

Pronóstico del Índice Nacional de Precios al Consumidor

Forecast of the National Index of Consumer Prices

Previsão do Índice Nacional de Preços ao Consumidor

Lilia Alejandra Flores Castillo

Universidad Tecnológica de la Mixteca, México

floresaly22@hotmail.com

Resumen

En la economía y las finanzas los pronósticos de indicadores macroeconómicos se han convertido en una herramienta indispensable para la planeación de políticas económicas, decisiones de inversión, de ahorro y consumo para los diversos agentes económicos. El futuro es incierto pero los pronósticos permiten anticipar situaciones de riesgo. El objetivo de este trabajo tuvo como eje temático realizar el pronóstico de Índice Nacional de Precios al Consumidor. En la metodología se utilizó un enfoque cuantitativo y descriptivo sobre tres metodologías de pronóstico, el modelo autorregresivo integrado de media móvil (ARIMA), la técnica Holt-Winters y redes neuronales artificiales. Los resultados mostraron la precisión de cada uno de los modelos de pronóstico al evaluar cada predicción respecto al error cuadrático medio. De acuerdo a los resultados obtenidos se concluye que la metodología de redes neuronales artificiales presenta menor poder predictivo para este caso en particular.

Palabras Clave: Modelos de series de tiempo, redes neuronales artificiales, modelo ARIMA, técnica metodología y aplicaciones.

Abstract

In economics and finance, forecasts of macroeconomic indicators have become an indispensable tool in the planning of economic policies, investment decisions, savings and consumption for the various economic agents. The future is uncertain but the forecasts allow us to anticipate risk situations. The purpose of this paper was to make the forecast of the National Consumer Price Index. The methodology used a quantitative and descriptive approach on three prognostic methodologies, the integrated autoregressive moving average model (ARIMA), the Holt-Winters technique and artificial neural networks. The results showed the accuracy of each forecast model when evaluating each prediction using the mean square error. According to the results obtained it is concluded that the artificial neural network methodology presents a lower predictive power for this particular case.

Key words: Models of time series, artificial neural networks, ARIMA model, technical methodology and applications.

Resumo

Nas previsões econômicas e financeiras, os indicadores macroeconômicos se tornaram uma ferramenta indispensável para o planejamento de políticas econômicas, decisões de investimento, poupança e consumo para os vários agentes econômicos. O futuro é incerto, mas as previsões nos permitem antecipar situações de risco. O objetivo deste trabalho foi fazer a previsão do Índice Nacional de Preços ao Consumidor. A metodologia utilizou uma abordagem quantitativa e descritiva em três metodologias de previsão, modelo de média móvel autoregressiva integrada (ARIMA), técnica de Holt-Winters e redes neurais artificiais. Os resultados mostraram a precisão de cada um dos modelos de previsão ao avaliar cada previsão em relação ao erro quadrático médio. De acordo com os resultados obtidos, conclui-se que a metodologia da rede neural artificial apresenta menor poder preditivo para esse caso particular.

Palavras-chave: modelos de séries temporais, redes neurais artificiais, modelo ARIMA, metodologia técnica e aplicações.

Clasificación JEL: C22,C45,C53.

Fecha Recepción: Enero 2017

Fecha Aceptación: Abril 2017

1.- Introducción

El Índice Nacional de Precios al Consumidor (INPC) es un indicador económico que facilita la toma de decisiones económicas inherentes al comportamiento de los precios. Ello se debe a que brinda información al gobierno, las empresas y las familias sobre los cambios que tiene el costo de la vida en el país.

El INPC es un instrumento estadístico que permite medir la inflación, es decir, tiene como objetivo primordial medir a través del tiempo la variación de los precios de una canasta de bienes y servicios representativa del consumo de los hogares.

Todos los países necesitan conocer sus niveles de inflación, para así conocer la capacidad de compra de los diversos estratos sociales; el INPC provee de información para la toma de decisiones a los diversos agentes económicos: en el caso de los hogares, con base en él se plantean los presupuestos de consumo y ahorro; en el caso de las empresas la inflación permite una mejor toma de decisiones de inversión y producción; y para el caso del gobierno el INPC tiene una relevancia esencial en el diseño de la política monetaria de un país, la cual está en manos del Banco Central, BANXICO para el caso de México. El comportamiento del INPC es el punto de inicio para el diseño de políticas encaminadas a la búsqueda de estabilidad del poder adquisitivo de la moneda nacional. Hoy en día todo país cuya economía le permita presumir estabilidad macroeconómica debe necesariamente mostrar un nivel general de precios estable.

Actualmente la responsabilidad de recopilar, procesar y divulgar el INPC, corresponde al INEGI y tal atributo se establece en el Código Fiscal de la Federación en el segundo párrafo del artículo 20. Las aplicaciones del INPC han evolucionado con el paso del tiempo, hoy en día sus principales usos, son señalados por el INEGI (2013) y son los siguientes:

1. Factor de actualización de los créditos fiscales.
2. Determinante del valor de la Unidad de Inversión (UDI).
3. Referente en diversas negociaciones contractuales.
4. Factor de actualización de valores nominales y como deflactor en el Sistema de Cuentas Nacionales de México.
5. Auxiliar en la determinación de los incrementos salariales, los montos de las jubilaciones y de las prestaciones de seguridad social.
6. Auxiliar en el cálculo de los pagos de intereses, los montos de alquileres, los contratos privados y los precios de los bonos suelen estar indexados al INPC.
7. Auxiliar para las autoridades financieras y hacendarias del país en el diseño de las políticas monetarias, adquisitivo de la moneda nacional y unas finanzas públicas sanas.
8. Herramienta estadística para empresas e investigadores.

En México el control de precios mediante la política monetaria está basado principalmente en el modelo de objetivos de inflación, que persigue la obtención de tasas de inflación estables y controladas. En un estudio que pretende valorar la evidencia empírica de los resultados de la aplicación del modelo de objetivos de inflación, Angeriz y Arestis (2009) realizan un análisis que incluye economías desarrolladas y emergentes que operan bajo el régimen de objetivos de inflación. Afirman que esta estrategia compromete a los países a adoptar la estabilidad de precios como principal objetivo de política monetaria, los resultados que obtienen muestran que hasta el momento ninguno de los países que ha adoptado este régimen lo ha desechado, si bien trabajar bajo este enfoque ha dado buenos resultados.

