

# Pronósticos de inflación ¿Inflación por productos, *machine learning* o ‘enfoque contrafactual’?

Néstor Torres Betanco<sup>\*</sup>

## Resumen

El control y monitoreo de la inflación son parte del quehacer de un Banco Central, de modo que contar con pronósticos precisos puede ayudar a tomar mejores decisiones de política. Así, este documento tiene el objetivo de proveer un esquema sencillo y preciso de pronósticos de inflación a corto y mediano plazo basado en tres enfoques: 1) modelos de inflación por productos (MIPP); 2) modelos de *machine learning* y redes neuronales; y, 3) modelos basados en un principio contrafactual que internaliza expectativas inflacionarias externas. Se usan diversas simulaciones de distintos modelos que, junto con métodos de combinación de pronósticos, permiten obtener mejores estimaciones. Se observa que el ‘enfoque contrafactual’ es más preciso para pronosticar la inflación a corto y mediano plazo, pero las técnicas de *machine learning* y redes también manifiestan un alto grado de precisión. En tanto, el enfoque MIPP proporciona pronósticos precisos sólo a corto plazo.

**Palabras clave:** Inflación, *Machine learning*, Redes neuronales, Modelos dinámicos, Combinación de pronósticos.

**Códigos JEL:** E31, C32, C52, C53.

---

<sup>\*</sup> El autor es estudiante de doctorado en economía en la Universidad de Barcelona. Para comentarios comunicarse al correo: [nestortorres@ub.edu](mailto:nestortorres@ub.edu). El contenido de este documento es de exclusiva responsabilidad de su(s) autor(es), y no necesariamente representa la posición oficial del Banco Central de Nicaragua.

## 1. Introducción

El control y monitoreo de la inflación son parte del objetivo fundamental de los Bancos Centrales, de modo que contar con pronósticos precisos y oportunos de este indicador, puede ayudar en la toma de decisiones. En este sentido, el desarrollo de herramientas parsimoniosas y manejables para pronósticos inflacionarios es un componente importante para el éxito de dichas decisiones. No obstante, pronosticar la inflación es y ha sido siempre una tarea desafiante (McAdam & McNelis 2005, p.862), en parte, porque la inflación es a menudo afectada por factores aleatorios e imprevisibles.

Los métodos de pronósticos y combinación de pronósticos han sido ampliamente utilizados en la literatura, y la inflación ha sido uno de los indicadores de mayor cobertura, debido a su importancia en el diseño de políticas económicas, particularmente para los Bancos Centrales (véase: Stock & Watson 1999, Forni et al. 2003, D'Amato et al. 2008, Wright 2009, Koop & Korobilis 2012, Groen et al. 2013, Kelikume & Salami 2014, Chen et al. 2014, Breitung & Roling 2015, Aparicio & Bertolotto 2020, entre otros). Si bien los resultados de los pronósticos suelen ser mixtos (en función del método utilizado y el horizonte considerado), en la literatura existe un consenso: la combinación de pronósticos suele proveer mejores resultados, comparado con estimaciones individuales (véase Timmermann 2006). Además, la literatura reciente muestra que métodos avanzados de *machine learning* y redes neuronales ofrecen buenos resultados en los pronósticos de inflación (e.g., Rodríguez-Vargas 2020, Peirano et al. 2021, Paranhos 2025).

Considerando lo anterior, en este estudio se proponen pronósticos de inflación a corto y mediano plazo bajo tres esquemas. El primer esquema (denominado MIPP) usa información granular del Índice de Precios al Consumidor (IPC) de los 298 productos que componen el IPC general de Nicaragua (incluye bienes y servicios). El enfoque MIPP usa una variedad de modelos univariados incluyendo modelos autorregresivos (AR), modelos de media móvil (MA), modelos autorregresivos de media móvil (ARMA), modelos autorregresivos integrados de media móvil (ARIMA), así como modelos ARIMA extendidos con ajuste estacional (SARIMA). Los modelos se estiman con estructuras óptimas de rezagos, y con ello se pronostica la inflación de cada producto, lo cual luego se agrega a partir de las ponderaciones individuales de los productos en el IPC general.

El segundo enfoque incluye el uso de modelos de *machine learning* y redes neuronales. Específicamente, se consideran los modelos que en la literatura han demostrado mayor poder predictivo sobre la inflación, como regresiones LASSO (*Least Absolute Shrinkage and Selection Operator*) y *Ridge*, pero también redes (o modelos) LSTM (*Long Short-Term Memory*) y el algoritmo *Prophet*.

Mientras que el tercer enfoque se denomina ‘enfoque contrafactual’, porque se inspira en el método de control sintético de [Abadie & Gardeazabal \(2003\)](#), aunque sigue un esquema de ponderación diferente. En este, se usa la inflación externa y las expectativas inflacionarias en 38 países para modelar la inflación en Nicaragua. El algoritmo incluye ecuaciones semi-estructurales de Mínimos Cuadrados Ordinarios (MCO), pero también modelos Autorregresivos de Rezagos Distribuidos (ARDL), y modelos de Vectores Autorregresivos (VAR), entre otros. En todos los enfoques se usan estrategias de combinación de pronósticos.

Los resultados indican que el ‘enfoque contrafactual’ es el más preciso para pronosticar la inflación a corto y mediano plazo, pues minimiza el error global de pronóstico. En tanto, enfoque MIPP presenta un buen poder predictivo a muy corto plazo (i.e., 2 trimestres), mientras que el ajuste de la mayor parte de técnicas de *machine learning* y redes neuronales es elevado dentro de muestra, y los pronósticos fuera de muestra también son precisos.

Se observa que la mejor combinación de pronósticos dentro del ‘enfoque contrafactual’, es aproximadamente el doble más precisa que otras combinaciones del mismo enfoque, y supera también los resultados del enfoque MIPP. Por su parte, los modelos de *machine learning* informados con variables externas (como la inflación de Estados Unidos, precios de *commodities* y el deslizamiento cambiario) producen buenos resultados. No obstante, cuando estas técnicas avanzadas se limitan a un contexto univariado, suelen ser superadas por modelos tradicionales más simples.

El resto del documento está organizado de la siguiente forma: la sección [2](#) presenta la revisión de literatura. La sección [3](#) describe los aspectos metodológicos. Por su parte, los resultados son descritos en la sección [4](#), mientras que las conclusiones se presentan en la sección [5](#).

## 2. Revisión de literatura

El fenómeno inflacionario ha sido ampliamente estudiado en la literatura. Muchos de los trabajos se han concentrado en analizar los *drivers* de la inflación (Nguyen et al. 2017, Hmadouch 2025, Lim & Sek 2015, Kinlaw et al. 2023, Ha et al. 2024, entre otros), pero también en diseñar métodos que permitan tener mejores pronósticos de esta variable, dada su importancia en la toma de decisiones por parte de los Bancos Centrales. En este sentido, la literatura empírica es numerosa (Stock & Watson 1999, Forni et al. 2003, Stock & Watson 2006, Wright 2009, Koop & Korobilis 2012, Gupta & Hartley 2013, Aparicio & Bertolotto 2020, Özgür & Akkoç 2022, entre otros).

La evidencia empírica sobre los pronósticos de inflación es diversa. Los estudios han seguido distintos enfoques para tratar de mejorar los resultados en términos de precisión y oportunidad, pero tratando de mantener la simplicidad. El consenso de la literatura de pronósticos sugiere que las combinaciones de pronósticos individuales ofrecen—a menudo—mejores resultados.

D’Amato et al. (2008) usan una combinación de pronósticos de modelos univariados (i.e., ARMA) pero también multivariados (i.e., VAR y semi-estructurales), con los cuales demuestran que los pronósticos individuales suelen ser menos precisos que las combinaciones lineales de esos modelos individuales, lo cual es coherente con lo que recomiendan Engle et al. (1984), Newbold & Harvey (2002), Fang (2003) y Timmermann (2006).<sup>1</sup>

Fulton & Hubrich (2021) explora la combinación de pronósticos a partir de distintos modelos tradicionales (i.e., AR, VAR y Curva de Phillips), encontrando resultados similares a los descritos en D’Amato et al. (2008) y Kascha & Ravazzolo (2010). En particular, la combinación de pronósticos de inflación le permite compensar el desempeño de modelos con ‘malos’ resultados, dado que aunque esos modelos no presentan las mejores señales, recogen información que a nivel agregado puede ser importante (ibid). Conclusiones similares se derivan de los trabajos de Eklund & Karlsson (2007), Ögünç et al. (2013) y De-Castro & Aiube (2023).

Bjørnland et al. (2012) también demuestran que la combinación de

---

<sup>1</sup>Castillo & Ortiz (2018) concluyen también que existe una ganancia de precisión con el uso de métodos de combinación.

pronósticos es precisa, particularmente cuando se consideran pronósticos puntuales de la inflación (véase también [Hubrich & Skudelny 2017](#)). Si bien las combinaciones de pronósticos no garantizan siempre el mejor resultado al compararse con el mejor modelo individual, las combinaciones suelen ser más precisas y asintóticamente proveen un ‘seguro’ ante la selección de modelos inapropiados ([Kascha & Ravazzolo 2010](#), p.231).

Otro de los consensos de la literatura es que más información mejora los pronósticos (véase [Ögünç et al. 2013](#), p.312). Por ello, algunos estudios como el de [Stock & Watson \(1999\)](#), [Stock & Watson \(2003\)](#), [Forni et al. \(2003\)](#), [Stock & Watson \(2006\)](#), [Gupta & Hartley \(2013\)](#), [Adebiyi et al. \(2022\)](#), [Botha et al. \(2023\)](#), entre otros, usan múltiples series de tiempo para pronosticar la inflación.

Por ejemplo, [Ögünç et al. \(2013\)](#) demuestran que los pronósticos de modelos multivariados son alrededor de 30 por ciento más acertados que los derivados de modelos *benchmark* univariados. El mismo resultado se deriva de [Stock & Watson \(1999\)](#), [Forni et al. \(2003\)](#) y [Gupta & Hartley \(2013\)](#), en donde se observa que las variables financieras y los precios de activos juegan un rol importante para predecir la inflación, particularmente, en el mediano plazo ([Gupta & Hartley 2013](#), p.239).

Métodos más avanzados para pronósticos incluyen el uso de *machine learning*, en donde la literatura es creciente (véase [Ülke et al. 2018](#), [Medeiros et al. 2021](#), [Aliaj et al. 2023](#), [Özgür & Akkoç 2022](#), [Naghi et al. 2024](#), [Stoneman & Duca 2024](#), [Bolívar 2025](#)). Estos métodos ofrecen buenos resultados en cuanto a la precisión de los pronósticos de inflación, debido a que suelen tener mejor capacidad de incluir más factores explicativos, lo cual naturalmente mejora la bondad de ajuste de los modelos.<sup>2</sup> Un método comúnmente utilizado es el de regresiones LASSO (o *shrinkage*). Este método permite mejorar el ajuste al penalizar a los modelos menos precisos, a la vez que se evita la sobre-parametrización (véase [Aliaj et al. 2023](#)).

Por su flexibilidad y capacidad de adaptarse a contextos con grandes volúmenes de información, el método LASSO tiende a ofrecer un mejor desempeño. [Özgür & Akkoç \(2022\)](#) llegan a esa conclusión al comparar regresiones LASSO con modelos tradicionales como ARIMA o VAR en Turquía. En este caso, se observa que las regresiones LASSO poseen un mejor ajuste a la inflación, dado que estas seleccionan (mediante un

---

<sup>2</sup>Por ejemplo, el estadístico  $R^2$  incrementa en la medida que se incluyen más regresores.

algoritmo) los regresores más importantes de manera dinámica, de modo que los pronósticos se optimizan en la medida que se incluye más información al sistema. Lo mismo encuentran [Liu et al. \(2024\)](#) para el caso de Japón.

