

ISSN 2304-8875



BANCO CENTRAL
DE BOLIVIA



ESTADO PLURINACIONAL DE
BOLIVIA

REVISTA DE ANÁLISIS

VOLUMEN 41 - 2024



"2025 BICENTENARIO DE BOLIVIA"



BANCO CENTRAL DE BOLIVIA

Revista de Análisis

Consejo Editorial

Roger Edwin Rojas Ulo
Gumercindo Héctor Pino Guzmán
Rolando Sergio Colque Soldado
Abraham Alfonso Churata Calamani
Rolando Jorge Olmos Alcalá
Sergio Callisaya Ávila
Pascual Oswaldo Quelali Nina

Editor Académico

José Antonio Caballero Peláez

Los autores son responsables de las ideas y opiniones expuestas, las cuales no reflejan necesariamente la opinión o posición del Banco Central de Bolivia

Revista de Análisis del Banco Central de Bolivia. Publicación semestral

Compaginación y diseño: Subgerencia de Comunicación y Relacionamento Institucional
Mes y año de publicación: Agosto de 2025
Número de ejemplares: 350.-
Correspondencia: Banco Central de Bolivia - Asesoría de Política Económica
Ayacucho esquina Mercado
La Paz, Bolivia
Teléfono (591) (02) 2409090 int. 2310
Casilla 3118
Correo electrónico: revistadeanalisis@bcb.gob.bo
Lugar de publicación: La Paz - Bolivia

Derechos reservados: Banco Central de Bolivia
Depósito legal: No. 4-3-833-99

*"Queda prohibida la reproducción total o parcial de este texto por cualquier medio. Su uso deberá realizarse citando la fuente.
La distribución y venta de esta publicación es de derecho exclusivo del Banco Central de Bolivia"*

BANCO CENTRAL DE BOLIVIA

ASESORÍA DE POLÍTICA ECONÓMICA

**REVISTA DE
ANÁLISIS**

Volumen 41
Julio - Diciembre 2024

CONTENIDO

Agradecimiento a árbitros	5
Presentación	7
Nowcast del PIB mediante algoritmos de machine learning: Una evaluación en tiempo real <i>PABLO CACHAGA HERRERA</i> <i>DASHIDA MARY VILLANUEVA OSORIO</i>	9
Proyección del comportamiento de la inflación y descomposición de los choques <i>YARA PÉREZ FORONDA</i>	65
Modelos no lineales para la predicción de indicadores adelantados del PIB con variables monetarias y fiscales <i>PABLO CACHAGA HERRERA</i> <i>MARTIN VALLEJOS TARQUI</i>	101
Pruebas de tensión integral como herramienta de política macroprudencial mediante un enfoque de aprendizaje profundo (<i>deep learning</i>) <i>PATRICIA ARANDA BLANCO</i> <i>BORIS ALFREDO LUNA ACEVEDO</i>	149
Reseña del libro <i>Slow burn: The hidden costs of a warming world</i>	189

AGRADECIMIENTO A ÁRBITROS

El Consejo Editorial del Banco Central de Bolivia desea expresar su reconocimiento a las siguientes personas, quienes realizaron la revisión arbitral de los artículos del Volumen 41 de la *Revista de Análisis*:

Armstrong Lenin Apaza Ticona
Banco Central del Ecuador
Marco Antonio Belmonte Fagalde
Guido Mario Camacho Soria
Abraham Alfonso Churata Calamani

Wilder Guarachi Cusi
Lisbeth Lidia Limachi Cruz
Ángela Andrea Ortiz Ameller
Juan Pablo Rowert Mariscal
Marcial Villarroel Siles

PRESENTACIÓN

El presente volumen 41 de la Revista de Análisis llega con cuatro artículos de interés, los mismos tratan el tema de los pronósticos económicos, utilizando distintas metodologías. Asimismo, una de las investigaciones se refiere a pruebas de tensión aplicadas al sistema financiero. En seguida, se presenta una síntesis de dichos artículos a manera de introducción e invitación a su lectura.