Ahora bien, ¿por qué realizar un pronóstico del INPC? Los agentes económicos diariamente se enfrentan a la toma de decisiones económicas, principalmente: consumo, ahorro, inversión, mantener dinero en efectivo, y compra-venta de activos financieros. Un individuo racional basa su toma de decisiones en información obtenida del propio comportamiento de la economía. Siendo el nivel general de precios una variable determinante de la actividad económica general, es normal que los individuos deseen conocer su trayectoria pasada, presente y futura; para con ello lograr una toma de decisiones bien fundamentada y racional.

El objetivo de la investigación es realizar y evaluar el pronóstico del INPC a partir de los resultados obtenidos de la implementación de tres métodos de pronóstico alternativos, como son el modelo RNA, el modelo ARIMA y la técnica de Holt-Winters. Para el pronóstico se utilizó una muestra histórica compuesta de 133 observaciones con periodicidad mensual del INPC, que comprende el periodo de enero de 2005 a enero de 2016. Para lograr el objetivo planteado, el presente documento se integra por cinco apartados: el primero es la presente introducción; el segundo, la descripción de la metodología empleada para cumplir con el objetivo del trabajo; el tercero, cuarto y quinto muestran los resultados, discusión y conclusiones.

2. Método

En este trabajo se adoptó un tipo de investigación descriptiva con un enfoque cuantitativo y diseño longitudinal-retrospectivo donde se recoge información directa de los valores del INPC y se identifica su tendencia con la finalidad de realizar y evaluar el pronóstico.

Para el pronóstico se utilizó una muestra histórica compuesta de 113 observaciones con periodicidad mensual del INPC. La muestra se dividió en dos periodos, con el objetivo de evaluar el pronóstico dentro y fuera de la muestra. Comprende el periodo de enero de 2005 a mayo del 2014, para la prueba dentro de la muestra; y junio 2014 a enero 2016 para la evaluación del pronóstico fuera de la muestra.

Los instrumentos para realizar el pronóstico son tres técnicas distintas implementadas por las redes neuronales artificiales, el modelo autorregresivo integrado de media móvil (ARIMA) y la técnica Holt-Winters:

a) *Redes neuronales artificiales*

La teoría de redes neuronales se remonta al año de 1960, cuando se presentó la primera red neuronal, conocida como perceptrón, y las técnicas de aprendizaje para entrenarla; a partir de este nuevo avance en el conocimiento surgió un gran número de aportaciones al tema y se encontraron diversas aplicaciones para esta herramienta.

Las redes neuronales artificiales, son un modelo de procesamiento de información, que pueden expresarse mediante métodos matemáticos que pretenden emular el funcionamiento del cerebro humano. Son modelos estadísticos no lineales, no paramétricos utilizados principalmente para la clasificación, predicción de datos y variables; en finanzas la aplicación de una red neuronal se centra como apoyo para el pronóstico y administración de portafolios.

Una red neuronal artificial (RNA), puede ser útil para los procesos no lineales que tienen una relación funcional desconocida y como consecuencia son difíciles de ajustar. Implementaciones de RNA en el pronóstico del comportamiento de diversas variables [Jonson y Padilla (2005), Fadlalla y Lin (2001), Swales y Young (1992), Villada, Cadavier, y Molina (2008), Villamil y Delgado (2007)], aseveran que el modelo de RNA es significativamente superior y tiene ventajas sobre los resultados obtenidos mediante modelos lineales tradicionales.

En cuanto a la estructura de una red neuronal artificial, ésta puede ser diseñada con base en una estructura perceptrón multicapa, que puede estar conformada por tres capas de neuronas con diferentes funciones. La primera capa es la capa de entrada, mediante la cual se introducen los datos que van alimentar a la red. La segunda capa es denominada capa oculta, la cual tiene asociada una regla de propagación y una función de activación. La



tercera capa es lineal y calcula una respuesta como una combinación lineal de la respuesta de la capa oculta, obteniendo la salida de la red.

De acuerdo con Martin y Sanz (2007), los elementos básicos de una RNA son los siguientes:

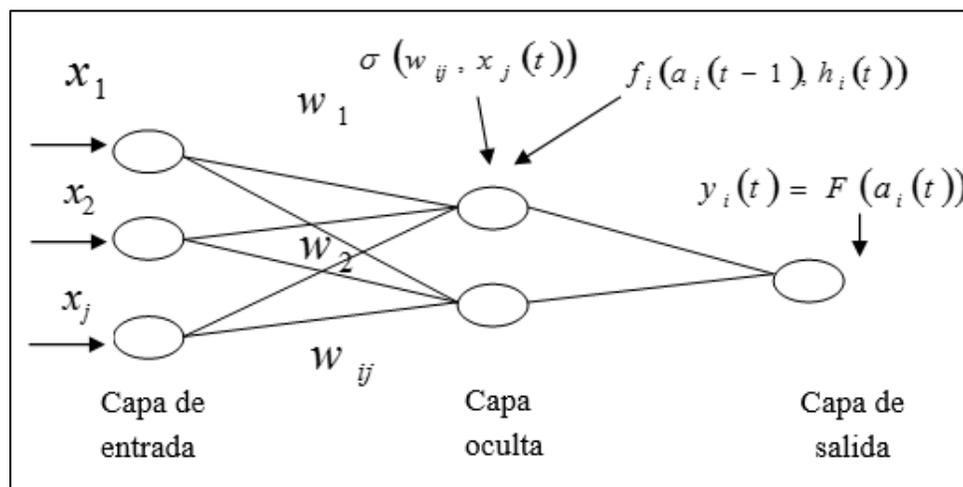
- Conjunto de entradas, $x_j(t)$.
- Pesos sinápticos de la neurona i , w_{ij} que representan la intensidad de interacción entre cada neurona pre-sináptica j y la neurona post-sináptica i .
- Regla de propagación $\sigma(w_{ij}, x_j(t))$, que proporciona el valor del potencial post-sináptico $h_i(t) = \sigma(w_{ij}, x_j(t))$ de la neurona i en función de sus pesos y entradas.
- Función de activación de la neurona i en función de su estado anterior $a_i(t-1)$ y de su potencial pos sináptico actual, que representa simultáneamente la salida de la neurona y su estado de activación.
- Función de salida $f_i(a_i(t))$, que proporciona la salida actual de la neurona i en su estado de activación.