En Estados Unidos, [Medeiros et al. \(2021\)](#) también usan métodos de *machine learning* para pronosticar la inflación, demostrando su potencial frente a modelos tradicionales. En particular, modelos LASSO y *Random Forest* ofrecen los mejores resultados en contextos de grandes volúmenes de datos. En particular, el modelo de *Random Forest* reduce significativamente el error de pronóstico debido a su habilidad de seleccionar variables relevantes, pero también por su capacidad de incorporar relaciones no lineales ([Medeiros et al. 2021](#), [Araujo & Gaglianone 2023](#)). [Stoneman & Duca \(2024\)](#) demuestran que los métodos de *machine learning* proporcionan pronósticos más precisos que los basados en encuestas a expertos, y estos también presentan un desempeño notable en contextos de crisis, como el experimentado durante la pandemia de COVID-19.

Dentro del instrumental de *machine learning*, se desprenden los modelos de redes neuronales y sus variantes más complejas. No obstante, no siempre los métodos ‘menos elementales’ suelen ofrecer mejores resultados, y en este sentido, la literatura ofrece resultados mixtos. Por ejemplo, [Moshiri et al. \(1999\)](#) estima una serie de modelos de redes neuronales híbridas y dinámicas, y lo que se observa es que el poder predictivo de esos modelos es igual o inferior al que ofrecen modelos *benchmark* del tipo VAR ([Moshiri et al. 1999](#), p.230). Por su parte, [McAdam & McNelis \(2005\)](#) demuestran que los métodos de redes neuronales combinados y bajo un esquema de curva de Phillips para la modelación de la inflación, superan a los modelos lineales y tradicionales en economías industrializadas.

[Choudhary & Haider \(2012\)](#) evalúan el poder predictivo de redes neuronales para generar pronósticos de inflación en 28 países de la Organización para la Cooperación y el Desarrollo Económicos (OCDE), y evidenciaron que en el 45 por ciento de los casos, los modelos de redes neuronales superaron el desempeño de modelos AR, mientras que estos últimos se desempeñaron mejor en el 21 por ciento de los casos. Ello refleja la importancia de los modelos univariados, pues a pesar de su simpleza pueden ofrecer bondades importantes cuando se trata de pronósticos, particularmente, a (muy) corto plazo (véase [Nason & Palasciano 2025](#)). Sin embargo, en el estudio de [Oyewale et al. \(2019\)](#) se observa que los métodos de redes neuronales superan a modelos ARIMA, aunque solamente se evalúa un horizonte de

proyección.

A pesar de lo anterior, Šestanović & Arnerić (2021) demuestran que los modelos de redes neuronales ofrecen mejores resultados—en cuanto a precisión—en el mediano plazo (e.g., en horizonte de 2 años). Esto se debe en parte a que los modelos *benchmark* como AR o ARMA, suelen converger a su media incondicional, de modo que luego de cierto tiempo, la dinámica previa de la variable provee menor poder explicativo en la varianza actual de dicha serie.

Rodríguez-Vargas (2020) evalúa el potencial del modelo o red LSTM, y encuentra que este método es el más preciso para proyectar la inflación en Costa Rica. No obstante, otros modelos como *Random Forest*, también resultan ser potentes para identificar la tendencia y dirección de la inflación, particularmente, en horizontes más largos (Rodríguez-Vargas 2020, p.8).

En Estados Unidos, Paranhos (2025) utiliza también modelos LSTM, y al igual que Rodríguez-Vargas (2020), encuentra que estos modelos superan a modelos más sofisticados de redes neuronales al pronosticar la inflación. Almosova & Andresen (2023) y Peirano et al. (2021) llegan a la misma conclusión, y sus resultados mejoran al combinar el modelo LSTM con modelos tradicionales (e.g., SARIMA). Así, los pronósticos macroeconómicos pueden mejorar con el uso de *machine learning* y *deep learning*, dada su capacidad de modelar relaciones no lineales y no estacionarias (Theoharidis et al. 2023).

Menculini et al. (2021) comparan el poder del modelo *Prophet*, así como modelos LSTM, contrastado con el desempeño de modelos ARIMA en un contexto de datos semanales. Su conclusión es que los modelos LSTM y los modelos ARIMA reflejaron un desempeño similar para pronosticar la inflación mayorista de alimentos en Italia. Por su parte, aunque el modelo que usa el algoritmo *Prophet* es más sencillo de implementar, su precisión fue menor que los otros esquemas usados para el contraste (véase Menculini et al. 2021, p.644).

Una posible explicación detrás del menor desempeño de modelos como el *Prophet*, es que a menudo estos se limitan a una variable, y también proporcionan resultados más acertados en la medida que las series presentan mayor volatilidad y regularidad en el tiempo, de modo que las series con mayor frecuencia (e.g., semanal o diaria) son un mejor objetivo a analizar

con este tipo de herramientas. Como menciona [Menculini et al. \(2021\)](#), algoritmos como *Prophet* han sido usados para pronósticos de series de alta volatilidad como precios de acciones o criptomonedas, ofreciendo resultados positivos, no obstante, en series con alta persistencia (como la inflación) este tipo de métodos presentan más limitaciones.

Como demuestran [Ang et al. \(2007\)](#), [Ghysels & Wright \(2009\)](#), [Altug & Çakmaklı \(2016\)](#) y [Araujo & Gaglianone \(2023\)](#), las expectativas inflacionarias son una herramienta potente a la hora de pronosticar o mejorar los pronósticos de inflación. En muchos estudios se consideran las encuestas de expectativas a especialistas como una *proxy* confiable de la inflación esperada ([Oinonen & Paloviita 2017](#), p.139). Lo interesante de usar encuestas de expectativas inflacionarias es que, en ciertos contextos, los pronósticos obtenidos a partir de dichas encuestas, son iguales o más precisos que los derivados de métodos tradicionales de pronósticos ([Thomas & Grant 2000](#)).

Por ejemplo, en [Araujo & Gaglianone \(2023, p.15\)](#) se presenta la evaluación y comparativa del desempeño de 50 modelos (i.e., *machine learning* y modelos tradicionales) y métodos de combinación de pronósticos para Brasil, donde se observa que la encuesta de expectativas de inflación de Brasil presenta el desempeño más notable en cuanto a la precisión a corto y mediano plazo (entre 1 y 18 meses), superando a la mayoría de modelos tradicionales y de *machine learning*, los cuales suelen ofrecer mejores resultados a medida que el horizonte de tiempo es mayor.

[Ang et al. \(2007\)](#) también contrasta el poder predictivo de encuestas de expectativas con modelos tradicionales en Estados Unidos, donde encuentran que las encuestas sistemáticamente superan a métodos tradicionales (i.e., modelos ARMA y curva de Phillips), y la combinación de pronósticos no genera mejoras, dado que los mayores pesos se asignan a los pronósticos de las encuestas ([Ang et al. 2007](#), p.1163). [Faust & Wright \(2013, p.2\)](#) y [Croushore \(2010\)](#) llegan a una conclusión similar. Los resultados de [Ang et al. \(2007\)](#), [Faust & Wright \(2013\)](#) y [Araujo & Gaglianone \(2023\)](#) son coherentes con lo descrito previamente, donde a menudo se observa que las técnicas más complejas no necesariamente son garantía de resultados más precisos.



### 3. Aspectos metodológicos

#### 3.1. Datos

En este estudio se usan datos mensuales y trimestrales de la inflación de Nicaragua, los cuales provienen del Banco Central, así como de la Secretaría del Consejo Monetario Centroamericano (SECMCA). También se usan datos trimestrales de la inflación y las expectativas inflacionarias de 38 países a nivel internacional provenientes de la Organización para la Cooperación y el Desarrollo Económicos (OCDE). Los datos trimestrales incluyen también información de la tasa de deslizamiento cambiario, así como una variable indicativa estacional, como parte de los fundamentos de la inflación a mediano plazo.

La inflación trimestral se contempla desde el primer trimestre del 2000, hasta el último trimestre de 2024. Pero también se incorpora información sobre las expectativas inflacionarias de las 38 economías, las cuales se extienden hasta el último trimestre de 2025.<sup>3</sup> Entre estos países se encuentran los principales socios comerciales de Nicaragua, como Estados Unidos, China, México, países de Centroamérica, así como países de la Unión Europea.

Según señala la OCDE, las expectativas de inflación se estiman en función del clima económico particular de cada país y la coyuntura internacional, para lo cual se usan modelos técnicos de estimación, pero también el juicio de expertos, así como encuestas de expectativas. Esto último es importante, porque en la literatura se ha demostrado que las encuestas de expectativas de inflación tienen un poder predictivo que puede ser igual o superior al de modelos tradicionales (véase [Ang et al. 2007](#), [Altug & Çakmaklı 2016](#), [Araujo & Gaglianone 2023](#)).

Por su parte, los datos mensuales consideran la inflación pormenorizada de los 298 productos incluidos en el cálculo del IPC, correspondiente a las 12 divisiones.<sup>4</sup> Así, el pronóstico de la inflación surge a partir del pronóstico individual de cada producto, lo cual posteriormente se pondera en función de la contribución de dicho producto en el IPC general. Las estimaciones se hacen tanto en niveles del IPC, como en tasas de variación

---

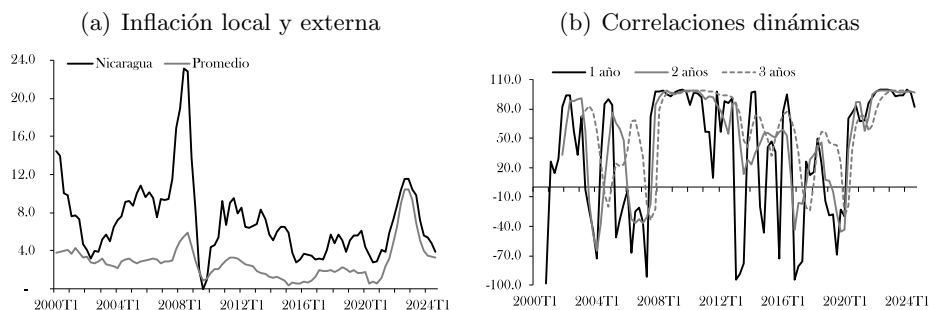
<sup>3</sup>La última actualización de la información considerada de la OCDE es a junio de 2024.

<sup>4</sup>1) Alimentos y bebidas no alcohólicas; 2) bebidas alcohólicas y tabaco; 3) prendas de vestir y calzado; 4) alojamiento, agua, electricidad, gas; 5) equipamiento y artículos para el hogar; 6) salud; 7) transporte; 8) telecomunicaciones; 9) recreación y cultura; 10) educación; 11) restaurantes y hoteles; 12) bienes y servicios diversos.

de ese índice, debido a las discrepancias que pueden derivarse al momento de ponderar el IPC general con la tasa de variación del IPC de cada producto.

La Figura 1 representa la inflación de Nicaragua y el promedio de inflación externa a partir de los datos de los 38 países. En esta figura se puede observar que la inflación doméstica ha mantenido en general una tendencia que sigue el comportamiento de la inflación externa, aunque con un mayor nivel, particularmente antes de 2009, cuando el traspaso aparente pudo haber sido no lineal o mayor a 1.

FIGURA 1: Inflación en Nicaragua e Inflación Externa



Nota:—La inflación promedio del panel (a) se estima usando la inflación de los 38 países de la OCDE. La correlación dinámica del panel (b) se calcula considerando ventanas móviles de 1, 2 y 3 años. Datos trimestrales desde el primer trimestre del 2000 al tercer trimestre de 2024.

Fuente: Elaboración propia.

En tanto, en los últimos años la inflación en Nicaragua manifiesta una tendencia similar a la inflación internacional, lo que puede sugerir que el incremento inflacionario observado entre 2021 y 2022, y el correspondiente proceso desinflacionario reciente, podrían estar vinculados mayormente con factores externos, lo que también podría ser consistente con lo observado en el panel (b), el cual representa la correlación dinámica entre las series en diferentes horizontes de tiempo (i.e., 1, 2 y 3 años), mismas que convergen hacia 100 por ciento (de correlación) en el periodo más reciente, superando la correlación histórica de 60 por ciento entre ambas variables.