El artículo “Nowcast del PIB mediante algoritmos de *machine learning*: Una evaluación en tiempo real” fue escrito por Pablo Herrera y Dashida Mary Villanueva. Los autores utilizan tres metodologías para suplir el rezago con el cual el Producto Interno Bruto (PIB) se publica y, de esa manera, contar con estimaciones para la formulación más oportuna de políticas económicas. Tres enfoques son aplicados por los autores: dos son de regresión y uno de árboles de decisión. Obtenidos los resultados, los autores concluyen que uno de los métodos de árboles de decisión, como es el *Gradient Boosting*, es el que ofrece un mejor desempeño predictivo dentro de la muestra, mientras que los métodos de regresión *Ridge* y de vectores de soporte (SVR) resultan ser los que presentan un menor error cuadrático medio fuera de la muestra.

La autora Yara Pérez propone el artículo “Proyección del comportamiento de la inflación y descomposición de los choques” en el que plantea un modelo para la proyección de corto plazo de la inflación en Bolivia, considerando variables relevantes endógenas y exógenas. Para ello, aplica el modelo VARX (vectores autorregresivos con información exógena) al periodo comprendido entre el primer trimestre del año 2000 hasta el segundo trimestre del año 2024. El principal resultado demuestra ser satisfactorio, de ágil aplicación y puede ser considerado dentro de la batería de herramientas para el pronóstico de la inflación en el corto plazo.

Los investigadores Pablo Cachaga y Martín Vallejos ponen a prueba la capacidad predictiva de las variables monetarias y fiscales sobre la actividad económica de Bolivia, utilizando los métodos de *machine learning* y de Vector autorregresivo variables en el tiempo (TVP-VAR). El artículo se titula “Modelos no lineales para la predicción de indicadores adelantados del PIB con variables monetarias y fiscales” y en él, los autores constatan que ambos métodos tienen ventajas complementarias. Por una parte, el modelo de *machine learning* permite detectar relaciones no lineales en contextos de estabilidad, mientras que el TVP-VAR es más preciso en situaciones de cambios estructurales.

“Pruebas de tensión integral como herramienta de política macroprudencial mediante un enfoque de aprendizaje profundo (*deep learning*)” es el artículo que ha sido elaborado por los analistas Patricia Aranda y Boris Luna. Empleando modelos de aprendizaje de redes neuronales profundas, desarrollan pruebas de

tensión aplicadas al sistema financiero boliviano. Utilizando un enfoque basado en datos históricos y simulaciones, se desarrollan modelos predictivos que permiten analizar los efectos de condiciones económicas adversas en la solvencia bancaria. Los resultados obtenidos con esta herramienta resultaron ser robustos y se constituyen en una buena alternativa para la toma de decisiones estratégicas y la gestión de riesgo financiero.

El propósito de la Revista de Análisis del Banco Central de Bolivia es el de contribuir al conocimiento con enfoque científico. Por tal motivo, le invitamos a que dé un repaso a estos artículos, luego de lo cual, seguramente contribuirán a que usted, amable lector, forme una opinión y, posiblemente, profundice en estos temas.

Rolando Sergio Colque Soldado
Asesor Principal de Política Económica



RETRATO DE NIÑA AYMARA
Cecilio Guzmán de Rojas
1945
Dibujo a caboncillo sobre papel

Nowcast del PIB mediante algoritmos de *machine learning*: Una evaluación en tiempo real *

Pablo Cachaga Herrera
Dashida Mary Villanueva Osorio

RESUMEN

La demora en la publicación del Producto Interno Bruto (PIB) en América Latina y el Caribe dificulta una formulación oportuna de políticas económicas. Este estudio propone un modelo de *nowcasting* del PIB para Bolivia, utilizando algoritmos de *Machine Learning* (ML) y datos en tiempo real. Se aplican tres enfoques principales: regresión penalizada (*Ridge*, Lasso, Elastic Net), métodos basados en árboles de decisión (*Random Forest*, *Gradient Boosting*) y regresión de vectores de soporte (SVR). El análisis se basa en 87 variables macroeconómicas del período 2007-2023. Los resultados demuestran que *Gradient Boosting* es el método con mejor desempeño predictivo dentro de la muestra. No obstante, fuera de la muestra, enfoques como *Ridge* y SVR presentan un menor error cuadrático medio (MSE). Los hallazgos destacan el potencial de estas técnicas para estimar el PIB en tiempo real y respaldar decisiones económicas y de política pública en Bolivia, mejorando la toma de decisiones estratégicas.