La operación de una neurona i puede expresarse como:

$$Y_i(t) = F_i(f_i[a_i(t-1), \sigma(w_{ij}, x_j(t))]) \quad (1)$$

En la Figura 1 se pueden observar los elementos básicos de una red neuronal artificial antes señalados.

Figura 1. Elementos básicos de una Red Neuronal Artificial



Fuente: Elaboración propia.

Fase de entrenamiento:

Durante la fase de entrenamiento se modifican los pesos de las conexiones y se sigue la regla de aprendizaje que trata de optimizar su respuesta mediante la minimización del error de ajuste. El modo de aprendizaje más sencillo consiste en la presentación de un conjunto de patrones de entrada y salida deseados para cada patrón de entrada.

El problema para caracterizar al modelo de la red neuronal es determinar el vector de pesos que asocia el vector de entrada con el valor de salida para obtener con precisión el valor deseado; el proceso de aprendizaje corresponde a minimizar las diferencias entre las salidas deseadas y la salida real para todos los vectores de entrada para determinar los pesos que minimizan el conjunto de los errores (w_{1*} , w_{2*}).

La evaluación del funcionamiento de la red neural se realiza una vez que ha culminado la fase de entrenamiento. Es usual disponer de un conjunto de datos distintos a los usados para el entrenamiento para los cuales se conoce la respuesta correcta y se usan como examen para evaluar el aprendizaje de la red, se observa si responde adecuadamente al conjunto de entradas y salidas conocido.



b) *Modelo ARIMA*

A finales de la década de los setenta Box y Jenkins (1970) desarrollaron una nueva herramienta de predicción, el denominado modelo autorregresivo integrado de media móvil (ARIMA (p, d, q)), mediante el cual se pueden predecir valores de una serie que depende del tiempo con una combinación lineal de sus propios valores pasados y errores pasados (también llamados shocks o innovaciones).

La expresión general del modelo ARIMA (p, d, q), donde p representa el orden del proceso autorregresivo, d es el orden de los datos estacionarios y q es el orden del proceso de media móvil, viene dada por:

$$\Delta^d y_t = \phi_1 \Delta^d y_{t-1} + \dots + \phi_p \Delta^d y_{t-p} + a_t + \phi_1 a_{t-1} + \dots + \phi_q a_{t-q} \quad (2)$$

Donde $\Delta^d y_t$, expresa que sobre la serie original y_t se han aplicado d diferencias. El método Box-Jenkins considera cuatro pasos:

1. Identificación: determinar los valores apropiados de p, d, q .
2. Estimación: estimar los parámetros de los términos autorregresivos y de media móvil incluidos en el modelo.
3. Verificación del diagnóstico: comprobar si el modelo seleccionado ajusta los datos adecuadamente.
4. Predicción.

El proceso de identificación se puede determinar como uno de los siguientes:

a) Proceso autorregresivo AR(p)

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + a_t + \varepsilon_t \quad (3)$$

b) Proceso de media móvil MA(q)

$$y_t = \mu + \varepsilon_t - \Theta \varepsilon_{t-1} - \Theta \varepsilon_{t-2} - \dots - \Theta \varepsilon_{t-q} \quad (4)$$

c) Proceso autorregresivo y de media móvil ARIMA

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta \varepsilon_{t-1} - \theta \varepsilon_{t-2} - \dots - \theta \varepsilon_{t-q} \quad (5)$$

El mayor problema al estimar el modelo ARIMA es determinar los valores más apropiados para p , d , q .

c) Técnica Holt-Winters

La estructura básica de la técnica Holt-Winters fue desarrollada por Holt en 1957, y se amplió para incluir un parámetro de ajuste estacional por su estudiante Winters en 1960. En este trabajo se considera el suavizado de Winters estacional multiplicativo, que es un método de suavizado de series temporales que presentan tendencia y estacionalidad, que de acuerdo con González:

consiste en tres ecuaciones, cada una de las cuales suaviza un factor asociado con cada uno de los componentes de la serie: aleatoriedad, tendencia y estacionalidad por lo que ha de utilizar tres constantes de alisamiento, α, β, γ , todas comprendidas entre 0 y 1 (2009).

Las ecuaciones de suavizado son las siguientes:

$$a_t = \alpha(y_t / S_{t-p}) + (1 - \alpha)(a_{t-1} + T_{t-1}) \quad (6)$$

$$T_t = \beta(a_t - a_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

$$S_t = \gamma(y_t / a_t) + (1 - \gamma)S_{t-p} \quad (8)$$

La ecuación de predicción que se define en este modelo es la siguiente:

$$y_{t+n} = (a_t + nT_t) S_{t+k-1} \quad (9)$$

Donde:

a_t : componente constante, estimación suavizada para el periodo t .

y_t : con los valores actuales de la variable

ε : aleatoriedad no controlable



α : constante de suavización exponencial simple de la serie de datos

γ : constante para factores estacionales

β : constante para la tendencia

T_t : componente de pendiente de tendencia

S_t : componente estacional

p : significa el periodo de temporada (por ejemplo 4 para datos trimestrales y 12 para datos mensuales).

n : cantidad de periodos a pronosticar hacia adelante

k : observaciones que predice

De manera breve se han descrito las tres metodologías que se consideran para realizar el pronóstico. Respecto al procedimiento que se siguió en la investigación, éste consistió en: 1) recabar los datos mensuales de INPC, en la página de Instituto Nacional de Estadística y Geografía; b) darle tratamiento a la serie histórica de acuerdo a cada uno de los modelos; c) seguir el procedimiento de pronóstico que establece cada modelo; d) evaluar el pronóstico con el error medio cuadrático y determinar cuál es el modelo que minimiza el error.

3. Resultados

Al considerar los aspectos metodológicos planteados en esta investigación, la evidencia empírica se observa al realizar el pronóstico INPC con cada uno de los modelos expuestos RNA, ARIMA y técnica Holt-Winters.

