

# Colombian inflation forecast using Long Short-Term Memory approach

Borradores de Economía

**Número:**

1241

**DOI:**

<https://doi.org/10.32468/be.1241>

**Publicado:**

Miércoles, 21 Junio 2023

**Authors:**

Julián Alonso Cárdenas-Cárdenas<sup>e</sup>,

Deicy Johana Cristiano-Botia<sup>a</sup>,

Nicolás Martínez-Cortés<sup>a</sup>

Ver más

<sup>e</sup>Externo

<sup>a</sup>Banco de la República, Colombia

**Clasificación JEL:**

C45, C51, C52, C53, C61, E37

**Palabras clave:**

Aprendizaje profundo, redes neuronales Long Short-Term Memory, pronóstico, Inflación

[Descargar documento](#)

- [RESUMEN NO TÉCNICO](#)
- [Enfoque](#)
- [Contribución](#)
- [Resultados](#)

## Lo más reciente

[Impacto macroeconómico y fiscal del cambio demográfico](#)

Jesús Alonso Botero-García, Ligia Alba Melo-Becerra, Cristian Castrillón Gaviria, Daniela Gallo

[Uncertainty and monetary policy: the case of the Central Bank of Colombia](#)

Hernando Vargas-Herrera

[Revista Ensayos Sobre Política Económica - Explorando las brechas de género en Colombia](#)

María Teresa Ramírez-Giraldo, Karina Acosta, Olga Lucia Acosta Navarro, Lucia Arango-Lozano, Fernando Arias-Rodríguez, Oscar Iván Ávila-Montealegre, Oscar Reinaldo Becerra Camargo, Leonardo Bonilla-Mejía, Grey Yuliet Ceballos-García, Luz Adriana Flórez, Juan Miguel Gallego-Acevedo, Luis Armando Galvis-Aponte, Luis M. García-Pulgarín, Andrés Felipe García-Suaza, Anderson Grajales, Daniela Gualtero-Briceño, Didier Hermida-Giraldo, Ana María Iregui-Bohórquez, Juliana Jaramillo-Echeverri, Karen Laguna-Ballesteros, Francisco Javier Lasso-Valderrama, Daniel Márquez, Carlos Alberto Medina-Durango, Ligia Alba Melo-Becerra, María Fernanda Meneses-González, Juan José Ospina-Tejeiro, Andrea Sofía Otero-Cortés, Daniel Parra-Amado, Juana Piñeros-Ruiz, Christian Manuel Posso-Suárez, Natalia Ramírez-

## RESUMEN NO TÉCNICO

### Enfoque

Se utilizan redes neuronales *Long Short-Term Memory* (LSTM) para el pronóstico de la inflación en Colombia. Esta es una metodología de aprendizaje profundo que ha demostrado alta capacidad de pronóstico en diversos tipos de aplicaciones. En este trabajo utilizamos dos enfoques, uno que solo incorpora información de la variable objetivo, la inflación, otro que emplea información adicional proveniente de algunas variables potencialmente relevantes. Se aplica *rolling sample* dentro del proceso tradicional de construcción de las redes neuronales, incorporando el método de optimización bayesiano y seleccionando los hiperparámetros con criterios de minimización del error de pronóstico. Utilizamos modelos tipo ARIMA optimizados para pronóstico (con y sin variables explicativas) para comparar los resultados de las redes LSTM.

### Contribución

Este documento aporta a la literatura existente sobre la aplicación de métodos de aprendizaje profundo para pronosticar el comportamiento de series macroeconómicas como la inflación, tarea relevante para los bancos centrales y organizaciones internacionales relacionadas. El documento presenta una descripción detallada de la aplicación y de los resultados obtenidos con la metodología LSTM. Asimismo, representa una herramienta adicional en la batería de modelos utilizados por el Banco de la República para el pronóstico de la inflación en Colombia.

**Modelos de redes neuronales LSTM tienen mejor capacidad de pronóstico de la inflación en Colombia que modelos tipo ARIMA, especialmente para horizontes más largos y cuando se incluye información de variables adicionales.**

### Resultados

Esta aplicación sobre la inflación en Colombia encuentra que los modelos LSTM superan en capacidad de pronóstico a modelos tipo ARIMA, en especial para horizontes más largos (de siete a 12 meses). Además, los resultados muestran que es útil incluir variables adicionales (auxiliares o explicativas) como insumo de los modelos de redes neuronales LSTM ya que al hacerlo mejora notablemente su capacidad de predicción (de nuevo, con mayor ganancia en horizontes más largos). Adicionalmente sugiere que para series con características similares a la modelada (relativamente corta y con comportamiento poco complejo en el contexto del aprendizaje profundo) no se requiere una arquitectura compleja del modelo LSTM ya que ello no necesariamente conduce a mejores resultados en términos de capacidad de pronóstico.