

Uso de redes neuronales para el pronóstico de la inflación en México

Use of neural networks for inflation forecasting in Mexico

Héctor Pedroza Robles, *Universidad Nacional Autónoma de México*

Resumen

El objetivo de este artículo es mostrar el poder predictivo de la red neural artificial (RNA) como método alternativo para pronosticar la inflación mensual en México. Utilizando un enfoque de series de tiempo dando énfasis en el factor estacional y un proceso AR(1), dándole importancia al análisis de los datos antes de su implementación, que a pesar de ser sencilla, requiere de realizar distintas pruebas y ajustes para encontrar un modelo que generalice los patrones que presenta la serie.

Abstract

The aim of this paper is to show the predictive power of the artificial neural network (ANN) as an alternative method to forecast monthly inflation in Mexico. Using a time series approach emphasizing the seasonal factor and an AR (1) process, giving importance to the analysis of the data before its implementation, which requires different tests and adjustments to find a model that generalizes the patterns presented by the series.

Palabras clave— redes neuronales, RNA, inflación, México, series de tiempo

Keywords— neural networks, ANN, inflation, Mexico, time series

Introducción

El uso de redes neuronales artificiales (RNA) se ha popularizado debido a su desempeño en tareas de clasificación y regresión, así como a su implementación sencilla en diversos lenguajes de programación. Son capaces de detectar y aprender patrones complejos, especialmente en el modelado de series no lineales; por tanto, se han convertido en una herramienta útil para el análisis de información como el pronóstico de variables complejas.¹

El objetivo del presente artículo es mostrar la capacidad predictiva para series de tiempo no lineales que tiene esta técnica de estimación no paramétrica; asimismo, mostrar una metodología para el uso de redes neuronales con respecto a variables económicas. El caso particular es la predicción de la inflación en México. Puesto que la inflación influye en las decisiones de los agentes económicos, un pronóstico acertado puede beneficiar a dichos agentes (consumidores, productores y creadores de políticas monetarias)² mediante la predicción de los ajustes de los precios. Al ser el precio una variable que afecta a toda la economía, lo hace un candidato para el uso de esta herramienta de pronóstico.³

Datos y Metodología

Se utiliza la inflación mensual⁴ de enero de 1971 a mayo de 2019, siendo un total de 581 datos. El reducido número de observaciones con las que se cuenta puede llegar a ser

1. Jesús García Herrero y col., *Ciencia de datos. Técnicas analíticas y aprendizaje estadístico* (Alfaomega, 2018).

2. Chiranjit Chakraborty y Andreas Joseph, «Machine learning at central banks», *Bank of England*, número 674 (2017), <https://www.bankofengland.co.uk/-/media/boe/files/working-paper/2017/machine-learning-at-central-banks.pdf?1a=en&hash=EF5C4AC6E7D7BDC1D68A4BD865EEF3D7EE5D7806> hacen énfasis en que los Bancos Centrales deben hacer uso de técnicas de machine learning como lo son las redes neuronales.

3. M. Ali Choudhary y Adnan Haider, «Neural network models for inflation forecasting: An appraisal», *Applied Economics* 44, número 20 (2012): 2631-2635, ISSN: 00036846, doi:10.1080/00036846.2011.566190.

4. INEGI, *Banco de Información Económica*, visitado 2 de julio de 2019, <https://www.inegi.org.mx/app/indicadores/?tm=0#divFV628194>.

un problema para el entrenamiento de la red neuronal, puesto que es probable que no logre generalizar el comportamiento de la serie.

Una solución a dicho problema sería el uso de datos de mayor frecuencia como lo es la inflación quincenal. No obstante, en trabajos como en el de Choudhary y Haider⁵ y Rani, Haragopal y Reddy⁶ se utilizaron una menor cantidad de datos obteniendo buenos resultados, por lo que se opta por utilizar la serie mensual.