Pronóstico del INPC mediante redes neuronales artificiales

El pronóstico del INPC es estimado mediante el diseño de una red no lineal autorregresiva con entradas exógenas (NARX); esta red tiene las propiedades de eficiencia en memoria y velocidad. Estas características disminuyen el tiempo en que se entrena la red, ventaja que permite que el proceso de pronóstico sea más rápido; la red utiliza los valores pasados de la serie y rezagos en la información para predecir los valores futuros:

$$Y(t)=f(y(t-1), y(t-2)\dots y(t-n)) \quad (10)$$

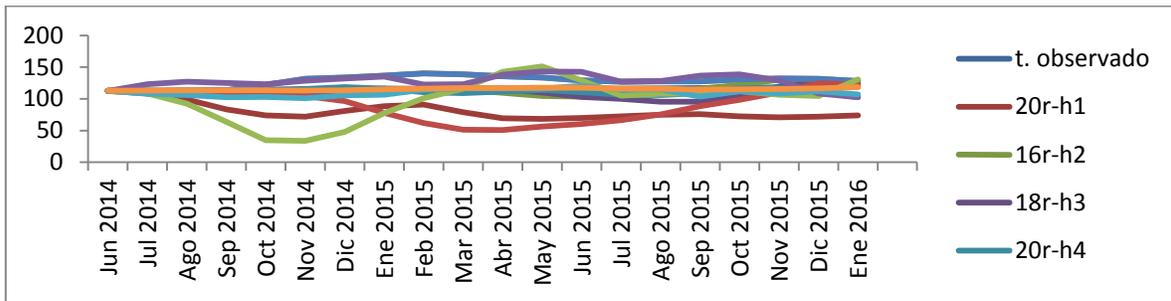


Los datos objetivos que representan la entrada de la red corresponden a las observaciones mensuales del INPC; son divididos aleatoriamente en tres submuestras, el 70% se utiliza en la fase de entrenamiento, 15% en la validación y medición de la generalización del comportamiento de la red neuronal y el 15% para efectos de prueba en la determinación de la red neuronal entrenada.

```
targetSeries = tonndata(INPC, false, false)
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'time'; % Divide up every value
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
```

El entrenamiento de la red se genera mediante el algoritmo de entrenamiento Levenberg-Marquardt de *backpropagation*, algoritmo de optimización que permite alcanzar con mayor rapidez un mínimo global, al minimizar el error en la fase de entrenamiento. A partir de un proceso iterativo de ensayo-error, se consideran diferentes valores para el número de neuronas en la capa oculta y el número de rezagos incluidos en la estructura de la red. El pronóstico que se obtuvo por cada una de las estructuras se muestra en la Gráfica.1.

Gráfica 1. Pronóstico del INPC con diferentes estructuras de una red



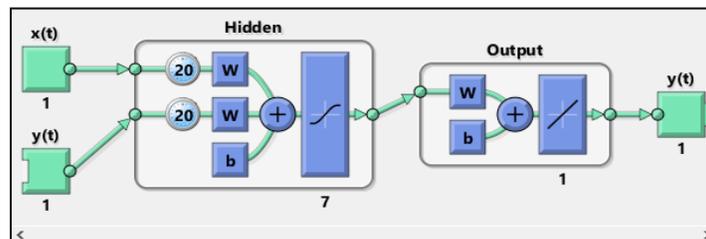
Nota: r se refiere al número de rezagos y h al número de neuronas incluidas en el diseño de la red.

Fuente: Elaboración propia con datos del INPC.

De acuerdo al error cuadrático medio, la estructura de red que minimiza el error es la que considera 20 rezagos y 7 neuronas en la capa oculta con un nivel de desempeño de 91.5%. Esto indica una mejor capacidad predictiva en relación a las demás estructuras de red diseñadas.

La Figura 2 muestra el diseño de la red con la estructura que se seleccionó siguiendo el modelo NARX. Los datos de entrada son representados por el vector x y los datos objetivos están representados por el vector y ; se observa que la red considera los 20 rezagos en los datos de entrada y 7 neuronas en la capa oculta. La salida de la red indica los valores que pronostica la red.

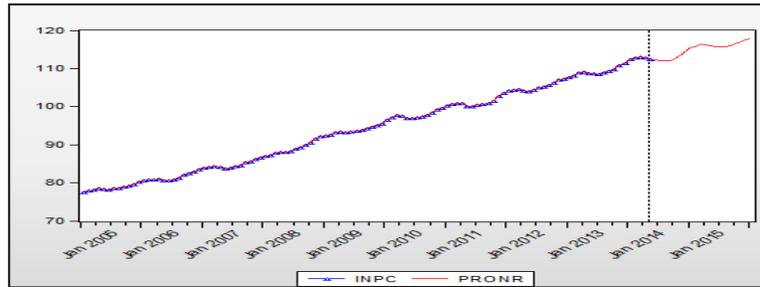
Figura 2. Diseño de la RNA



Fuente: Elaboración propia con datos del INPC y la caja herramientas de RNA de Matlab

En la Gráfica 2, se muestran los valores obtenidos del INPC como resultado del pronóstico realizado con la RNA. Se observa que el pronóstico obtenido (representado por la línea roja continua) se ajusta muy bien a los valores reales del INPC dentro de la muestra.

Gráfica 2. Tendencia del pronóstico



Fuente: Elaboración propia con datos del INPC y la caja herramientas de RNA de Matlab

La Tabla 1 indica que al comparar los valores observados con los pronosticados se marca cierto margen de error.

Tabla 1. Pronóstico con RNA

Fecha	INPC	RNA $t+20$ (2)
	Observado (1)	
Jun 2014	112.722	112.25796
Jul 2014	113.032	112.04706
Ago 2014	113.438	111.9772
Sep 2014	113.939	111.98278
Oct 2014	114.569	112.5899
Nov 2014	115.493	113.55201
Dic 2014	116.059	114.46047
Ene 2015	115.954	115.4663
Feb 2015	116.174	115.86738
Mar 2015	116.647	116.30212
Abr 2015	116.345	116.12019
May 2015	115.764	115.96856
Jun 2015	115.958	115.75109
Jul 2015	116.128	115.67797
Ago 2015	116.373	115.77701
Sep 2015	116.809	115.97621
Oct 2015	117.41	116.53766
Nov 2015	118.051	117.08103
Dic 2015	118.532	117.53644
Ene 2016	118.984	117.84547