Clasificación JEL: C53, C61, C82

Palabras clave: *Nowcasting, machine learning, PIB, regresión penalizada, árboles de decisión, economía en tiempo real*

* El contenido del presente documento es de responsabilidad de los autores y no compromete la opinión del Banco Central de Bolivia.

GDP nowcast using machine learning algorithms: A real-time evaluation *

Pablo Cachaga Herrera
Dashida Mary Villanueva Osorio

ABSTRACT

The delay in the release of Gross Domestic Product (GDP) data in Latin America and the Caribbean presents challenges for timely economic policy-making. This study develops a GDP nowcasting model for Bolivia using Machine Learning (ML) algorithms and real-time data. Three main approaches are employed: penalized regression methods (Ridge, Lasso, Elastic Net), tree-based models (Random Forest, Gradient Boosting), and support vector regression (SVR). The analysis employs 87 macroeconomic variables covering the period 2007–2023. Results show that Gradient Boosting achieves the best predictive accuracy in-sample, while Ridge and SVR yield lower mean squared errors (MSE) out-of-sample. The findings highlight the potential of these techniques to estimate GDP in real time and support economic and public policy decisions in Bolivia, thereby enhancing strategic decision-making.

JEL Classification: C53, C61, C82

Keywords: *Nowcasting, Machine Learning, GDP, Penalized Regression, Decision Trees, Real-Time Economy*

* The content of this document is the responsibility of the authors and does not represent the opinion of the Central Bank of Bolivia.

I. Introducción

En varios países de América Latina y el Caribe, la publicación de variables macroeconómicas clave, como el Producto Interno Bruto (PIB), presenta un retraso que limita la disponibilidad de información oportuna para los responsables de la formulación de políticas públicas y otros actores económicos. Esta demora constituye un desafío significativo, ya que impide la toma de decisiones oportunas en el corto plazo. Con la finalidad de superar esta limitación, los bancos centrales y organismos internacionales han recurrido a previsiones inmediatas, entendidas como evaluaciones del estado actual de la economía basadas en indicadores parcialmente disponibles.

En los últimos años, la literatura ha mostrado avances sustanciales en la aplicación de algoritmos de *Machine Learning* (ML) para el pronóstico macroeconómico y el *nowcasting*, posicionándose como una alternativa eficaz para realizar predicciones inmediatas, incluso en contextos de escasez de información o alta incertidumbre.

La metodología del *nowcasting*, se refiere a la estimación de una variable económica antes de su cálculo o publicación oficial, utilizando datos disponibles en tiempo real o con mayor frecuencia. En este contexto, los modelos de *nowcasting* han adquirido relevancia, ya que permiten mitigar el impacto del retraso en la publicación de indicadores económicos mediante el uso de datos de otros indicadores cuya frecuencia de actualización es más alta. Estos modelos se basan en variables que están semi o altamente correlacionadas con el PIB y que se publican semanal, mensual o trimestralmente, lo que posibilita la obtención de señales en tiempo real sobre la evolución de la economía y permite realizar pronósticos más precisos sobre el PIB para los períodos de interés.

El uso de algoritmos de *machine learning* para la predicción económica ha cobrado gran relevancia en la literatura reciente, especialmente en contextos de *nowcasting* del PIB, Stock y Watson (2016) y Ferrara y Simoni (2020). En Bolivia, las investigaciones que aplican *nowcasting* mediante técnicas de aprendizaje automático para estimar el PIB son limitadas. En este documento, se presenta un modelo de *nowcasting* para el PIB utilizando técnicas de *machine learning*, que emplean tres enfoques principales: regresión penalizada, árboles de decisión y regresión de

vectores de soporte (SVR). Los modelos de regresión penalizada utilizados son *Ridge*, *Lasso* y *Elastic Net*. En cuanto a los árboles de decisión, se emplean *Random Forest* y *Boosted Trees*. Finalmente, se utiliza la SVR incluyendo su variante lineal.