Es recomendable hacer estacionaria la serie como lo hace Gheyas y Smith,⁷ Khashei y Bijari;⁸ sin embargo, Ortiz,⁹ el cual usa redes neuronales para pronosticar el precio del petróleo, resalta que se pueden obtener buenos resultados a partir de los datos de entrada directos, por lo que se prefiere escalar de los datos entre 0 y 1 de la siguiente forma:

$$x' = \frac{x - \text{mín}(x)}{\text{máx}(x) - \text{mín}(x)} \quad (1)$$

Una vez escalados los datos (x'), se puede analizar la serie utilizando la metodología de Benkachcha, Benhra y El Hassani,¹⁰ la cual consiste en utilizar los componentes estacionales, irregulares y de tendencia. Se sabe gracias a las investigaciones de Capistrán, Constandse y Ramos-Francia¹¹ que, desde 2001 (Figura 1), la inflación es explicada por el componente

5. Ali Choudhary y Haider, «Neural network models for inflation forecasting: An appraisal».

6. S. A. Jyothi Ran, V. V. Haragopal y M. Krishna Reddy, «Forecasting Inflation Rate of India using Neural Networks», *International Journal of Computer Applications* 158, número 5 (2017): 45-48, doi:10.5120/ijca2017912866.

7. Iffat A Gheyas y Leslie S Smith, «A Neural Network Approach to Time Series Forecasting», *Lecture Notes in Engineering and Computer Science* II, número 1 (2009): 1-5.

8. Mehdi Khashei y Mehdi Bijari, «An artificial neural network (p, d, q) model for timeseries forecasting», *Expert Systems with Applications* 37, número 1 (2010): 479-489, ISSN: 09574174, doi:10.1016/j.eswa.2009.05.044, <http://dx.doi.org/10.1016/j.eswa.2009.05.044>.

9. Francisco Ortiz Arango, «Pronóstico de precios de petróleo: una comparación entre modelos GARCH y redes neuronales diferenciales», *Investigacion Economica* 76, número 300 (2017): 105-126, ISSN: 01851667, doi:10.1016/j.inveco.2017.06.002.

10. Said Benkachcha, Jamal Benhra e Hicham El Hassani, «Seasonal Time Series Forecasting Models based on Artificial Neural Network», *International Journal of Computer Applications* 116, número 20 (2015): 9-14.

11. Carlos Capistrán, Christian Constandse y Manuel Ramos-Francia, «Uso de Modelos Estacionales Para Pronosticar la Inflación a Corto Plazo», *Banco de México, Documento de Investigación*, número 05 (2009), <http://www.anterior.banxico.org.mx/publicaciones-y-discursos/publicaciones/documentos-de->

estacional, debido a que lo indican los cambios en el espectro.¹²




Figura 1: Inflación mensual enero 2001- mayo 2019 (%)

Fuente: Elaboración propia con datos de INEGI.

Considerando la estacionalidad, se utiliza como una adecuación de la arquitectura propuesta por Nakamura¹³ expresada de la siguiente forma:

$$\begin{aligned} \hat{\pi}_{t+j} = & L_1(w_{11}\pi_{-1} + w_{12}\pi_{-12} + b_1) + \\ & L_2\text{relu}(w_{21}\pi_{-1} + w_{22}\pi_{-12} + b_2) + \\ & L_3\text{relu}(w_{31}\pi_{-1} + w_{32}\pi_{-12} + b_3) \end{aligned} \tag{2}$$

Donde

π_t = Inflación mensual L_n = Capas ocultas ^a

w_n = Pesos b_n = Sesgos (bias)

relu = Función de activación unidad lineal rectificadas

investigacion/banxico/%7B2ACF8314-62A9-47B8-511F-B6D003D20540%7D.pdf.

12. Ibídem.

13. Emi Nakamura, «Inflation forecasting using a neural network», *Economics Letters* 86, número 3 (2005): 373-378, ISSN: 01651765, doi:10.1016/j.econlet.2004.09.003.