### 3.1.1. Correlaciones y componentes principales

La Tabla 1 muestra las correlaciones de la tasa de inflación trimestral en Nicaragua, contrastado con los demás países. Se toman dos medidas de asociación: 1) la correlación simple entre la inflación de Nicaragua y la de

su contraparte, y 2) la correlación de la inflación de Nicaragua y la de los principales socios comerciales. Es importante destacar que, en prácticamente todos los casos, la correlación existente es distinta de cero considerando un nivel de confianza de 95 por ciento. Dentro de los principales socios comerciales, destacan Costa Rica, España, Estados Unidos y Corea del Sur, en los cuales la correlación de su inflación con la de Nicaragua supera el 50 por ciento. Si se considera solamente la correlación ‘pura’, algunos países del Este de Europa manifiestan la mayor correlación con la inflación nicaragüense.

TABLA 1: Matriz de Correlaciones de la Inflación

Por correlación <sup>†</sup>		Por socio comercial <sup>‡</sup>	
País	Coef. de correl.	País	Coef. de correl.
Letonia	73.13***	Estados Unidos	53.74***
Estonia	61.17***	China	48.92***
Suiza	61.02***	México	32.27***
Costa Rica	59.99***	Costa Rica	59.99***
Chile	56.76***	Japón	24.52**
Luxemburgo	56.71***	Alemania	40.71***
Lituania	55.61***	Corea del Sur	53.16***
España	54.29***	España	54.29***
Estados Unidos	53.74***	Colombia	35.31***
Corea del Sur	53.16***	Canadá	37.53***

Nota: –Datos en porcentaje. El socio comercial se determina según las importaciones de Nicaragua por origen en 2024. <sup>†</sup> orden según coeficiente de correlación. <sup>‡</sup> orden según participación en las importaciones totales de Nicaragua. \*\*\* significancia estadística al 1 por ciento. \*\* significancia estadística al 5 por ciento. \* significancia estadística al 10 por ciento. Datos de inflación desde el primer trimestre del 2000, al tercer trimestre de 2024. Coef. de correl: coeficiente de correlación. Fuente: Elaboración propia.

Si bien lo anterior no refleja causalidad, puede ser un indicador importante para inferir *a priori* una mejor precisión de los pronósticos, dado que como muestran Thomas & Grant (2000), Ang et al. (2007), Altug & Çakmaklı (2016) y Araujo & Gaglianone (2023), las expectativas de inflación son esenciales para obtener mejores pronósticos a corto y mediano plazo, y aunque no se cuenta con expectativas de inflación en Nicaragua, se internalizan las expectativas de los principales socios comerciales, de modo que eso puede permitir modelar de mejor forma la tendencia inflacionaria futura, pues a mediano plazo la inflación doméstica depende fundamentalmente de la inflación importada y la depreciación cambiaria, como menciona el Banco Central de Nicaragua (2024, p.119).

Dado que se cuenta con información relevante de la inflación de 38 países, pero los modelos tienen limitaciones de estimación por el consumo de grados de libertad que supone incluir toda la información, se estiman los componentes principales del *set* completo de información, los cuales explican la mayoría de varianza de los datos en un número reducido de series no correlacionadas entre sí.

Los resultados de la descomposición de los datos en sus componentes principales se presenta en la Tabla 2, la cual muestra que los 10 componentes principales de los datos de inflación explican aproximadamente el 94 por ciento de la variación de los datos generales. Esto sugiere que esos 10 componentes proporcionan información suficiente para contemplar la tendencia inflacionaria de prácticamente todos los países en una cantidad significativamente menor de series.

TABLA 2: Componentes Principales de la Inflación Externa

Componente	Valor	Diferencia	Proporción	Prop. Acum.
			porcentaje	
1	24.81	22.06	65.28	65.28
2	2.75	0.57	7.24	72.52
3	2.18	0.62	5.73	78.25
4	1.55	0.48	4.09	82.33
5	1.07	0.07	2.82	85.16
6	1.00	0.11	2.64	87.80
7	0.89	0.28	2.35	90.15
8	0.61	0.16	1.61	91.75
9	0.45	0.07	1.19	92.95
10	0.38	0.05	1.00	93.95


Nota:—Los componentes principales se estiman usando la inflación de los 38 países de la OCDE. Datos trimestrales desde el primer trimestre del 2000 al cuarto trimestre de 2025. Prop. Acum: proporción acumulada.

Fuente: Elaboración propia.

La Figura 2 representa gráficamente los primeros 4 componentes principales estimados a partir de los datos de inflación, en los cuales se refleja una tendencia desinflacionaria global recogida por el primer componente, que es el que explica la mayor porción de la varianza global de los datos (más de 65 por ciento). Esto se alinea con lo que muestra la Figura 1, que refleja una tendencia general desinflacionaria de las economías. El primer componente proporciona más peso a la evolución reciente de la inflación externa, dado que

entre 2021 y 2022 la misma superó su media incondicional. Sin embargo, los demás componentes ponderan más el episodio inflacionario de 2008–2009 con ciertas variantes, pues eso garantiza que todos los componentes no compartan ninguna correlación.

FIGURA 2: Componentes Principales



Nota:—Los componentes principales se estiman usando la inflación de los 38 países. Datos trimestrales desde el primer trimestre del 2000 al cuarto trimestre de 2025.

Fuente: Elaboración propia.

## 3.2. Modelos

En esta sección se muestran los principales modelos usados en los ejercicios de pronósticos. En primer lugar se describe la variedad de modelos univariados usados en las estimaciones mediante el enfoque MIPP. Luego se presentan los modelos de *machine learning* (i.e., regresiones LASSO y Ridge) y redes neuronales utilizados, y finalmente se detalla el ‘enfoque contrafactual’.

### 3.2.1. Enfoque MIPP: modelos univariados

Para la estimación de los pronósticos de inflación mediante el enfoque MIPP, se usa la información de los 298 productos del IPC de Nicaragua en niveles, pero también en su tasa de variación interanual. Así, para el índice de precios (o variación) de cada producto  $i$  en el periodo  $t$  se define una ecuación de estimación mediante modelos AR, MA, ARMA, ARIMA y SARIMA. La estructura de rezagos de los modelos se determina de forma algorítmica, minimizando el criterio de información Criterio de Información de Akaike (AIC por sus siglas en inglés) de Akaike (1974).<sup>5</sup>

<sup>5</sup>El criterio AIC se define como:  $AIC = 2k - 2\ln(\mathcal{L})$ , donde  $\mathcal{L}$  representa el valor de la función de máxima verosimilitud, y  $k$  es el número de coeficientes del modelo.

### ■ Modelos AR, MA y ARMA

El modelo AR se define en la ecuación (1). En esa ecuación,  $\alpha$  representa el intercepto del modelo y  $\beta$  refleja la memoria del proceso de  $y_t^i$ . Mientras que  $p$  refleja el rezago óptimo correspondiente a cada serie  $i$ . En tanto,  $\epsilon_t^i \sim \mathcal{N}(0, \sigma_\epsilon^2)$  indica el error del modelo de la serie correspondiente, el cual presenta características de ruido blanco. De ese modo, cada índice de precios posee un modelo  $AR(p)$  que se ajusta de la mejor manera posible.

$$y_t^i = \alpha^i + \sum_{m=1}^p \beta^i y_{t-m}^i + \epsilon_t^i \quad \forall i = 1, 2, \dots, 298 \quad \forall t = 1, 2, \dots, T \quad (1)$$

Por su parte, la representación  $MA(q)$  se muestra en la ecuación (2), donde  $q$  representa el número óptimo de rezagos de los términos de error de cada serie  $\epsilon_t^i$ , el cual también se determina en función de la minimización del criterio AIC.

$$y_t^i = \mu^i + \sum_{n=0}^q \omega^i \epsilon_{t-n}^i \quad \forall i = 1, 2, \dots, 298 \quad \forall t = 1, 2, \dots, T \quad (2)$$

El modelo  $ARMA$  con parámetros  $p$  y  $q$  se presenta en la ecuación (3). En este modelo,  $\mathbf{L}^m$  y  $\mathbf{L}^n$  representan los operadores de rezagos del componente auto-regresivo y de media móvil, respectivamente.<sup>6</sup>

$$\left(1 - \sum_{m=1}^p \beta^i \mathbf{L}^m\right) y_t^i = \gamma^i + \left(1 + \sum_{n=0}^q \omega^i \mathbf{L}^n\right) \epsilon_t^i \quad \forall i = 1, \dots, 298 \quad \forall t = 1, \dots, T \quad (3)$$

### ■ Modelos ARIMA y SARIMA

A diferencia de los modelos anteriores, el modelo  $ARIMA(p, d, q)$  incluye la posibilidad de superar los inconvenientes de las raíces unitarias a través de  $(1 - \mathbf{L})^d$ , donde el parámetro  $d$  define el número de veces que la serie  $y_t^i$  tiene que ser diferenciada para que la misma sea estacionaria. Al igual que en los casos anteriores,  $\mathbf{L}$  representa el operador de rezagos.

$$\left(1 - \sum_{m=1}^p \beta^i \mathbf{L}^m\right) (1 - \mathbf{L})^d y_t^i = \gamma^i + \left(1 + \sum_{n=0}^q \omega^i \mathbf{L}^n\right) \epsilon_t^i \quad \forall i = 1, \dots, 298 \quad \forall t = 1, \dots, T \quad (4)$$

La ecuación (5) muestra la representación del modelo SARIMA con parámetros  $p, d, q$  y  $P, D, Q$ , los cuales representan los mismos elementos

<sup>6</sup>Los valores de  $p$  y  $q$  pueden o no ser iguales.

del modelo ARIMA presentado anteriormente, pero se divide el modelo en sus componentes estacionales y no estacionales. La ventaja de este método es que puede ajustarse mejor a patrones regulares de las series de tiempo, lo cual suele observarse en indicadores como la inflación. En este caso, los parámetros  $\theta^i$  y  $\Omega^i$  recogen la contribución relativa del componente estacional de la serie  $y_t^i$ , el cual permite pronosticar de mejor manera la regularidad de dicha serie.

$$\left(1 - \sum_{m=1}^P \theta^i \mathbf{L}^{ms}\right) \left(1 - \sum_{m=1}^p \beta^i \mathbf{L}^m\right) (1 - \mathbf{L}^s)^D (1 - \mathbf{L})^d y_t^i = \gamma^i + \left(1 + \sum_{n=0}^Q \Omega^i \mathbf{L}^{ns}\right) \left(1 + \sum_{n=0}^q \omega^i \mathbf{L}^n\right) \epsilon_t^i \quad (5)$$

La tasa de inflación general pronosticada por cada método se calcula en función de la contribución individual del índice de precios de cada producto. Es decir, se multiplica el pronóstico individual ( $\hat{y}_{t+h}^i$ ) por la ponderación de dicho producto en el IPC ( $\mathcal{W}^i$ ), lo que implica que  $\hat{y}_{t+h} = \sum_{i=1}^p \mathcal{W}^i \hat{y}_{t+h}^i$ .

Una vez que se tiene el pronóstico general de la inflación mediante todos los métodos, se unifican los pronósticos con base en la precisión de los mismos, pero también asignando un peso  $\pi_m$  proporcional a cada modelo ( $\mathcal{W}_m = \frac{1}{M}$ ), donde  $M$  es el número de modelos, lo cual permite generar ganancias de pronósticos, al comparar los resultados con los pronósticos individuales. Este método de combinación, también se usa bajo los otros enfoques. Así, el pronóstico agregado promedio o ponderado de inflación  $h$  pasos hacia adelante surge como  $\tilde{y}_{t+h} = \frac{1}{M} \sum_{j=1}^M \hat{y}_{t+h}^j$ .