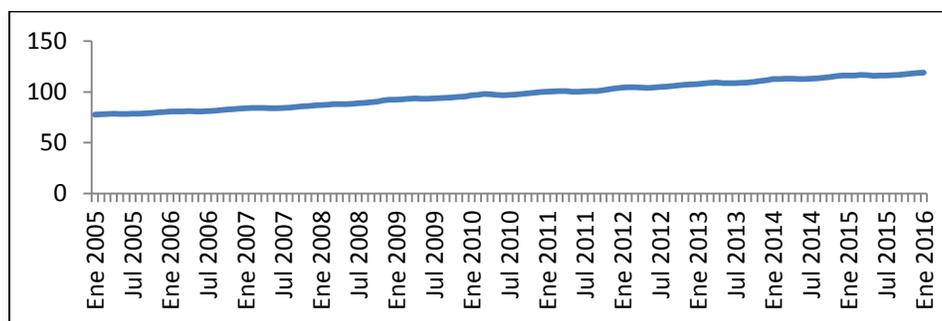
Fuente: Elaboración propia con datos del INPC

En este trabajo se va a seleccionar la metodología que minimice el error cuadrático medio. A continuación se estima el pronóstico del INPC con el modelo ARIMA.

Pronóstico del INPC mediante modelo ARIMA

El primer paso para obtener el pronóstico mediante el modelo autorregresivo integrado de media móvil (ARIMA) es verificar si la serie es estacionaria. En la gráfica 3, se observa un cambio sistemático en la media y en la varianza a lo largo del tiempo.

Gráfica 3. Tendencia del INPC



Fuente: Elaboración propia con datos del INPC

Un criterio formal para detectar la estacionariedad de la serie, es el test de raíz unitaria, el cual se obtiene mediante la prueba Dickey-Fuller aumentada (ADF). La hipótesis nula que se plantea en esta prueba considera la presencia de raíz unitaria en la serie del INPC.

Los resultados de la prueba se indican en la tabla 2. Al ser la probabilidad mayor a 0.05 y el t-estadístico menor en valores absolutos en relación a los valores críticos (ver Tabla 2), se acepta la hipótesis nula: la serie presenta raíz unitaria. Tiene una media y una varianza que se modifica con el tiempo y por lo tanto no es estacionaria, sólo se puede estudiar el comportamiento de la serie durante el periodo en consideración sin generalizar para otros periodos. Para el propósito de realizar un pronóstico sobre cualquier variable, una serie no estacionaria tiene poco valor, es recomendable volverla estacionaria.

Tabla 2. Prueba de Dickey-Fuller aumentada

	t-estadístico	Prob*
Prueba estadística Dickey-Fuller aumentada	0.998479	0.9964
Valores críticos de la prueba		
1%	-3.493129	
5%	-2.888932	
10%	-2.581453	

Fuente: Elaboración propia con datos del INPC

Debido a la no-estacionariedad de la serie se realiza una transformación aplicando logaritmos y una primera diferenciación a los valores de la serie original $\Delta Y = Y - Y_{t-1}$, después de esta transformación se obtiene la prueba Dickey-Fuller aumentada.

La tabla 3 muestra los resultados de la prueba Dickey-Fuller aumentada, los cuales indican una probabilidad de 0.00 y un valor t-estadístico de -8.200339 en valor absoluto, mayor que los valores críticos. La hipótesis nula se rechaza, y por lo tanto se confirma que la serie es estacionaria.

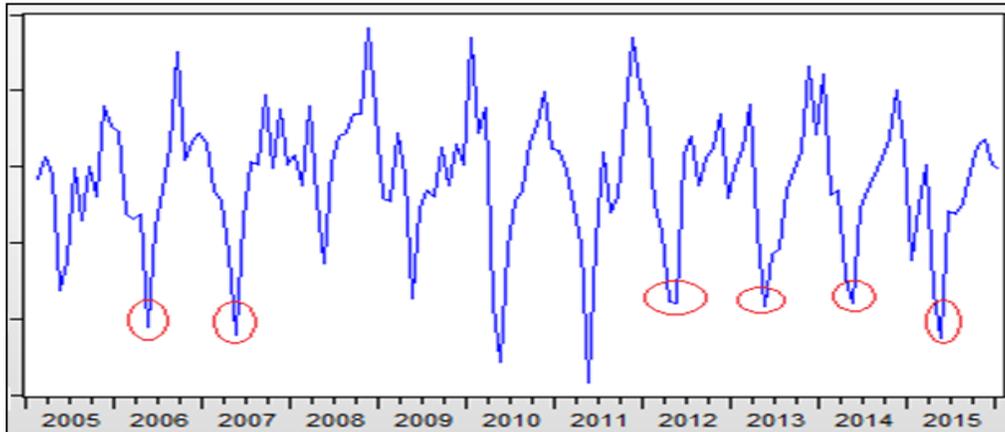
Tabla 3. Prueba de Dickey-Fuller aumentada

	t-estadístico	Prob*
Prueba estadística Dickey- Fuller aumentada	-8.200339	0.000
Valores críticos de la prueba		
1%	-3.493129	
5%	-2.888932	
10%	-2.581453	

Fuente: Elaboración propia con datos del INPC

Al ser el INPC una serie de periodicidad mensual, en la gráfica 4 se observa un componente estacional; que de igual manera es observado en el correlograma que se muestra en la Figura 3.