Este documento tiene como objetivo describir los modelos de machine learning empleados en los ejercicios de *nowcasting*, con el fin de proporcionar información oportuna sobre el comportamiento económico. El documento está estructurado en cinco secciones principales: i) introducción, ii) revisión de la literatura, iii) metodología, iv) resultados, y v) conclusiones.

II. Revisión de la literatura

Esta sección destaca las investigaciones que aplican *nowcasting* mediante técnicas de *machine learning*, especialmente para variables macroeconómicas clave como el PIB. Dado que la publicación del PIB presenta un retraso significativo, lo que limita la disponibilidad de información en tiempo real, el uso de métodos de *nowcasting* resulta clave para generar estimaciones más precisas y oportunas sobre la evolución económica. Bok et al. (2018) demostraron que modelos de regresión regularizados mejoran la precisión de los pronósticos en economías emergentes. Asimismo, Bañbura et al. (2010) encontraron que técnicas de reducción de dimensionalidad como *Ridge* y *Lasso* permiten capturar información relevante en tiempo real para la predicción de indicadores macroeconómicos. A continuación, se presentan las investigaciones más relevantes:

Giannone et al. (2008) desarrolla un modelo de factores dinámicos para Estados Unidos, empleando 200 indicadores macroeconómicos que incluyen variables reales, financieras, de precios, salarios, agregados de dinero y crédito, y encuestas, abarcando el periodo de enero de 1982 a marzo de 2005. El modelo econométrico es un factor dinámico que estima los factores en dos pasos: primero, calculando los componentes principales, y luego, utilizando el suavizador de Kalman. Los resultados empíricos muestran que los flujos de datos intratrimestrales mejoran la precisión de las previsiones a medida que se dispone de nueva información.

Rusnák (2016) emplea un Modelo de Factores Dinámicos (DFM) para realizar predicciones en tiempo real del PIB de la República Checa, utilizando datos de diversas variables entre 2005 y 2012. Se evalúa el rendimiento del modelo utilizando datos históricos de diversas variables y considerando los retrasos en la publicación de varios indicadores mensuales. El principal hallazgo es que la precisión de las predicciones generadas por el modelo de factores dinámicos es comparable con las de la República Checa (CNB), y al combinar ambos métodos, se obtiene una mayor precisión.

Richardson et al. (2019) evalúan el rendimiento en tiempo real de varios algoritmos de aprendizaje automático con el objetivo de generar previsiones más precisas sobre el crecimiento del PIB de Nueva Zelanda. El estudio realiza estimaciones utilizando diferentes modelos de ML para el período 2009-2019, considerando aproximadamente 600 variables tanto nacionales como internacionales. Los resultados indican que la mayoría de los modelos ML superan en precisión a los modelos AR y de factores dinámicos. En consecuencia, se recomienda el uso de algoritmos de ML como herramientas complementarias.

El Banco Interamericano de Desarrollo (2021) presenta modelos de machine learning ajustados para realizar un *nowcasting* del PIB trimestral de Belice y El Salvador, destacando el uso de regresiones penalizadas como Lasso, Ridge y Elastic-Net. Los resultados indican que las regresiones penalizadas son los modelos que mejor se ajustan en comparación con otros métodos, según el error cuadrático medio. Además, el pronóstico realizado por estos modelos es bastante preciso en relación con la evolución del PIB trimestral en ambos países. Finalmente, los hallazgos muestran que las técnicas de *machine learning* son capaces de generar pronósticos precisos del PIB trimestral para ambas economías, estructuralmente diferentes, en un contexto económico de alta volatilidad.

Kant et al. (2022) comparan diversos métodos econométricos y de aprendizaje automático para realizar previsiones en tiempo real del PIB de Holanda entre 1992 y 2018, utilizando un amplio conjunto de datos mensuales. Los resultados sugieren que, desde la crisis financiera, el rendimiento relativo del modelo de factores dinámicos (utilizado en muchos bancos centrales) se ha deteriorado en comparación con otros modelos. En particular, el modelo de bosque aleatorio destaca por ofrecer

las predicciones más precisas, ya que utiliza las distintas variables de manera relativamente estable e igualitaria.