### 3.2.2. Enfoque de *machine learning* y redes neuronales

En este enfoque se usan 4 modelos esencialmente. Regresiones LASSO y *Ridge* propuestos por Tibshirani (1996) y Hoerl & Kennard (1970), respectivamente. También se usa el modelo LSTM introducido en Hochreiter & Schmidhuber (1997) y el algoritmo *Prophet*, recientemente desarrollado por Taylor & Letham (2018). Esto, considerando que en la literatura son los métodos que han ofrecido los mejores resultados en cuanto a su precisión y consistencia en los pronósticos fuera de muestra de la inflación.

#### ■ Regresión LASSO y *Ridge*

La regresión LASSO es una generación del método tradicional de mínimos cuadrados ordinarios (MCO), pero con una función de penalización del coeficiente  $\beta_j$  asociado a cada regresor  $j$ , pudiendo reducir a cero el valor

de  $\beta_j$  en dependencia de la varianza explicada por la variable asociada con dicho coeficiente. Por ello, la regresión LASSO es también conocida como un método de *shrinkage*, y sigue un esquema similar a las *stepwise regressions*, que eliminan variables redundantes o irrelevantes.

En particular, la regresión LASSO minimiza el error cuadrático de predicción, penalizando los parámetros  $\beta_j$  como muestra la ecuación (6).

$$\left\{ \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} \dots - \beta_p x_{ip})^2 + \lambda (|\beta_1| + |\beta_2| + \dots + |\beta_p|) \right\} \quad (6)$$

En este caso,  $\lambda$  representa el parámetro de regularización siendo  $\lambda > 0$ . Se debe notar que cuando  $\lambda = 0$  se regresa al esquema habitual de MCO, dado que en ese caso la minimización ocurre sólo en términos del error de predicción al cuadrado. Así, el  $\hat{\beta}^{lasso}$  se determina como:

$$\hat{\beta}^{lasso} = \arg \min_{\beta} \left\{ \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (7)$$

A pesar de que la regresión LASSO no tiene una forma cerrada del  $\hat{\beta}^{lasso}$  (como en el caso del modelo MCO<sup>7</sup>), dicho estimador se obtiene mediante algoritmos de optimización, como el propuesto en Tibshirani (1996, p.278).

La regresión *Ridge* es en esencia el precursor de la regresión LASSO, y sigue un planteamiento similar, dado que también minimiza el error de pronóstico al cuadrado, incluyendo de igual forma el coeficiente  $\lambda$  de regularización, aunque en este caso los parámetros  $\beta_j$  son tratados de forma distinta. La regresión *Ridge* se resume en la ecuación (8).

$$\left\{ \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} \dots - \beta_p x_{ip})^2 + \lambda (\beta_1^2 + \beta_2^2 + \dots + \beta_p^2) \right\} \quad (8)$$

Aunque el planteamiento es similar al de la regresión LASSO, la función objetivo a minimizar por parte de la regresión *Ridge* permite tener una forma cerrada de su estimador. En particular, la regresión minimiza la función (9) escogiendo valores óptimos para  $\beta_j$  y  $\lambda$ .

<sup>7</sup>El estimador de MCO es:  $\hat{\beta}^{MCO} = (X'X)^{-1}X'y$ , donde  $X'$  representa la matriz  $X$  transpuesta.



$$\hat{\beta}^{\text{ridge}} = \arg \min_{\beta} \left\{ \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\} \quad (9)$$

Al igual que el caso anterior, si  $\lambda = 0$  se está en presencia de una regresión tradicional de MCO, pero en este caso, con  $\lambda > 0$ , es relativamente sencillo demostrar que el estimador  $\hat{\beta}^{\text{ridge}} = (X'X + I\lambda)^{-1}X'y$ , lo cual es una extensión del estimador de MCO cuando  $\lambda = 0$ . Aquí,  $I$  representa la matriz identidad de orden  $p \times p$ .

Tanto en el caso de la regresión LASSO como *Ridge*, el parámetro  $\lambda$  puede tomar valores superiores a cero sin cota superior. No obstante, es importante notar que en la medida que  $\lambda$  incrementa, el valor de los coeficientes  $\beta_j$  tiende a cero, y en el caso de regresiones LASSO pueden ser iguales a cero en el extremo, pero en el modelo *Ridge* esto no ocurre. Debido al *trade-off* de sesgo y varianza, en la medida que  $\lambda$  incrementa, el sesgo también aumenta, pero se reduce la varianza. Por ello, el valor de  $\lambda$  se determina endógenamente a partir de algoritmos de aproximación.

### ■ Modelo LSTM y *Prophet*

De acuerdo con [Hochreiter & Schmidhuber \(1997\)](#), una red (o modelo) LSTM procesa una secuencia temporal  $\{y_t\}_{t=1}^T$  manteniendo un estado oculto ( $h_t$ ) y una celda de memoria ( $c_t$ ) que permiten modelar y retener relaciones de largo plazo. La celda de memoria de la red LSTM es lo que permite modelar relaciones de corto y largo plazo, pero también hacer pronósticos, y su dinámica está determinada por tres fases que interactúan con tres estados:

$$f_t = \sigma(W_f y_t + U_f h_{t-1} + b_f) \quad \text{fase de olvido} \quad (10)$$

$$i_t = \sigma(W_i y_t + U_i h_{t-1} + b_i) \quad \text{fase de entrada} \quad (11)$$

$$o_t = \sigma(W_o y_t + U_o h_{t-1} + b_o) \quad \text{fase de salida} \quad (12)$$

$$\tilde{c}_t = \tanh(W_c y_t + U_c h_{t-1} + b_c) \quad \text{estado candidato} \quad (13)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad \text{estado de actualización (memoria)} \quad (14)$$

$$h_t = o_t \odot \tanh(c_t) \quad \text{estado oculto actualizado} \quad (15)$$

donde  $y_t$  es el vector de entrada en el tiempo  $t$ ;  $h_t \in \mathbb{R}^m$  es el estado oculto;  $c_t \in \mathbb{R}^m$  es el vector de memoria;  $W(\cdot)$  y  $U(\cdot)$  son matrices de pesos;  $b$  son vectores de sesgo;  $\sigma(\cdot)$  es la función sigmoide, mientras que  $\odot$  es el producto de Hadamard que denota la multiplicación elemento a elemento.

En la red LSTM, la fase de olvido  $f_t$  es la que decide la información poco relevante que debe descartarse. En tanto, la fase de entrada  $i_t$  y el estado candidato  $\tilde{c}_t$  determinan la nueva información que debe incorporarse y la que retener de las fases previas. Finalmente, la fase de salida  $o_t$  delimita la información que incidirá en los pronósticos a partir de la memoria de la red. Esto último permite recoger y modelar la memoria de la serie a pronosticar, pero también la potencial influencia de otros factores externos.

En general, el pronóstico del modelo LSTM sobre la serie temporal  $\hat{y}_{t+h}$  en el periodo  $t + h$ , se obtiene a partir del estado oculto de la ecuación (16), donde  $g(\cdot)$  es una capa densa lineal o no lineal.

$$\hat{y}_{t+h} = g(h_t), \quad (16)$$

El modelo *Prophet* es relativamente más sencillo que el LSTM, aunque también modela una secuencia temporal  $\{y_t\}_{t=1}^T$ , pero como un modelo aditivo, como proponen Taylor & Letham (2018). Este modelo tiene como componentes principales la tendencia y estacionalidad de la serie, de modo que los pronósticos que resultan son esencialmente las contribuciones de estos componentes sobre la varianza de  $y_t$ . Así,  $y_t$  se puede descomponer como:

$$y_t = \tau(t) + s(t) + l(t) + \epsilon_t, \quad (17)$$

donde  $\tau(t)$  representa la tendencia a largo plazo,  $s(t)$  son los componentes estacionales (semanales, mensuales, trimestrales, anuales), mientras que  $l(t)$  son los efectos de períodos festivos. Finalmente,  $\epsilon_t \sim \mathcal{N}(0, \sigma^2)$  es el término de error que es determinado por el componente irregular(aleatorio) y no sistemático de la serie.

Como describen Taylor & Letham (2018, p.39), con el modelo *Prophet* la tendencia se denota como una función lineal con puntos de cambio (*change-points*), como muestra la ecuación (18), en la que  $k$  es la pendiente inicial;  $m$  es el intercepto;  $\mathbf{a}(t)$  es un vector indicador que activa los cambios de pendiente en los *change-points*;  $\delta$  son los cambios de pendiente, mientras que  $\gamma$  son los ajustes de nivel para mantener continuidad.

$$\tau(t) = (k + \mathbf{a}(t)^\top \delta)t + (m + \mathbf{a}(t)^\top \gamma) \quad (18)$$

Por su parte, la estacionalidad del modelo *Prophet* descansa en el uso de la serie de Fourier, la cual permite aproximar la naturaleza periódica de los datos (Taylor & Letham 2018, p.40). Así, la aproximación de la

estacionalidad a partir de la aproximación de Fourier puede denotarse como la descrita en (19).

$$s(t) = \sum_{n=-N}^N c_n e^{i \frac{2\pi n t}{P}} \quad (19)$$

donde  $N$  representa la complejidad de la estacionalidad que se modela y  $P$  indica la periodicidad de los datos. Por ejemplo, según este modelo  $P = 365,25$  refleja datos anuales, mientras que  $P = 7$  se puede usar para datos con estacionalidad semanal.

Según Taylor & Letham (2018), los parámetros que se deben estimar en el modelo son  $c_n, n = -N, \dots, N$ . En este caso, un  $N$  grande permite aproximar procesos de estacionalidad más complejos, pero se corre el riesgo de sobre-ajustar  $y_t$ . Para datos con estacionalidad anual y semanal, el modelo usa generalmente los parámetros  $N = 10$  y  $N = 3$ , respectivamente. De ese modo, se puede definir  $X(t)$  de la siguiente forma:

$$X(t) = \left( e^{i \frac{2\pi(-10)t}{365,25}}, \dots, e^{i \frac{2\pi(10)t}{365,25}} \right) \quad (20)$$

Entonces, el componente estacional  $s(t)$  se determina como el producto punto de  $X(t)$  con un vector de parámetros  $\mathcal{B} \sim \mathcal{N}(0, \sigma)$ . En el modelo generativo,  $s(t) = X(t)\mathcal{B}$  impone un suavizado previo sobre la estacionalidad (Taylor & Letham 2018).

### 3.2.3. ‘Enfoque contrafactual’

Este enfoque se denomina “enfoque contrafactual”, dado que se inspira en la idea general del método de control sintético propuesto por Abadie & Gardeazabal (2003), aunque no se usa directamente dicho método. No obstante, dado que la inflación en Nicaragua se modela con la inflación de otras economías, el resultado del pronóstico de la inflación (basado en la inflación) resulta en una forma de ‘contrafactual’, o una serie sintética de inflación para Nicaragua, aunque con un esquema iterativo y de asignación de pesos que difiere del planteamiento de Abadie & Gardeazabal (2003).

En este enfoque se utilizan datos de inflación y las expectativas inflacionarias de los 38 países de la OCDE, y se estiman modelos univariados y multivariados cuasi-estructurales. El enfoque consta de dos etapas. En una primera etapa se estiman los modelos considerando la información de

los principales socios comerciales, así como de los países cuya inflación manifiesta la mayor correlación con la inflación de Nicaragua. Mientras que la segunda etapa se complementa con un algoritmo que utiliza los componentes principales de la inflación y las expectativas inflacionarias de los 38 países.

En el algoritmo se trabaja con los 10 componentes principales y se realizan distintas simulaciones con diversas combinaciones de factores, rezagos y sub-muestras de los distintos modelos estimados, con el objetivo de evitar el posible sesgo de seleccionar un modelo en particular. La segunda fase del algoritmo sigue un esquema recursivo, en el cual se agregan los pronósticos al *set* de datos existente, a fin de pronosticar fuera de muestra.