La función relu se define como:

$$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases} \quad (3)$$

Una vez planteada la arquitectura, se entrena al modelo utilizando el 80 % de los datos y el resto para prueba. Esto se realiza para evitar que el modelo memorice los datos en vez de hacer generalizaciones. Se utiliza la librería Keras desarrollada en Python, haciendo uso de un optimizador nadam y una función de pérdida de error cuadrado medio.

Resultados

Después de entrenar la RNA por 100 épocas, se pronostican los valores reservados para las pruebas, por lo que se evalúa el desempeño fuera de la muestra. Lo anterior quiere decir que son datos que el modelo no conoce, por lo que es necesario determinar si el modelo logró generalizar (aprender el patrón de la serie). Utilizando las métricas presentadas en el cuadro 1.

Cuadro 1: Desempeño de la red neuronal
Fuente: Elaboración propia.

Error cuadrado medio ^a	0.000522
Raíz de error cuadrado medio	0.001071
Perdida empírica	0.027049

^a Es el error con los datos de entrenamiento.

Como se puede observar, el modelo se desempeñó de manera favorable fuera de la muestra, logrando reducir la perdida empírica.¹⁴ Como se mencionó anteriormente, logró capturar el patrón estacional.¹⁵ (Figura 2)

14. La pérdida empírica es el error cuadrado medio con los datos de prueba, es decir fuera de la muestra.

15. En el Anexo 1 se encuentra una tabla con los valores observados y pronosticados.

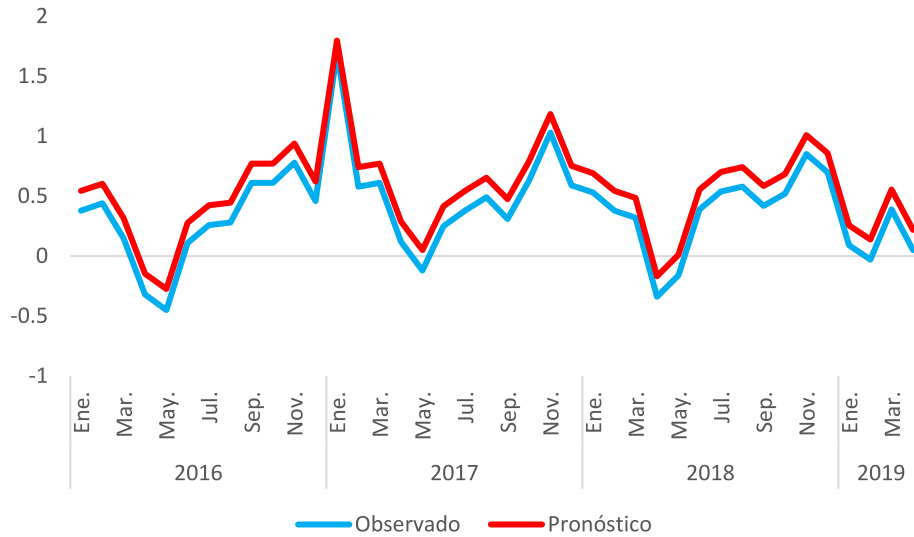


Figura 2: Pronóstico inflación enero 2016 – mayo 2019* (%)

Fuente: Elaboración con estimación propia y datos de INEGI

*Los datos se regresan a su escala original.

Conclusiones

El enfoque propuesto de RNA para el pronóstico de la inflación es de gran utilidad por su sencilla implementación, mostrando que se pueden obtener buenos pronósticos sin la necesidad de realizar complejas transformaciones a los datos de entrada. Sin embargo, es importante realizar un diagnóstico de la serie para poder plantear una arquitectura adecuada. Por otra parte, se debe prestar atención a la cantidad de datos que se destinan a entrenamiento y prueba, el número de neuronas que se utilizan y el optimizador.

