.71
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.61	0.75	0.10	0.65	0.59	0.61	0.60	0.77
	SETAR-AR(1)	[6]	-	-	-	-	-	0.58	0.61	0.58	0.64	0.50	0.67	0.70
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.74	0.39	0.56	0.54	0.78	0.61
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.65	0.60	0.61	0.60	0.76
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.68	0.87	0.72	0.53
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.77	0.64	0.63
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.45	0.60
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.61
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

(b) Regla de desempeño de Pronóstico

		h=3	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.52	0.52	0.45	0.44	0.55	0.55	0.44	0.48	0.44	0.51	0.52	0.52
	SETAR	[2]	-	0.45	0.49	0.51	0.47	0.55	0.51	0.48	0.44	0.42	0.42	0.48
	LSTAR	[3]	-	-	0.45	0.45	0.47	0.45	0.45	0.38	0.45	0.44	0.58	0.51
	AR(1)	[4]	-	-	-	0.55	0.58	0.60	0.56	0.52	0.45	0.49	0.51	0.55
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.55	0.56	0.11	0.49	0.51	0.49	0.52	0.56
	SETAR-AR(1)	[6]	-	-	-	-	-	0.56	0.42	0.19	0.42	0.51	0.52	0.53
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.42	0.32	0.22	0.51	0.53	0.53
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.49	0.55	0.49	0.52	0.53
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.58	0.51	0.56	0.64
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.51	0.55	0.66
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.55	0.53
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.48
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

Nota: En la tabla (a) la hipótesis nula corresponde a igual de desempeño estadístico del pronósticos de los modelos que se están comparando (el de la fila y la columna). El rechazo de la hipótesis nula sugiere que el modelo y/o método de la fila es superado en habilidad predictiva por el modelo de la columna. En la tabla (b) se presenta la regla descrita por Giacomini y White (2006), indicado la proporción en la que el modelo de la fila es superado por el modelo de la columna.

Fuente: Cálculos del autor.

A.8 Capacidad predictiva condicional para h=6

(a) Test Giacomini y White para diversas especificaciones, Proyección de 6 meses hacia adelante: P-valores de la hipótesis nula

		h=6	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.78	0.81	0.68	0.68	0.84	0.84	0.67	0.62	0.80	0.76	0.80	0.86
	SETAR	[2]	-	0.75	0.79	0.79	0.78	0.78	0.79	0.85	0.79	0.73	0.70	0.65
	LSTAR	[3]	-	-	0.83	0.82	0.90	0.84	0.82	0.80	0.84	0.74	0.80	0.82
	AR(1)	[4]	-	-	-	0.67	0.85	0.90	0.69	0.62	0.85	0.76	0.81	0.88
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.85	0.89	0.03	0.62	0.83	0.76	0.80	0.87
	SETAR-AR(1)	[6]	-	-	-	-	-	0.73	0.85	0.73	0.80	0.83	0.78	0.86
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.89	0.65	0.80	0.62	0.79	0.84
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.62	0.83	0.76	0.80	0.87
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.55	0.83	0.85	0.77
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.60	0.78	0.83
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.71	0.74
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.74
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

(b) Regla de desempeño de Pronóstico

		h=6	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	[13]
	AR(3)	[1]	0.52	0.53	0.53	0.53	0.56	0.56	0.52	0.51	0.47	0.51	0.52	0.56
	SETAR	[2]	-	0.45	0.49	0.48	0.47	0.53	0.49	0.49	0.45	0.49	0.44	0.45
	LSTAR	[3]	-	-	0.45	0.47	0.48	0.47	0.47	0.34	0.44	0.47	0.53	0.49
	AR(1)	[4]	-	-	-	0.47	0.55	0.60	0.45	0.51	0.44	0.51	0.51	0.55
Combinación simple	AR(3)-AR(1)	[5]	-	-	-	-	0.59	0.62	0.03	0.52	0.47	0.51	0.51	0.55
	SETAR-AR(1)	[6]	-	-	-	-	-	0.60	0.41	0.18	0.41	0.47	0.52	0.52
	LSTAR-AR(1)	[7]	-	-	-	-	-	-	0.38	0.32	0.21	0.37	0.53	0.55
Combinación ponderada	AR(3)-AR(1)	[8]	-	-	-	-	-	-	-	0.52	0.45	0.51	0.51	0.55
	SETAR-AR(1)	[9]	-	-	-	-	-	-	-	-	0.53	0.47	0.58	0.66
	LSTAR-AR(1)	[10]	-	-	-	-	-	-	-	-	-	0.53	0.56	0.66
Combinación óptima	AR(3)-AR(1)	[11]	-	-	-	-	-	-	-	-	-	-	0.52	0.60
	SETAR-AR(1)	[12]	-	-	-	-	-	-	-	-	-	-	-	0.51
	LSTAR-AR(1)	[13]	-	-	-	-	-	-	-	-	-	-	-	-

Nota: En la tabla (a) la hipótesis nula corresponde a igual de desempeño estadístico del pronósticos de los modelos que se están comparando (el de la fila y la columna). El rechazo de la hipótesis nula sugiere que el modelo y/o método de la fila es superado en habilidad predictiva por el modelo de la columna. En la tabla (b) se presenta la regla descrita por Giacomini y White (2006), indicado la proporción en la que el modelo de la fila es superado por el modelo de la columna.

Fuente: Cálculos del autor.

A.9 Pronósticos resultantes de la combinación de modelos con el *benchmark* AR(1)

(a) Combinación Simple

(b) Combinación Ponderada del ECM

(c) Combinación con Ponderaciones Óptimas

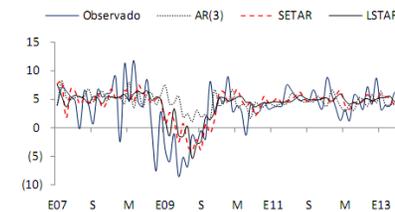
$h=1$



$h=3$



$h=6$



Fuente: Cálculos del autor.