En este proceso, se contempla la tendencia inflacionaria como un factor explicativo de la inflación observada, la cual se estima mediante la descomposición STL<sup>8</sup> de Cleveland et al. (1990). La particularidad de esto, es que la tendencia de la inflación general no se estima sobre la serie original, sino sobre la pronosticada, lo cual permite generar un proceso iterativo de pronósticos sin la limitación de la muestra de la inflación observada.

Una vez que se tienen todas las combinaciones de modelos, se realiza la agregación de los pronósticos de la inflación con base en la asignación del mismo peso  $w_j = \frac{1}{M}$  del modelo  $j$ , con  $\sum_{j=1}^J w_j = 1$  y  $w_j \geq 0$ . En este caso,  $M$  representa el total de modelos considerados en el análisis. También se utiliza la asignación de pesos para los modelos seleccionados en función de la mínima distancia con la inflación observada, usando el valor inverso de la raíz del error cuadrático medio (RMSE por sus siglas en inglés), descrito en la ecuación (21).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_t - \hat{y}_t)^2}{n}} \quad (21)$$

La estimación de la inflación se realiza con una serie de modelos univariados, multivariados y dinámicos, expresados en la “función transformadora”  $\mathcal{F}$ , la cual depende del vector de variables  $X'_t$ , que recoge, además de la inflación externa y las expectativas, la tasa de deslizamiento e indicadores estacionales y de tendencia. El conjunto de modelos contenidos en  $\mathcal{F}$  incluye regresiones de ecuaciones semi-estructurales mediante modelos ARDL, MCO y VAR. En total, se estiman más de 200 especificaciones de los distintos modelos.

---

<sup>8</sup> *Seasonal-Trend decomposition based on Loess.*

$$y_t = \mathcal{F}\{X_t'\beta\} + u_t \quad (22)$$

Con la información generada en la primera etapa por los modelos representados en (22), se estima la combinación del pronóstico inflacionario a  $h$  pasos hacia adelante ( $\hat{y}_{t+h}$ ), delimitado por la información disponible. Luego, se descompone  $\hat{y}_{t+h}$  en su factor regular y tendencial mediante el algoritmo STL, y se extrae la tendencia denotada por  $\bar{y}_{t+h}$ . Esta serie de tendencia se calcula a partir de ( $\hat{y}_{t+h}$ ) de modo que la disponibilidad de información hasta el periodo  $t$  no limita su estimación, y técnicamente no se usa la memoria de la inflación observada para definir dicha tendencia, aunque se estima de forma indirecta.

El componente  $\bar{y}_{t+h}$  es importante, dado que juega en la práctica el mismo rol de la memoria de un proceso AR, pero sin la limitación que impone dicha memoria a efectos de pronósticos a  $h$  pasos hacia adelante, ya que la distancia entre  $y_t$  y  $\hat{y}_{t+h}$  debe ser consistente con el orden del proceso AR modelado para obtener pronósticos fuera de muestra.

Finalmente, se pronostican los componentes principales usados para la estimación de la inflación en función de  $\hat{y}_{t+h}$ , lo que garantiza la dinámica endógena del pronóstico, continuando de esa forma el proceso de iteración y pronóstico. Cabe destacar que el pronóstico de un componente  $a$  no incluye retro-alimentación con otro componente  $b$ , porque los mismos no guardan correlación entre sí ( $Cov\{PC_a, PC_b\} = 0$ ).

Los parámetros principales del algoritmo se determinan por el número de componentes a incorporar en el pronóstico (hasta 10), así como por la cantidad de rezagos considerados para estimar los coeficientes de los modelos que luego se usan para pronosticar. Dado que las estimaciones se hacen incluyendo y excluyendo la tendencia inflacionaria, se balancean estos parámetros de modo que ambos pronósticos puedan alinearse en el mediano plazo, pero también garanticen estabilidad y consistencia a los resultados del algoritmo. En este esquema también se usan combinaciones de pronósticos.

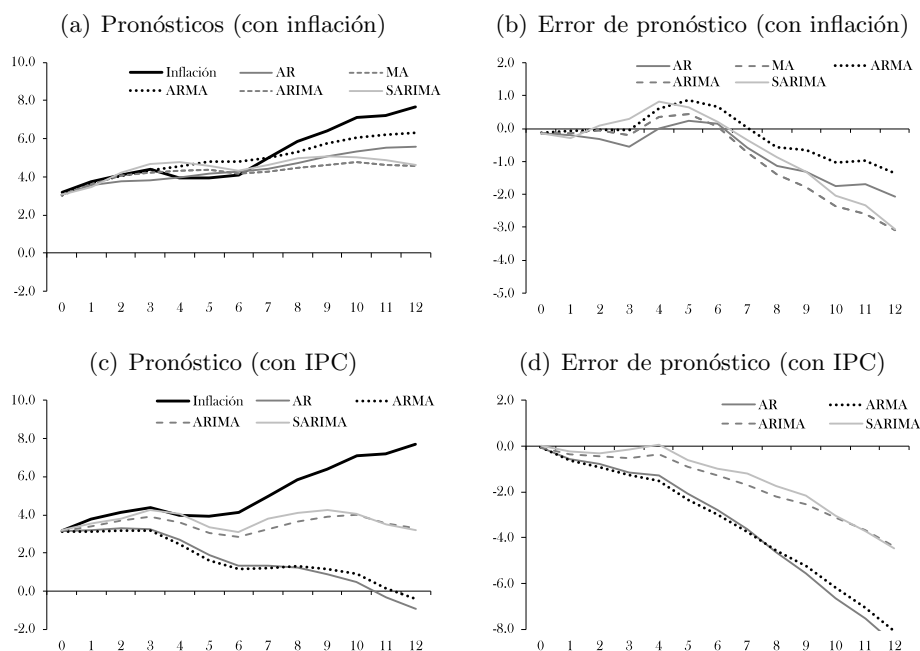
## 4. Resultados

### 4.1. Enfoque MIPP

La Figura 3 presenta los resultados de los pronósticos fuera de muestra de la inflación basados en el enfoque MIPP, en la cual se observa que, en general,

los modelos univariados tradicionales producen resultados aceptables. El ejercicio de pronósticos se lleva a cabo usando, tanto el índice de precios de cada uno de los 298 productos, como la tasa de inflación interanual individual. Esto porque al agregar el índice general, se logra consistencia usando el IPC por producto, pero para efectos de estabilidad de los modelos es adecuado usar la tasa de variación, misma que resulta ser estacionaria en la mayoría de los casos, siendo una característica deseable en contextos de modelos univariados.

FIGURA 3: Pronósticos Mensuales Fuera de Muestra con Enfoque MIPP



Nota:—El eje vertical representa porcentaje en la primera columna, y puntos porcentuales en el error de pronóstico, y el eje horizontal refleja periodos. El periodo fuera de muestra es 2021M1-2022M1. En los paneles (a) y (b) se usa y pronostica la tasa de inflación de cada producto  $i$ , y en los paneles (c) y (d) se utiliza el índice en niveles. Se usan datos mensuales de los 298 productos que componen el IPC de Nicaragua. Se excluye el modelo MA al pronosticar el IPC, dado que el mismo no converge. Datos mensuales.

Fuente: Elaboración propia.

Los resultados bajo este enfoque sugieren que, aunque los distintos modelos univariados manifiestan resultados similares, los modelos ARMA son los que mejor se ajustan a los datos de inflación por producto, minimizando el error de pronóstico en un horizonte de 12 meses, como muestra el panel (b)

de la Figura 3. No obstante, en la medida que el horizonte de pronóstico es mayor, la precisión de los modelos disminuye, manifestando diferencias de entre 1 y 3 puntos porcentuales entre la inflación proyectada y la observada.

Por su parte, al pronosticar los índices de precios individuales, se observa que todos los modelos presentan un menor grado de precisión, con diferencias significativas en cuanto al error de pronóstico que generan, comparado con dichos modelos al usar la tasa de inflación—en lugar del índice. En este caso, los modelos subestiman sistemáticamente la inflación observada después de 6 periodos (véase la Figura A1). No obstante, los modelos ARIMA y SARIMA proporcionan mejores resultados dado que los mismos diferencian las series de forma automática hasta lograr estacionariedad, garantizando así mayor estabilidad y consistencia en los pronósticos a corto plazo.

A pesar de la imprecisión de los modelos a ciertos horizontes, en general la mayoría demuestran un buen poder predictivo a (muy) corto plazo, lo que es natural en modelos univariados, dado que series como la inflación manifiestan cierta memoria que es modelada de buena forma con este tipo de estrategias. Esta es una regularidad que también se ha documentado en otros estudios, en los cuales modelos univariados como ARMA o ARIMA ‘compiten’ de buena manera, e incluso pueden superar el poder predictivo de modelos más avanzados de redes neuronales o *machine learning* (véase Moshiri et al. 1999, Choudhary & Haider 2012, Menculini et al. 2021).

## 4.2. *Machine learning* y redes neuronales

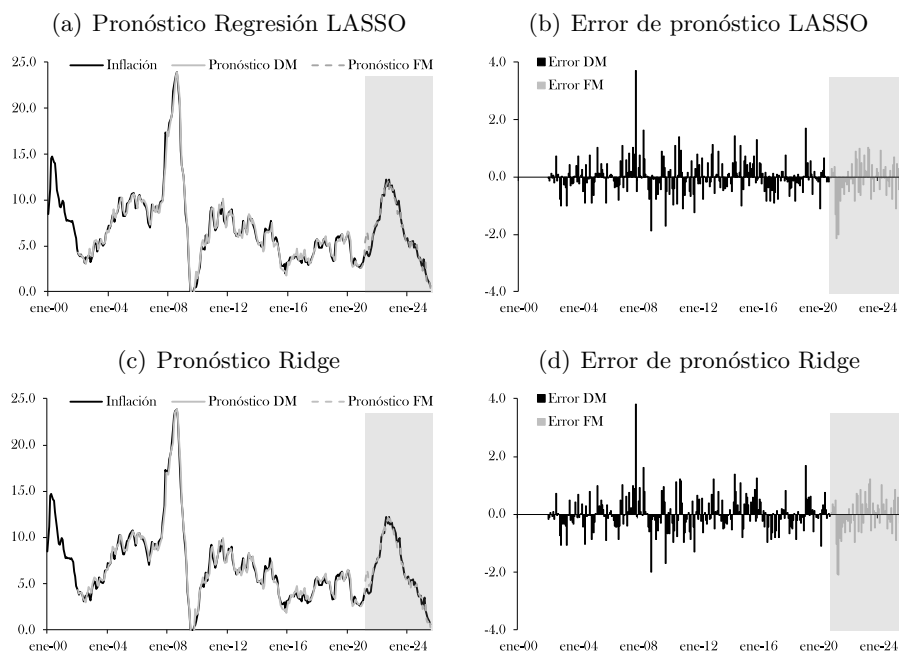
### 4.2.1. Regresión LASSO y *Ridge*

Los modelos LASSO y *Ridge* producen resultados cuantitativos similares en términos de los pronósticos de inflación (véase la Figura 4). Esos modelos se estiman incluyendo información externa, como la inflación de Estados Unidos y los precios de materias primas (petróleo y alimentos), así como el deslizamiento cambiario. En ambos casos, el ajuste dentro y fuera de muestra es adecuado para replicar los patrones de los datos en el periodo de entrenamiento y prueba. La precisión de los modelos LASSO y *Ridge* es significativamente superior a los modelos univariados, pues el RMSE de estas técnicas de *machine learning* es cercano a 0.6 dentro de muestra, mientras que fuera de muestra el RMSE es menor a 1 (Tabla A2).

Dado que estos modelos requieren una cantidad de datos importante para calibrarse, se usan datos mensuales en el periodo 2000-2025 y tanto el modelo

LASSO como *Ridge*, usan una proporción de 80 por ciento del total de datos para entrenamiento, y el resto de información se usa para la fase de prueba. Si bien estos modelos superan la precisión de modelos univariados (Tabla A2), en el contexto en el cual las regresiones LASSO y *Ridge* no cuentan con información externa adicional a la inflación de Nicaragua y sus rezagos, los modelos univariados tradicionales suelen reflejar un mejor desempeño.