Referencias

- Ali Choudhary, M., y Adnan Haider. «Neural network models for inflation forecasting: An appraisal». *Applied Economics* 44, número 20 (2012): 2631-2635. ISSN: 00036846. doi:10.1080/00036846.2011.566190.
- Benkachcha, Said, Jamal Benhra e Hicham El Hassani. «Seasonal Time Series Forecasting Models based on Artificial Neural Network». *International Journal of Computer Applications* 116, número 20 (2015): 9-14.
- Capistrán, Carlos, Christian Constandse y Manuel Ramos-Francia. «Uso de Modelos Estacionales Para Pronosticar la Inflación a Corto Plazo». *Banco de México, Documento de Investigación*, número 05 (2009). <http://www.anterior.banxico.org.mx/publicaciones-y-discursos/publicaciones/documentos-de-investigacion/banxico/%7B2ACF8314-62A9-47B8-511F-B6D003D20540%7D.pdf>.
- Chakraborty, Chiranjit, y Andreas Joseph. «Machine learning at central banks». *Bank of England*, número 674 (2017). <https://www.bankofengland.co.uk/-/media/boe/files/working-paper/2017/machine-learning-at-central-banks.pdf?la=en&hash=EF5C4AC6E7D7BDC1D68A4BD865EEF3D7EE5D7806>.
- García Herrero, Jesús, Antonio Berlanga de Jesús, José Manuel Molina López, Miguel Ángel Patricio Guisado, Álvaro Luis Bustamante y Washington R. Padilla. *Ciencia de datos. Técnicas analíticas y aprendizaje estadístico*. Alfaomega, 2018.
- Gheyas, Iffat A, y Leslie S Smith. «A Neural Network Approach to Time Series Forecasting». *Lecture Notes in Engineering and Computer Science II*, número 1 (2009): 1-5.
- INEGI. *Banco de Información Económica*. Visitado 2 de julio de 2019. <https://www.inegi.org.mx/app/indicadores/?tm=0#divFV628194>.

- Jyothi Ran, S. A., V. V. Haragopal y M. Krishna Reddy. «Forecasting Inflation Rate of India using Neural Networks». *International Journal of Computer Applications* 158, número 5 (2017): 45-48. doi:10.5120/ijca2017912866.
- Khashei, Mehdi, y Mehdi Bijari. «An artificial neural network (p, d, q) model for timeseries forecasting». *Expert Systems with Applications* 37, número 1 (2010): 479-489. ISSN: 09574174. doi:10.1016/j.eswa.2009.05.044. <http://dx.doi.org/10.1016/j.eswa.2009.05.044>.
- Nakamura, Emi. «Inflation forecasting using a neural network». *Economics Letters* 86, número 3 (2005): 373-378. ISSN: 01651765. doi:10.1016/j.econlet.2004.09.003.
- Ortiz Arango, Francisco. «Pronóstico de precios de petróleo: una comparación entre modelos GARCH y redes neuronales diferenciales». *Investigacion Economica* 76, número 300 (2017): 105-126. ISSN: 01851667. doi:10.1016/j.inveco.2017.06.002.

Anexo 1 - Datos del Pronóstico

Cuadro 2: Datos del pronóstico

Fecha	Observado	Pronóstico
2010/01	1.09	0.5714899
2010/02	0.58	1.0488693
2010/03	0.71	0.8010428
2010/04	-0.32	0.8159418
2010/05	-0.63	-0.08992507
2010/06	-0.03	-0.22352482
2010/07	0.22	0.2158504
2010/08	0.28	0.41375428
2010/09	0.52	0.52902824
2010/10	0.62	0.65537584
2010/11	0.8	0.7893323
2010/12	0.5	0.89595366
2011/01	0.49	0.85028356
2011/02	0.38	0.7100383
2011/03	0.19	0.6618055
2011/04	-0.01	0.24061273
2011/05	-0.74	-0.09832424
2011/06	0	-0.3491177
2011/07	0.48	0.22049786
2011/08	0.16	0.60953313
2011/09	0.25	0.46014944
2011/10	0.67	0.53312296
2011/11	1.08	0.8784905
2011/12	0.82	1.1186364
2012/01	0.71	0.9500589