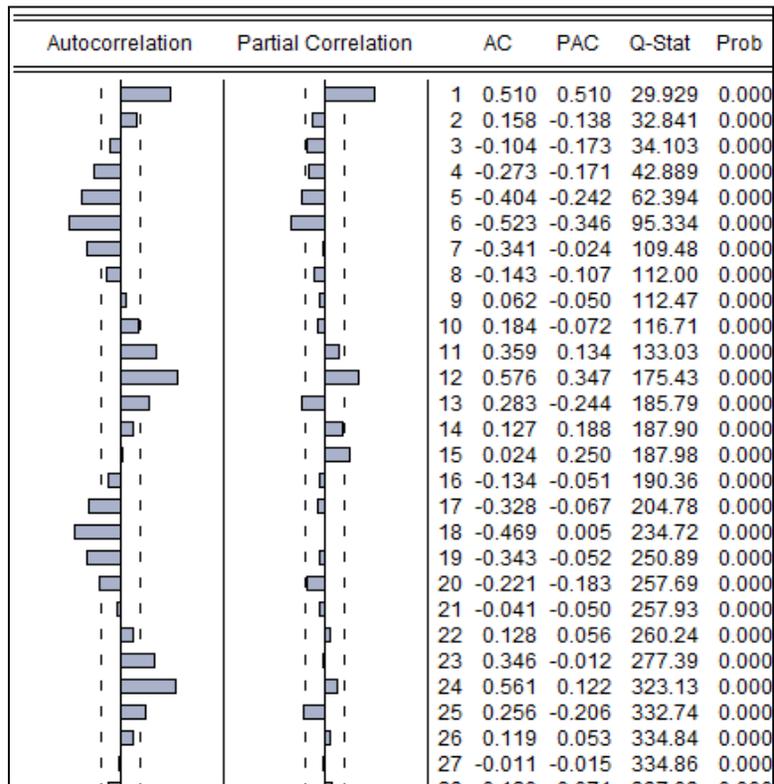
Gráfica 4. Serie estacionaria del INPC



Fuente: Elaboración propia con datos del INPC

A partir de las funciones *fac* y *facp* que se presentan de manera gráfica a través del correlograma que se muestra en la Figura 3 de la serie de tiempo del INPC, se realizó la identificación del modelo ARIMA.

Figura 3. Correlograma del INPC



Fuente: Elaboración propia con datos del INPC

En la Tabla 4 se expresa el modelo que se identificó para efectuar el pronóstico; es un modelo ARIMA estacional (modelo SARIMA). En la tabla 4 se observa que todos los parámetros son significativos de acuerdo al t-estadístico y al nivel de probabilidad.

Tabla 4. Modelo SARIMA

	Coefficiente	Std. error	t-estadístico	Prob.
AR(1)	0.39941	0.090053	4.435291	0.0000
AR(3)	-0.280538	0.088632	-3.1652	0.0021
SAR(12)	1.0055558	0.020794	48.35871	0.0000
MA(12)	-0.883766	0.029001	-30.47336	0.0000

Fuente: Elaboración propia con datos del INPC

Ya determinado el modelo, es posible realizar el pronóstico del INPC, el cual se muestra en la Tabla 5.

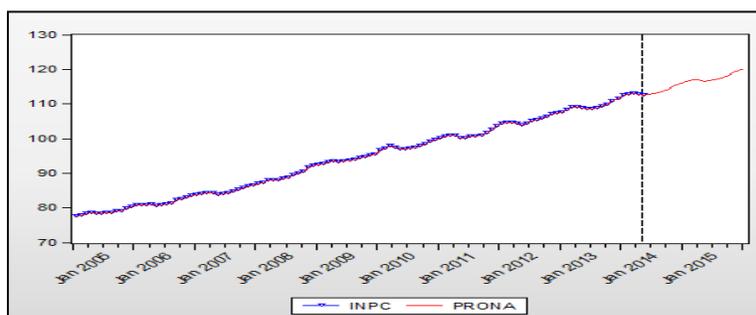
Tabla 5. Pronóstico con modelo SARIMA

Fecha	INPC	$t+20$	Fecha	INPC	$t+20$
Jun 2014	112.72	112.68	Abr 2015	116.35	116.99
Jul 2014	113.03	113.05	May 2015	115.76	116.59
Ago 2014	113.44	113.37	Jun 2015	115.96	116.70
Sep 2014	113.94	113.86	Jul 2015	116.13	117.01
Oct 2014	114.57	114.32	Ago 2015	116.37	117.33
Nov 2014	115.49	115.13	Sep 2015	116.81	117.82
Dic 2014	116.06	115.66	Oct 2015	117.41	118.31
Ene 2015	115.95	116.32	Nov 2015	118.05	119.13
Feb 2015	116.17	116.65	Dic 2015	118.53	119.67
Mar 2015	116.65	117.05	Ene 2016	118.98	120.33

Fuente: Elaboración propia con datos del INPC

La Gráfica 5 presenta la tendencia del pronóstico del INPC, y se observa que el ajuste dentro de la muestra está bien definido.

Gráfica 5. Tendencia del pronóstico



Fuente: Elaboración propia con datos del INPC

Pronóstico del INPC mediante técnica Holt-Winters

En consideración al pronóstico del INPC mediante la técnica Holt-Winters, el primer paso es determinar el número de factores estacionales en la serie. En el caso del INPC y considerando la periodicidad mensual de los datos, la tabla 6 indica los valores para los parámetros alfa, beta y gamma, y se determinan 12 factores estacionales.

Tabla 6. Componente estacional

Parámetros:	Alfa			1
	Beta			0
	Gamma			0
	Suma cuadrada del error			3.997093
	Error cuadrático medio			0.188076
		Media		112.9439
		Tendencia		0.318115
		Estacional:	2013M06	0.994049
			2013M07	0.994091
			2013M08	0.993848
			2013M09	0.995908
			2013M10	0.997293
			2013M11	1.001753
			2013M12	1.00373
			2014M01	1.006347
			2014M02	1.006091
			2014M03	1.006793
			2014M04	1.003788
			2014M05	0.996309

Fuente: Elaboración propia con datos del INPC

Una vez que se obtiene el valor del parámetro alfa, se puede estimar el valor de la constante para el suavizamiento de los datos $a_t = \alpha(y_t/S_{t-p}) + (1 - \alpha)(a_{t-1} + T_{t-1})$. Al obtener el valor de beta se puede obtener el componente de la pendiente de la tendencia $T_t = \beta(a_t - a_{t-1}) + (1 - \beta)T_{t-1}$, y al obtener gama se determina el valor del componente estacional $S_t = \gamma(y_t/a_t) + (1 - \gamma)S_{t-p}$ de tal manera que se pueda obtener el pronóstico para $n+20$ mediante la siguiente ecuación: $y_{t+n} = (a_t + kT_t)S_{t+k-1}$. $y_{t+n} = (a_t + KT_t)S_{t+k-1}$

La estimación en *Eviews* que se muestra en la tabla 6 muestra los valores de α , β y γ que minimizan los errores cuadráticos medios a la hora de obtener el pronóstico. El pronóstico de la serie se puede ver en la tabla 7.