FIGURA 4: Pronósticos de Inflación Regresión LASSO y *Ridge*



Nota:—Los modelos se calibran considerando 12 rezagos y usa el 80 por ciento de los datos para entrenamiento. El modelo *Ridge* usa un  $\lambda = 1$ . Modelo multivariado que incluye: la inflación de Estados Unidos, el precio del petróleo, precio de alimentos y el deslizamiento cambiario. El área sombreada refleja los pronósticos y errores fuera de muestra. El eje vertical en el panel (a) y (c) indica porcentaje, y en el panel (b) y (d) representa puntos porcentuales. DM: dentro de muestra. FM: fuera de muestra. Datos mensuales.

Fuente: Elaboración propia.

Algo que se debe destacar de los pronósticos generados por los modelos de *machine learning*, es que estos reflejan un error absoluto con características de ruido blanco, es decir, no presentan patrones sistemáticos de sobre-estimación o sub-estimación de la inflación, lo cual es una característica deseable en este contexto. Si bien los resultados pueden variar con los hiper-parámetros que se usan (e.g.,  $\lambda$  o el número de rezagos), en

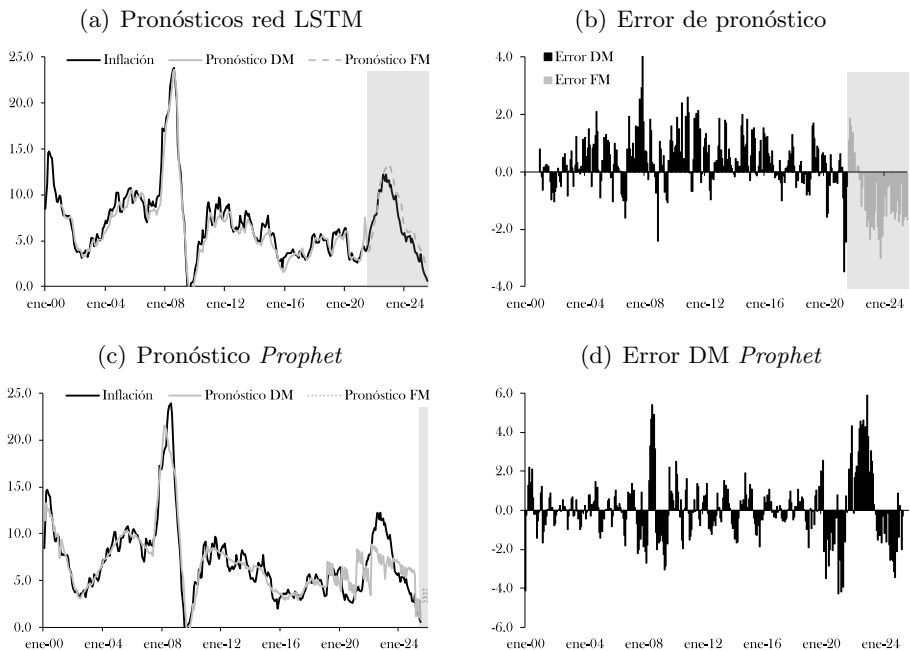


este caso se utilizan valores estándar para series temporales con frecuencia mensual, como muestra la Tabla A1. No obstante, la variación de los parámetros no genera mayores cambios en el ajuste de los modelos.

#### 4.2.2. LSTM y Prophet

Los pronósticos de la red (o modelo) LSTM se presentan en la Figura 5. A diferencia de los modelos univariados anteriores, esta red se construye considerando un esquema multivariado (como en las regresiones LASSO y Ridge), en el cual la inflación de Nicaragua se pronostica usando información de la inflación de Estados Unidos, los precios del petróleo, los precios de alimentos así como el deslizamiento cambiario.

FIGURA 5: Pronósticos de Inflación LSTM



Nota:—El modelo LSTM se calibra considerando 12 rezagos y usa el 80 por ciento de los datos para entrenamiento. Modelo multivariado que incluye: la inflación de Estados Unidos, el precio del petróleo, precio de alimentos y el deslizamiento cambiario. El área sombreada refleja los pronósticos y errores fuera de muestra. El eje vertical en el panel (a) y (c) indica porcentaje, y en el panel (b) y (d) representa puntos porcentuales. DM: dentro de muestra. FM: fuera de muestra. Datos mensuales.

Fuente: Elaboración propia.

En el panel (a) de la Figura 5 se observa que el ajuste de la red LSTM

dentro de muestra es importante, manifestando un seguimiento adecuado a la tendencia y el nivel de la inflación observada. En particular, el RMSE dentro de muestra es de 1.02 (1.51 fuera de muestra), lo cual resulta más bajo que el observado en modelos univariados, aunque mayor al que reflejan los modelos LASSO y *Ridge*. Una característica llamativa de los resultados del modelo LSTM, es que los pronósticos dentro de muestra reflejan una relativa sub-estimación de la inflación observada, mientras que en el periodo fuera de muestra se refleja una sobre-estimación sistemática de la inflación, lo que podría relacionarse con la calibración de la red, aunque se sigue una calibración estándar (Tabla A1).

La red LSTM se calibra también usando el 80 por ciento de los datos para entrenamiento (Tabla A1), y el restante para prueba, en una configuración de 12 rezagos debido a la frecuencia de los datos. Por su parte, otros hiper-parámetros utilizados por la red (e.g., cantidad de muestras para actualizar pesos de los pronósticos, o número de veces que la red recorre la muestra), se calibran de forma relativamente estándar para datos mensuales, pero los resultados son robustos ante variaciones de los mismos.

Por su parte, el modelo *Prophet* manifiesta un comportamiento más errático para modelar la inflación, a pesar de que todos los modelos multivariados se ‘informan’ de la misma manera. Dado que el ajuste dentro de muestra es débil, los pronósticos del modelo *Prophet* son los menos precisos contrastados con los resultados de los métodos de *machine learning* y redes. Esto puede estar relacionado con su relativa simplicidad, pero también con la calibración de los parámetros, pues entre todos los métodos, el modelo *Prophet* es el que manifiesta la mayor sensibilidad a cambios de sus hiper-parámetros. Así, este método es poco confiable para pronosticar la inflación.

### 4.3. ‘Enfoque contrafactual’

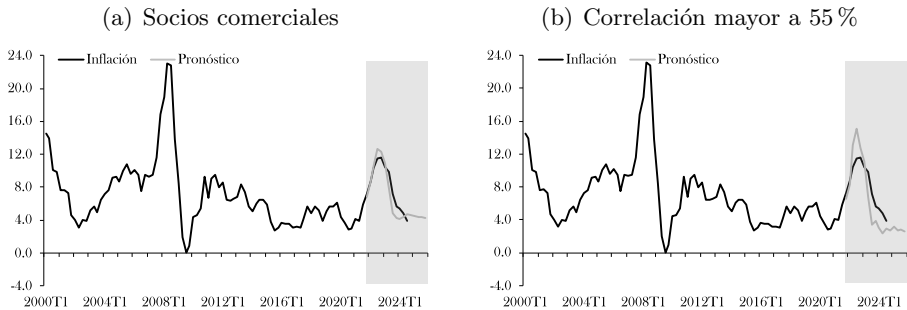
#### 4.3.1. Estimaciones según correlación

En la Figura 6 se muestran los resultados obtenidos al usar la inflación de los 5 principales socios comerciales de Nicaragua (según la correlación de la Tabla 1), así como los países que reflejan una alta correlación de su inflación con la inflación doméstica (superior a 55 por ciento). En estas estimaciones se incluye la inflación de la mayor parte de países presentados en la Tabla 1 que cumplen alguno de los dos criterios.

Al evaluar los resultados dentro de muestra bajo este enfoque, el RMSE

resultante es de 1.16 para el modelo que incluye la inflación de los socios comerciales, y de 2.27 para el segundo modelo (Tabla A2), lo que indica que la inflación de socios comerciales posee un mayor poder predictivo sobre la inflación doméstica, lo cual podría explicarse por el traspaso inflacionario que se puede dar a través de las importaciones. Los resultados sugieren que la tendencia desinflacionaria en Nicaragua continuará en 2025 (aunque se desacelerará), y considerando distintas simulaciones, se estima que al cierre del año la inflación se podría ubicar entre 2.5 y 4 por ciento, aproximadamente.

FIGURA 6: Pronósticos de Inflación Según Correlación



Nota:—Se incluye información de la inflación de Nicaragua hasta 2024T3. Los modelos contemplan información de la inflación local y externa y del deslizamiento cambiario. El panel (a) contempla información de los 5 principales socios comerciales. En el panel (b) se considera la mayor correlación entre la inflación de Nicaragua y los demás países presentados en la Tabla 1 que cumplen el criterio. El eje vertical representa porcentajes, y el eje horizontal indica trimestres. El área sombreada representa el periodo fuera de muestra. Estimaciones promedio en función de distintas simulaciones, sub-periodos y modelos. Datos trimestrales.

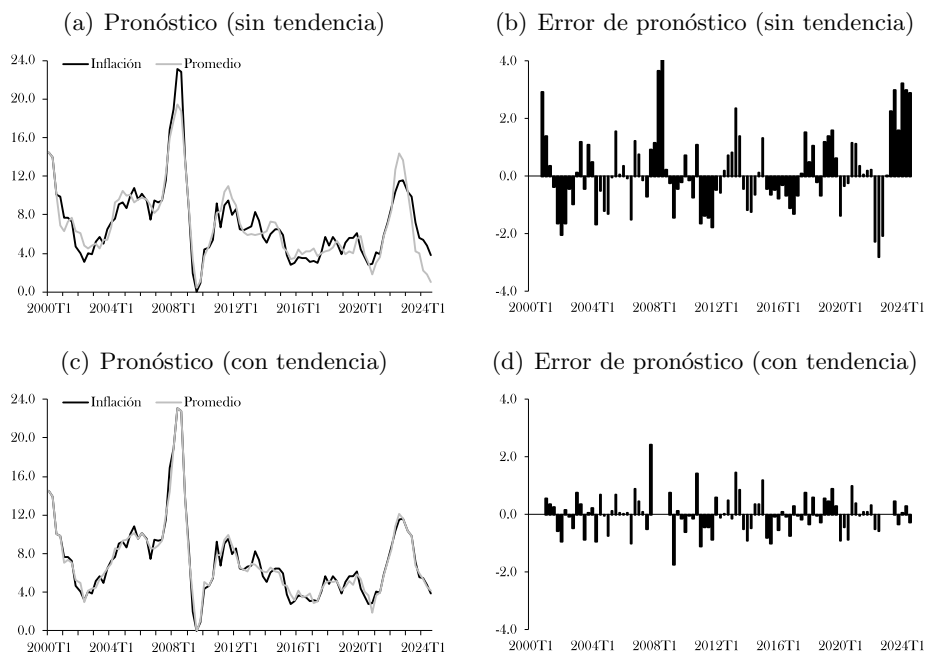
Fuente: Elaboración propia.

#### 4.3.2. Estimaciones con componentes principales

Los pronósticos de inflación usando componentes principales se muestran en las Figuras 7 y 8, en la cuales los resultados indican que la información de inflación externa y el deslizamiento cambiario son variables muy importantes para explicar la dinámica de la inflación en Nicaragua. La Figura 7 presenta las estimaciones dentro de muestra en el periodo 2000–2024, en el cual el RMSE se sitúa en 1.36, siendo similar al desempeño del mejor modelo descrito en la sección anterior. No obstante, los resultados mejoran sustancialmente cuando se modela la tendencia de la inflación en Nicaragua a partir de los pronósticos iniciales (usando la descomposición STL), siguiendo el proceso descrito en la sección 3.2.3.