Cuadro 2: Datos del pronóstico (continuación)

Fecha	Observado	Pronóstico
2012/02	0.2	0.83396244
2012/03	0.06	0.42136508
2012/04	-0.31	0.2512618
2012/05	-0.32	-0.39565757
2012/06	0.46	-0.04118611
2012/07	0.56	0.62805444
2012/08	0.3	0.6588432
2012/09	0.44	0.4998109
2012/10	0.51	0.68649447
2012/11	0.68	0.8386251
2012/12	0.23	0.90210813
2013/01	0.4	0.56368715
2013/02	0.49	0.54411393
2013/03	0.73	0.5826381
2013/04	0.07	0.6425122
2013/05	-0.33	0.18956116
2013/06	-0.06	0.078191884
2013/07	-0.03	0.27608237
2013/08	0.28	0.24863139
2013/09	0.38	0.5035855
2013/10	0.48	0.60528165
2013/11	0.93	0.7209556
2013/12	0.57	0.9399393
2014/01	0.89	0.7441557
2014/02	0.25	0.97660285
2014/03	0.27	0.59223956

Cuadro 2: Datos del pronóstico (continuación)

Fecha	Observado	Pronóstico
2014/04	-0.19	0.42179948
2014/05	-0.32	-0.057785295
2014/06	0.17	-0.05655971
2014/07	0.28	0.28535497
2014/08	0.36	0.4749386
2014/09	0.44	0.56043506
2014/10	0.55	0.6445553
2014/11	0.81	0.8321007
2014/12	0.49	0.9376663
2015/01	-0.09	0.79690826
2015/02	0.19	0.21919516
2015/03	0.41	0.39677367
2015/04	-0.26	0.43836078
2015/05	-0.5	-0.08875688
2015/06	0.17	-0.1253267
2015/07	0.15	0.36642092
2015/08	0.21	0.40129545
2015/09	0.37	0.46191624
2015/10	0.51	0.6043917
2015/11	0.55	0.7723439
2015/12	0.41	0.7320019
2016/01	0.38	0.49695215
2016/02	0.44	0.53569204
2016/03	0.15	0.62896985
2016/04	-0.32	0.2511527
2016/05	-0.45	-0.26173994

Cuadro 2: Datos del pronóstico (continuación)

Fecha	Observado	Pronóstico
2016/06	0.11	-0.092521735
2016/07	0.26	0.29533598
2016/08	0.28	0.44146276
2016/09	0.61	0.50024676
2016/10	0.61	0.7689662
2016/11	0.78	0.79338044
2016/12	0.46	0.88127553
2017/01	1.7	0.6543445
2017/02	0.58	1.5381021
2017/03	0.61	0.72004163
2017/04	0.12	0.5627286
2017/05	-0.12	0.14028792
2017/06	0.25	0.14798601
2017/07	0.38	0.43575355
2017/08	0.49	0.5497052
2017/09	0.31	0.71163267
2017/10	0.63	0.58851117
2017/11	1.03	0.8480382
2017/12	0.59	1.0718004
2018/01	0.53	1.0616889
2018/02	0.38	0.7426045
2018/03	0.32	0.6401632
2018/04	-0.34	0.47509503
2018/05	-0.16	-0.06574397
2018/06	0.39	0.13166189
2018/07	0.54	0.5618778

Cuadro 2: Datos del pronóstico (continuación)

Fecha	Observado	Pronóstico
2018/08	0.58	0.71943235
2018/09	0.42	0.7122138
2018/10	0.52	0.67561316
2018/11	0.85	0.833177
2018/12	0.7	0.9694798
2019/01	0.09	0.8636409
2019/02	-0.03	0.38747752
2019/03	0.39	0.26014364
2019/04	0.05	0.31595504
2019/05	-0.29	0.21694665