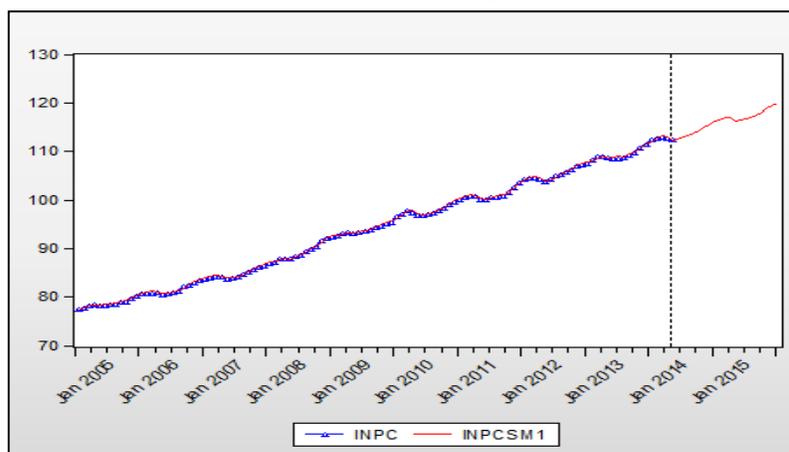
Tabla 7. Pronóstico con técnica Holt-Winters

Fecha	INPC	$t+20$	Fecha	INPC	$t+20$
Jun 2014	112.72	112.59	Abr 2015	116.35	116.88
Jul 2014	113.03	112.91	May 2015	115.76	116.33
Ago 2014	113.44	113.20	Jun 2015	115.96	116.38
Sep 2014	113.94	113.75	Jul 2015	116.13	116.70
Oct 2014	114.57	114.22	Ago 2015	116.37	116.99
Nov 2014	115.49	115.05	Sep 2015	116.81	117.55
Dic 2014	116.06	115.60	Oct 2015	117.41	118.03
Ene 2015	115.95	116.22	Nov 2015	118.05	118.88
Feb 2015	116.17	116.51	Dic 2015	118.53	119.43
Mar 2015	116.65	116.91	Ene 2016	118.98	120.06

Fuente: Elaboración propia con datos del INPC

La Gráfica 6 muestra la tendencia del pronóstico obtenido mediante la técnica Holt-Winters dentro de la muestra y fuera de la muestra.

Gráfica 6. Tendencia del pronóstico.



Fuente: Elaboración propia con datos del INPC

Evaluación de la capacidad predictiva

La capacidad de pronóstico de cada uno de los modelos se llevó a cabo a partir del error cuadrático medio. La fórmula para obtenerlo se expresa en la ecuación 11.

$$ECM = \left[\frac{1}{N} \sum_{n=1}^N (f_n - O_n)^2 \right]^{1/2} \tag{11}$$

El error cuadrático medio para cada uno de los pronósticos obtenidos mediante los diversos modelos se muestra en la Tabla. 8.

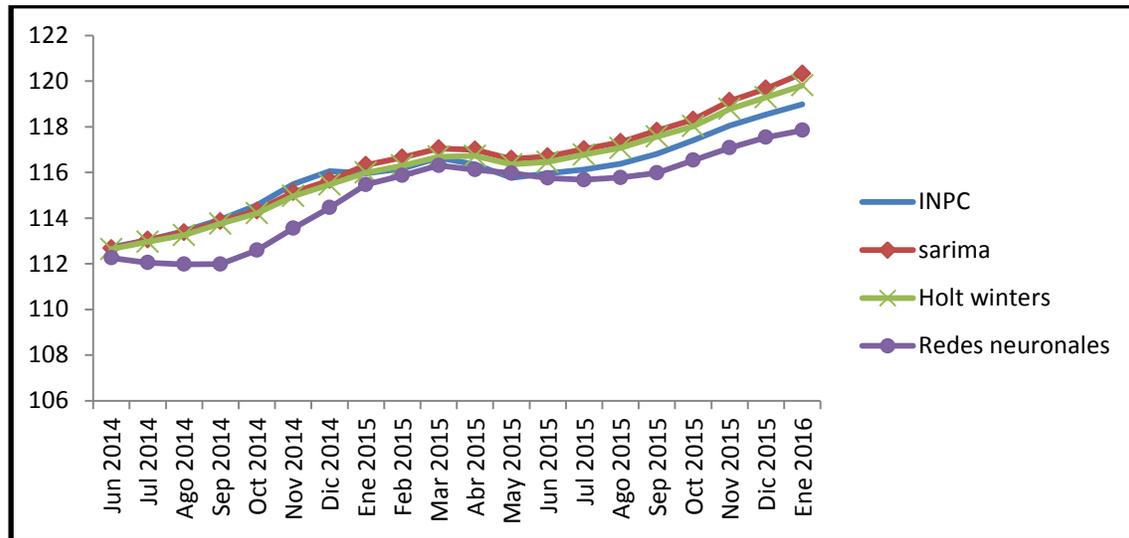
Tabla 8. Error cuadrático medio

	ECM
SARIMA	0.258700984
HOLT-WINTERS	0.037260577
RNA	0.759556223

Fuente: Elaboración propia con datos del INPC

De acuerdo al error cuadrático medio, la técnica Holt-Winters tiene un error menor en el pronóstico del INPC, seguida por el modelo ARIMA estacional, mientras que la red neuronal artificial presenta el mayor error.

Gráfica 7. Pronóstico del INPC



Fuente: Elaboración propia con datos del INPC

El pronóstico del INPC obtenido fuera de la muestra analizada por cada una de las metodologías se puede contrastar de forma visual en la gráfica 7. Claramente se ve un horizonte de tiempo que parte de junio del 2014 a enero del 2016, es decir, se tiene un pronóstico de 20 observaciones que se compara con el valor real observado del INPC. El modelo ARIMA y la técnica de Holt-Winters permiten un mejor ajuste en los primeros diez datos pronosticados; a partir del número 11 el error empieza a crecer y se genera un pronóstico sobreestimado. En este ejercicio, del pronóstico que se obtiene mediante la red neuronal se observa que sigue la tendencia de la serie, sin embargo genera un pronóstico subestimado.