Cuando se incluye la tendencia inflacionaria de Nicaragua, el error de pronóstico disminuye significativamente como se muestra en el panel (d) de la Figura 7, mismo que presenta una media incondicional de cero en todo el periodo, y tiene características de ruido blanco, es decir, no hay una sub-estimación o sobre-estimación sistemática de la inflación dentro de muestra. En el caso donde se controla la tendencia de la inflación el RMSE disminuye a 0.62 en el periodo 2000-2024, representando menos de la mitad del RMSE del modelo que no incorpora dicha tendencia. Con esto, la ganancia de precisión fuera de muestra es notable (véase la Tabla A2).

FIGURA 7: Pronósticos de Inflación Dentro de Muestra



Nota:—Se incluye información de la inflación de Nicaragua hasta 2024T3. Los modelos contemplan información de la inflación local y externa y del deslizamiento cambiario. El eje vertical del panel (a) y (c) refleja porcentaje, mientras que en los paneles (b) y (d) indica puntos porcentuales. El eje horizontal muestra trimestres. Estimaciones promedio en función de distintas simulaciones que incluyen hasta 10 componentes principales derivados de los 38 países, pero también sub-periodos en los que se eliminan hasta 4 años de información al final de la muestra para estimar los pronósticos fuera de muestra. Datos trimestrales.

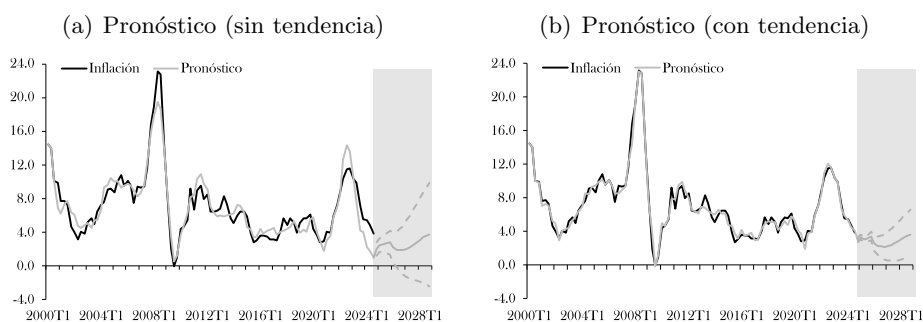
Fuente: Elaboración propia.

Con los modelos anteriores se generan los pronósticos fuera de muestra,

los cuales convergen en el mediano plazo independientemente de si se controla indirectamente (o no) por la tendencia inflacionaria. Esto se logra al calibrar los parámetros principales relativos al número de componentes y la memoria de esos procesos, lo que garantiza consistencia y estabilidad a los pronósticos generados por ambos enfoques, como describe la sección 3.2.3.

Así, los modelos indican que, en condiciones normales, al cierre de 2025 la inflación podría situarse aproximadamente entre 2.5 y 3.4 por ciento. Mientras que en 2026 se observa cierta estabilidad inflacionaria, la cual podría incrementar en 2027 y 2028 hasta 3.6 por ciento, aunque esto también se asocia con un grado de incertidumbre más alto debido a que el horizonte es lejano, considerando que la información que considera el modelo se extiende hasta 2024.

FIGURA 8: Pronósticos de Inflación Fuera de Muestra



Nota:—Se incluye información de la inflación de Nicaragua hasta 2024T3. Los modelos contemplan información de la inflación local y externa y del deslizamiento cambiario. El eje vertical representa porcentajes, y el eje horizontal indica trimestres. El área sombreada representa el periodo fuera de muestra, mientras que las líneas punteadas muestran un intervalo de confianza de 68 por ciento ( $\pm 1$  desviación estándar). Estimaciones promedio en función de distintas simulaciones que incluyen hasta 10 componentes derivados de los 38 países, pero también sub-periodos en los que se eliminan hasta 4 años de información al final de la muestra para estimar los pronósticos fuera de muestra. Datos trimestrales.

Fuente: Elaboración propia.

De ese modo, aunque la estimación puntual se sitúa por debajo de 4 por ciento, otros escenarios sugieren que la inflación podría ubicarse hasta en 5 o 6 por ciento. Si bien estas tasas son más altas que las actuales, indican que los modelos están internalizando la naturaleza de la inflación de converger a su media incondicional, la que podría reducirse (según las estimaciones), dado que se asume que el deslizamiento cambiario se mantendrá en cero por ciento en todo el periodo pronosticado, y el traspaso del deslizamiento a la inflación ha sido importante en años anteriores, por lo que la inflación

también podría tender a bajar en el futuro (bajo esas condiciones).

## 5. Conclusiones

Los pronósticos precisos de inflación, junto con las expectativas inflacionarias, son un complemento importante para el éxito del uso de instrumentos de política monetaria, los cuales buscan apuntar al cumplimiento de su objetivo principal de los Bancos Centrales: la estabilidad de precios. Así, el objetivo del estudio ha sido desarrollar un esquema sencillo y preciso de pronósticos de inflación a corto y mediano plazo, contrastando el poder predictivo de distintos métodos.

En el estudio se siguen tres enfoques principales. El primero genera pronósticos de la inflación a partir de datos desagregados de los 298 productos del IPC. El segundo enfoque incluye modelos de *machine learning* y redes neuronales, los cuales también han demostrado que tienen un poder predictivo importante cuando se contrastan con métodos tradicionales. Mientras que el tercer enfoque sigue un principio contrafactual de estimación de la inflación, e internaliza las expectativas de inflación externa. En todos los casos se usa la estrategia de combinación de pronósticos individuales, con el fin de generar ganancias de precisión.

El estimar diversos modelos permite hacer un contraste del poder predictivo de cada enfoque, considerando el error de pronóstico y otras métricas de precisión, como criterio principal de selección del enfoque más adecuado. Con ello, se demuestra que los modelos del enfoque MIPP, calibrados con estructuras óptimas de rezagos, ofrecen pronósticos precisos a (muy) corto plazo. En tanto, los métodos de redes neuronales y *machine learning* generan resultados acertados para los pronósticos dentro y fuera de muestra, considerando la correcta parametrización de los mismos y en un contexto multi-variado, donde se ‘informa’ al modelo con variables externas. Así, las regresiones LASSO y *Ridge*, y la red LSTM presentan un poder predictivo alto y similar dentro y fuera de muestra, superando a la mayoría de modelos univariados del enfoque MIPP.

Por otro lado, se demuestra que cuando se sigue el ‘enfoque contrafactual’ que internaliza las expectativas inflacionarias externas, se logran los mejores resultados en cuanto a precisión de los pronósticos generados a corto y mediano plazo. Lo importante de este enfoque (además de su precisión) es la simpleza comparada con otros métodos más avanzados que ofrecen

resultados relativamente más modestos en cuanto a precisión. Además, este método permite modelar de mejor manera los eventos atípicos de inflación en Nicaragua, los cuales a menudo son ocasionados por externalidades globales, como periodos de crisis o desalineamientos entre la oferta y demanda de insumos esenciales en los procesos productivos.

Si bien el ‘enfoque contrafactual’ ofrece buenos resultados al internalizar las expectativas de inflación externas, en futuros estudios se pueden también considerar las expectativas inflacionarias domésticas. A pesar de que en el país no se cuenta con esta información, la evidencia empírica demuestra que las encuestas a especialistas ofrecen aproximaciones razonables de las expectativas generales de los agentes, lo cual *per se* incluso puede superar el poder predictivo de modelos tradicionales (o avanzados), como demuestran diversos estudios en la literatura. Esto puede ser clave para complementar el instrumental utilizado en la toma de decisiones de política en el futuro.

## Referencias

- Abadie, A. & Gardeazabal, J. (2003), 'The economic costs of conflict: A case study of the basque country', *American Economic Review* **93**(1), 113–132.
- Adebiyi, M., Adenuga, A., Olusegun, T. & Mbutor, O. (2022), 'Big Data and Inflation Forecasting in Nigeria: a text mining application.', *Economic and Financial Review* **60**(1), 1–23.
- Akaike, H. (1974), 'A new look at the statistical model identification', *IEEE Transactions on Automatic Control* **19**(6), 716–723.
- Aliaj, T., Ciganovic, M. & Tancioni, M. (2023), 'Nowcasting inflation with lasso-regularized vector autoregressions and mixed frequency data', *Journal of Forecasting* **42**(3), 464–480.
- Almosova, A. & Andresen, N. (2023), 'Nonlinear inflation forecasting with recurrent neural networks', *Journal of Forecasting* **42**(2), 240–259.
- Altug, S. & Çakmaklı, C. (2016), 'Forecasting inflation using survey expectations and target inflation: Evidence for Brazil and Turkey', *International Journal of Forecasting* **32**(1), 138–153.
- Ang, A., Bekaert, G. & Wei, M. (2007), 'Do macro variables, asset markets, or surveys forecast inflation better?', *Journal of Monetary Economics* **54**(4), 1163–1212.
- Aparicio, D. & Bertolotto, M. I. (2020), 'Forecasting inflation with online prices', *International Journal of Forecasting* **36**(2), 232–247.
- Araujo, G. S. & Gaglianone, W. P. (2023), 'Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models', *Latin American Journal of Central Banking* **4**(2), 100087.
- Banco Central de Nicaragua (2024), Informe anual 2023, Managua, Banco Central de Nicaragua.
- Bjørnland, H. C., Gerdrup, K., Jore, A. S., Smith, C. & Thorsrud, L. A. (2012), 'Does forecast combination improve Norges Bank inflation forecasts?', *Oxford Bulletin of Economics and Statistics* **74**(2), 163–179.
- Bolivar, O. (2025), 'High-frequency inflation forecasting: A two-step machine learning methodology', *Latin American Journal of Central Banking* p. 100172.



- Botha, B., Burger, R., Kotzé, K., Rankin, N. & Steenkamp, D. (2023), 'Big data forecasting of South African inflation', *Empirical Economics* **65**(1), 149–188.
- Breitung, J. & Roling, C. (2015), 'Forecasting inflation rates using daily data: A nonparametric midas approach', *Journal of Forecasting* **34**(7), 588–603.
- Castillo, C. E. & Ortiz, E. (2018), 'Evaluación de combinaciones de inflación en Nicaragua (NICA): Un método eficiente para combinar pronósticos', *Revista de Economía y Finanzas* **5**(1), 1–34.
- Chen, Y.-c., Turnovsky, S. J. & Zivot, E. (2014), 'Forecasting inflation using commodity price aggregates', *Journal of Econometrics* **183**(1), 117–134.
- Choudhary, M. A. & Haider, A. (2012), 'Neural network models for inflation forecasting: an appraisal', *Applied Economics* **44**(20), 2631–2635.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., Terpenning, I. et al. (1990), 'Stl: A seasonal-trend decomposition', *Journal of Official Statistics* **6**(1), 3–73.
- Croushore, D. (2010), 'An evaluation of inflation forecasts from surveys using real-time data', *The BE Journal of Macroeconomics* **10**(1).
- D'Amato, L., Garegnani, L. & Blanco, E. (2008), Forecasting inflation in Argentina: Individual models or forecast pooling?, Technical report, Working Paper.
- De-Castro, C. H. D. C. & Aiube, F. A. L. (2023), 'Forecasting inflation time series using score-driven dynamic models and combination methods: The case of Brazil', *Journal of Forecasting* **42**(2), 369–401.
- Eklund, J. & Karlsson, S. (2007), 'Forecast combination and model averaging using predictive measures', *Econometric Reviews* **26**(2-4), 329–363.
- Engle, R. F., Granger, C. W. & Kraft, D. (1984), 'Combining competing forecasts of inflation using a bivariate ARCH model', *Journal of Economic Dynamics and Control* **8**(2), 151–165.
- Fang, Y. (2003), 'Forecasting combination and encompassing tests', *International Journal of Forecasting* **19**(1), 87–94.
- Faust, J. & Wright, J. H. (2013), Forecasting inflation, in 'Handbook of Economic Forecasting', Vol. 2, Elsevier, pp. 2–56.

- Forni, M., Hallin, M., Lippi, M. & Reichlin, L. (2003), 'Do financial variables help forecasting inflation and real activity in the euro area?', *Journal of Monetary Economics* **50**(6), 1243–1255.
- Fulton, C. & Hubrich, K. (2021), 'Forecasting US inflation in real time', *Econometrics* **9**(4), 1–20.
- Ghysels, E. & Wright, J. H. (2009), 'Forecasting professional forecasters', *Journal of Business & Economic Statistics* **27**(4), 504–516.
- Groen, J. J., Paap, R. & Ravazzolo, F. (2013), 'Real-time inflation forecasting in a changing world', *Journal of Business & Economic Statistics* **31**(1), 29–44.
- Gupta, R. & Hartley, F. (2013), 'The role of asset prices in forecasting inflation and output in South Africa', *Journal of Emerging Market Finance* **12**(3), 239–291.
- Ha, J., Kose, M. A., Ohnsorge, F. & Yilmazkuday, H. (2024), 'What explains global inflation', *IMF Economic Review* pp. 1–34.
- Hmadouch, Y. A. (2025), 'Domestic and external drivers of inflation in oil importing developing countries', *International Journal of Energy Economics and Policy* **15**.
- Hochreiter, S. & Schmidhuber, J. (1997), 'Long short-term memory', *Neural Computation* **9**(8), 1735–1780.
- Hoerl, A. E. & Kennard, R. W. (1970), 'Ridge regression: Biased estimation for nonorthogonal problems', *Technometrics* **12**(1), 55–67.
- Hubrich, K. & Skudelny, F. (2017), 'Forecast combination for euro area inflation: a cure in times of crisis?', *Journal of Forecasting* **36**(5), 515–540.
- Kascha, C. & Ravazzolo, F. (2010), 'Combining inflation density forecasts', *Journal of Forecasting* **29**(1-2), 231–250.
- Kelikume, I. & Salami, A. (2014), 'Time series modeling and forecasting inflation: evidence from Nigeria', *The International Journal of Business and Finance Research* **8**(2), 41–51.
- Kinlaw, W., Kritzman, M., Metcalfe, M. & Turkington, D. (2023), 'The determinants of inflation', *Journal of Investment Management* **21**(3), 29–41.

- Koop, G. & Korobilis, D. (2012), ‘Forecasting inflation using dynamic model averaging’, *International Economic Review* **53**(3), 867–886.
- Lim, Y. C. & Sek, S. K. (2015), ‘An examination on the determinants of inflation’, *Journal of Economics, Business and Management* **3**(7), 678–682.
- Liu, Y., Pan, R. & Xu, R. (2024), ‘Mending the crystal ball: Enhanced inflation forecasts with machine learning’, *IMF Working Paper No.206*.
- McAdam, P. & McNelis, P. (2005), ‘Forecasting inflation with thick models and neural networks’, *Economic Modelling* **22**(5), 848–867.
- Medeiros, M. C., Vasconcelos, G. F., Veiga, Á. & Zilberman, E. (2021), ‘Forecasting inflation in a data-rich environment: the benefits of machine learning methods’, *Journal of Business & Economic Statistics* **39**(1), 98–119.
- Menculini, L., Marini, A., Proietti, M., Garinei, A., Bozza, A., Moretti, C. & Marconi, M. (2021), ‘Comparing prophet and deep learning to ARIMA in forecasting wholesale food prices’, *Forecasting* **3**(3), 644–662.
- Moshiri, S., Cameron, N. E. & Scuse, D. (1999), ‘Static, dynamic, and hybrid neural networks in forecasting inflation’, *Computational Economics* **14**(3), 219–235.
- Naghi, A. A., O’Neill, E. & Danielova Zaharieva, M. (2024), ‘The benefits of forecasting inflation with machine learning: New evidence’, *Journal of Applied Econometrics* **39**(7), 1321–1331.
- Nason, G. P. & Palasciano, H. A. (2025), ‘Forecasting UK consumer price inflation with RaGNAR: Random generalised network autoregressive processes’, *International Journal of Forecasting*.
- Newbold, P. & Harvey, D. I. (2002), ‘Forecast combination and encompassing’, *A Companion to Economic Forecasting* **1**, 620.
- Nguyen, A. D., Dridi, J., Unsal, F. D. & Williams, O. H. (2017), ‘On the drivers of inflation in Sub-Saharan Africa’, *International Economics* **151**, 71–84.
- Öğünç, F., Akdoğan, K., Başer, S., Chadwick, M. G., Ertuğ, D., Hülagü, T., Kösem, S., Özmen, M. U. & Tekatlı, N. (2013), ‘Short-term inflation forecasting models for Turkey and a forecast combination analysis’, *Economic Modelling* **33**, 312–325.

- Oinonen, S. & Paloviita, M. (2017), 'How informative are aggregated inflation expectations? Evidence from the ECB Survey of Professional Forecasters', *Journal of Business Cycle Research* **13**(2), 139–163.
- Oyewale, A. M., Kasali, A. O., Phazamile, K., Abiodun, M. V. & Adeyinka, A. (2019), 'Forecasting inflation rates using artificial neural networks', *International Journal of Statistics and Applications* **9**(6), 201–207.
- Özgür, Ö. & Akkoç, U. (2022), 'Inflation forecasting in an emerging economy: selecting variables with machine learning algorithms', *International Journal of Emerging Markets* **17**(8), 1889–1908.
- Paranhos, L. (2025), 'Predicting inflation with recurrent neural networks', *International Journal of Forecasting* (Forthcoming).
- Peirano, R., Kristjanpoller, W. & Minutolo, M. C. (2021), 'Forecasting inflation in Latin American countries using a SARIMA–LSTM combination', *Soft Computing* **25**(16), 10851–10862.
- Rodríguez-Vargas, A. (2020), 'Forecasting Costa Rican inflation with machine learning methods', *Latin American Journal of Central Banking* **1**(1-4), 100012.
- Šestanović, T. & Arnerić, J. (2021), 'Can recurrent neural networks predict inflation in euro zone as good as professional forecasters?', *Mathematics* **9**(19), 2486.
- Stock, J. H. & Watson, M. W. (1999), 'Forecasting inflation', *Journal of Monetary Economics* **44**(2), 293–335.
- Stock, J. H. & Watson, M. W. (2003), 'Forecasting output and inflation: The role of asset prices', *Journal of Economic Literature* **41**(3), 788–829.
- Stock, J. H. & Watson, M. W. (2006), 'Forecasting with many predictors', *Handbook of Economic Forecasting* **1**, 515–554.
- Stoneman, D. & Duca, J. V. (2024), 'Using deep (machine) learning to forecast us inflation in the covid-19 era', *Journal of Forecasting* **43**(4), 894–902.
- Taylor, S. J. & Letham, B. (2018), 'Forecasting at scale', *The American Statistician* **72**(1), 37–45.

- Theoharidis, A. F., Guillén, D. A. & Lopes, H. (2023), ‘Deep learning models for inflation forecasting’, *Applied Stochastic Models in Business and Industry* **39**(3), 447–470.
- Thomas, L. B. & Grant, A. P. (2000), ‘Forecasting inflation—surveys versus other forecasts’, *Business Economics* **35**(3), 9–9.
- Tibshirani, R. (1996), ‘Regression shrinkage and selection via the lasso’, *Journal of the Royal Statistical Society Series B: Statistical Methodology* **58**(1), 267–288.
- Timmermann, A. (2006), ‘Forecast combinations’, *Handbook of Economic Forecasting* **1**, 135–196.
- Ülke, V., Sahin, A. & Subasi, A. (2018), ‘A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA’, *Neural Computing and Applications* **30**(5), 1519–1527.
- Wright, J. H. (2009), ‘Forecasting US inflation by Bayesian model averaging’, *Journal of Forecasting* **28**(2), 131–144.

A. Anexo

TABLA A1: Calibración de Hiper-parámetros de Modelos

Método	Muestra	Variables	Parámetro	Valor
LASSO	2000-2025	Inflación Nicaragua	Rezago inflación	12
		Inflación EE.UU	Set entrenamiento( %)	80
		Precio WTI	Set de prueba ( %)	20
		Precio de alimentos	Cross-validation	5
		Deslizamiento	Random_state	42
Ridge	2000-2025	Inflación Nicaragua	Rezago inflación	12
		Inflación EE.UU	Set entrenamiento( %)	80
		Precio WTI	Set de prueba ( %)	20
		Precio de alimentos	Alpha	1
		Deslizamiento	Convergencia	0.001
Red LSTM	2000-2025	Inflación Nicaragua	Rezago inflación	12
		Inflación EE.UU	Set entrenamiento( %)	80
		Precio WTI	Set de validación ( %)	20
		Precio de alimentos	Neuronas	100
		Deslizamiento	Recorrido entrenamiento	50
Prophet	2000-2025		Batch actualizar pesos	5
		Inflación Nicaragua	Rezago inflación	12
		Inflación EE.UU	Estacionalidad mensual	30.5
		Precio WTI	Orden Fourier	5
		Precio de alimentos	Change-point	10
		Deslizamiento	Prior de estacionalidad	0.5

Nota:–Incluye información hasta julio de 2025. WTI: West Texas Intermediate. EE.UU: Estados Unidos.

Fuente: Elaboración propia.


TABLA A2: Evaluación de Pronósticos de Inflación

Enfoque	Modelo	Frecuencia	Explicativas	Evaluación	Periodo	RMSE
Pronóstico sobre: Tasa de inflación						
2-7	AR	Mensual	Univariado	Fuera de muestra	21M1-22M1	1.04
	MA					1.46
	ARMA					0.69
	ARIMA					1.46
	SARIMA					1.33
MIPP						
Pronóstico sobre: IPC						
2-7	AR	Mensual	Univariado	Fuera de muestra	21M1-22M1	4.44
	MA					26.4
	ARMA					4.25
	ARIMA					2.14
	SARIMA					2.03
Pronóstico sobre: Tasa de inflación						
2-7	Lasso	Mensual	Inflación EE.UU. Precio del petróleo. Precio de alimentos. Deslizamiento.	Dentro de muestra	02M1-21M1	0.61
	Ridge					0.62
	LSTM					1.02
	Prophet					1.24
ML y RN	Lasso	Mensual	Inflación EE.UU. Precio del petróleo. Precio de alimentos. Deslizamiento.	Fuera de muestra	21M1-22M1	0.98
	Ridge					0.98
	LSTM					1.51
	Prophet					2.54
Pronóstico sobre: Tasa de inflación						
2-7	Socios com. Correlación	Trimestral	Inflación externa	Fuera de muestra	21T4-24T3	1.16
						2.27
Contrafactual	Sin tendencia	Trimestral	CP inflación externa	Dentro de muestra	00T1-21T3	1.36
	Con tendencia					0.62
	Sin tendencia					2.27
	Con tendencia					2.27
						0.32

Nota:–IPC: índice de precios al consumidor. MIPP: modelos de inflación por productos. ML: *machine learning*. RN: redes neuronales. M: mes. T: trimestre. Los sub-periodos en los cuales se estima el RMSE no necesariamente coinciden con los determinados por los modelos de ML, dado que en ese caso se considera el 80 por ciento de datos como muestra de entrenamiento y el restante como muestra de prueba (como detalla la Tabla A1), y se pretende hacer consistentes los sub-periodos entre distintos enfoques, ya que los datos del enfoque MIPP se extienden hasta enero de 2022.

Fuente: Elaboración propia.

FIGURA A1: Pronósticos Fuera de Muestra con Enfoque MIPP



Nota:—El eje vertical representa porcentaje y el eje horizontal refleja periodos. En el panel (a) se usa y pronostica la tasa de inflación de cada producto  $i$ , mientras que en el panel (b) se utiliza el índice en niveles, sin ninguna transformación. Se usan datos mensuales de los 298 productos que componen el IPC general.

Fuente: Elaboración propia.