4. Discusión

Una limitación dentro del trabajo radica en el hecho de que se pronostica el INPC como una serie de tiempo, sin considerar variables independientes. Por lo tanto se podría presentar un área de debilidad respecto a la teoría económica, al no incluir variables que puedan influir sobre la inflación. Estas variables podrían ser la tasa de interés, tipo de cambio fijo e índice global de la actividad económica, entre otras; la metodología a utilizar sería la indicada por un modelo vectorial autorregresivo (VAR).

La principal fortaleza del trabajo es la comparación de los pronósticos obtenidos con cada una de las metodologías propuestas e identificar aquellas que minimizan el error cuadrático medio y por lo tanto tienen mayor poder de predicción.

5. Conclusiones

En la economía y las finanzas los pronósticos de indicadores macroeconómicos se han convertido en una herramienta indispensable dentro de la planeación de políticas económicas y decisiones de inversión, ahorro y consumo para los diversos agentes económicos. El futuro es incierto pero los pronósticos permiten anticipar situaciones de riesgo. A lo largo de este trabajo se describen tres metodologías de pronóstico del INPC; se elige este indicador por su importancia a nivel macroeconómico y su influencia en los sectores financiero y real; una vez expuestas las bases teóricas de las tres metodologías se realizó el correspondiente pronóstico y al final una comparación de los resultados logrados.

Los resultados obtenidos permiten comparar los pronósticos provenientes de un modelo no lineal (red neuronal) con los de un modelo lineal tradicional ARIMA estacional y la técnica Holt-Winters de suavizado con componente estacional. Los resultados empíricos de la prueba, al realizar el contraste de la capacidad predictiva, muestran mayor poder de predicción de los modelos lineales para pronósticos con un horizonte menor a diez días, mientras que el modelo no lineal proyecta valores subestimados.

Una desventaja que se hizo evidente en el caso de la red neuronal es que el entrenamiento de la red es largo y consume un tiempo considerable, lo que hace más lento el proceso de obtener el pronóstico.

Resulta interesante comparar las mismas tres metodologías con diversas variables económicas y financieras a fin de identificar comportamientos para ampliar las conclusiones.

Bibliografía

- Angeriz, A. y Arestis, P. (2009). Objetivo de inflación: evaluación de la evidencia. *Investigación Económica*, 68(SPE), pp. 21-46.
- Banco de México (2002). El Índice Nacional de Precios al Consumidor: características y actualización de su base al año 2002. México.
- Banco de México (2011). Documento metodológico. INPC. México.
- Box, G. y Jenkins, G. (1970). Time series analysis: forecasting and control. Holden dsy, Inc. San Francisco.
- Chatfield, C. y Yar, M. (1988). Holt-Winters forecasting: Some practical issues. *The Statistician*, 37, pp. 129-140.
- Contreras, J., Espínola R., Nogales, F. J. y Conejo A. J. (2003). ARIMA models to predict next-day electricity prices. *IEEE Trans. Power Syst.*, 18(3), pp. 1014-1020.
- Fadlalla, A. y Lin, C. H. (2001). An Analysis of the Applications of Neural Networks in Finance. *Interfaces*, 31(4), pp. 112-122.
- Faraway, J. y Chatfield, C. (1998). Time series forecasting with neural networks: a comparative study using the airline data. *Applied Statistics*, 47 (2), pp. 231–250.
- Freeman, J. A. y Skapura, D.M. (1993). *Redes Neuronales, algoritmos, aplicaciones y técnicas de programación*. Addison-Wesley/ Diaz de Santos, Estados Unidos de América.
- Gelper,S., Fried, R. y Croux, C.(2010). Robust forecasting with exponential and Holt-Winters smoothing. *Journal of Forecasting*, 29, pp. 285-300.

- Gonzalez, M.P (2009). Técnicas de Predicción Económica. Serie de documentos Sarrikon, Universidad del País Vasco (UPV-EHU), pp. 284.
- Hagan, M. T., Demuth, H.B., y Beale, M. H. (2002). *Neural network design*, PWS Publishing Company, USA.
- INEGI, (2013). Índice Nacional de Precios al Consumidor, Documento metodológico, Instituto Nacional de Estadística y Geografía, México.
- Jonson, C.A., y Padilla, M.A. (2005). Regularidades no lineales en índices accionarios. Una aproximación con redes neuronales. *El Trimestre Económico*, LXXII-4 (288), pp. 765-821.
- Jiménez, J. F., Gázquez, J. C. y Sánchez, R. (2006). La capacidad predictiva en los métodos Box-Jenkins y Holt-Winters: una aplicación al sector turístico. Universidad de Almería.
- Mantey G. (2009). Intervención esterilizada en el mercado de cambios en un régimen de metas de inflación: la experiencia de México. *Investigación Económica*. 68(SPE), pp. 47-78.
- Martin, B. y Sanz A. (2007). *Redes Neuronales y Sistemas Borrosos*, 3a ed, Alfaomega, México.
- McCulloch S. y Piits, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), pp. 115-133.



- Ponce, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*, Alfaomega, México.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 65(6), p 386.
- Rumelhart D., Hinton G. y Williams R. (1986). Learning representation by backpropagating errors, *Nature* 323, pp. 533-536.
- Sanchez, J. (2006). Aplicación de los métodos Mars, Holt-Winters y ARIMA generalizado en el pronóstico de caudales medios mensuales en Rios de Antioquia. *Meteorología colombiana*, N.10.
- Swales, G. y Young, Y. (1992). Applying Artificial Neural Networks to Investment Analysis, *Financial Analysts Journal*, 48(5), pp. 78-81.
- Villada, F., Cadavie, D. R. y Molina J. D. (2008). Pronóstico del precio de la energía eléctrica usando redes neuronales artificiales. *Revista facultad de ingeniería*, (44), pp. 111-118.
- Villamil, J. A. y Delgado, J. A. (2007). Entrenamiento de una red neuronal multicapa para la tasa de cambio euro-dólar (EUR/USD). *Ingeniería e investigación*, 27(3), pp. 106-117.
- Werbos P. (1974). Beyond regression: new tools for prediction and analysis in the behavioral sciences. PhD thesis, Harvard University.
- Windrow B. y Hoff, M.E. (1960). Adaptive switching circuits, IRE WESCON Convention Record, parte 4, pp. 96-104.

Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, pp. 324–342.

Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, pp. 159-175.