Dauphin et al., (2022) analiza datos de seis economías europeas (Portugal, Austria, Polonia, Hungría, Malta e Irlanda) y compara métodos de predicción tradicionales y modernos entre 1995T1 y 2021T4. Los DFM y de ML demostraron ser particularmente útiles en períodos de alta volatilidad, como la pandemia de COVID-19, superando al modelo AR(1) en la mayoría de los casos. El rendimiento de los modelos varió según el país y el periodo de tiempo, y no existe un modelo universalmente superior. En términos generales, el DFM fue más efectivo en tiempos de estabilidad para algunos países, mientras que los modelos ML fueron más eficaces durante la crisis del COVID-19 al capturar puntos de inflexión en el PIB.

Tenorio y Pérez (2024c) presentan modelos de proyección del crecimiento del PIB en Perú basados en aprendizaje automático desde enero de 2007 hasta mayo de 2023, utilizando 91 indicadores económicos líderes; además evalúa seis algoritmos de *machine learning*. Los hallazgos destacan la capacidad predictiva superior de los modelos de ML, en particular *Gradient Boosting Machine*, *LASSO* y *Elastic Net*, los cuales logran una reducción del 20% al 25% en los errores de predicción en comparación con los modelos autorregresivos (AR) y los modelos de factores dinámicos (MFD) tradicionales. Este rendimiento mejorado se atribuye a la capacidad superior de los modelos de ML para gestionar los datos en períodos de alta incertidumbre, como las crisis económicas.

Gonzales-Astudillo y Baquero (2019) proponen un modelo de *nowcasting* para la economía ecuatoriana, que combina datos mensuales de 30 variables macroeconómicas y financieras con datos trimestrales del PIB real, utilizando un enfoque de frecuencia mixta que mejora la precisión de las previsiones. El modelo incluye un coeficiente variable en el tiempo para la tasa de crecimiento del PIB, lo que mejora la precisión de las previsiones en comparación con un modelo con tasa constante. Los resultados muestran que el modelo con intercepto variable en el tiempo supera significativamente al modelo con intercepto constante en predicciones fuera de la muestra. También se encontró que la inclusión de variables financieras puede deteriorar el rendimiento, y que modelos más simples con solo variables reales o un solo factor pueden ser igualmente efectivos.

En Bolivia, las investigaciones que aplican *nowcasting* con técnicas de aprendizaje automático son limitadas. Bolívar (2024) propone una metodología innovadora que emplea modelos de *Ridge*, *ElasticNet* y *Gradient Boosting Regressor*, utilizando datos derivados de imágenes satelitales para predecir el crecimiento económico en tiempo real. Los resultados muestran que esta metodología mejora la precisión de las estimaciones, superando los modelos econométricos tradicionales. Los resultados indican que esta metodología no solo mejora la precisión de las estimaciones, sino que también es capaz de adaptarse a eventos atípicos, como la pandemia de COVID-19, superando los modelos econométricos convencionales en cuanto a rendimiento predictivo.

III. Metodología

La metodología emplea tres enfoques principales: regresión penalizada, árboles de decisión y SVR. Los modelos de regresión penalizada, como Ridge, Lasso y Elastic Net, aplican penalizaciones para evitar el sobreajuste y seleccionar variables clave. Los árboles de decisión, como *Random Forest* y *Boosted Trees*, segmentan los datos en nodos jerárquicos y, combinando varios árboles, mejoran la precisión y robustez de las predicciones.

Finalmente, la SVR, incluyendo su variante lineal, ajusta una función a los datos permitiendo un margen de tolerancia, lo que la hace resistente al ruido y especialmente eficaz en tareas de regresión. A continuación, se detallan los enfoques:

III.1. Modelo de regresión penalizada

Los modelos de regresión penalizada son técnicas que añaden una penalización a los coeficientes del modelo para evitar el sobreajuste y mejorar su capacidad de generalización, especialmente cuando hay muchas variables predictoras. Entre estos métodos se encuentran *Ridge*, Lasso y *Elastic Net*, los cuales aplican distintas formas de penalización, lo que facilita la selección de las variables más relevantes y el control de la complejidad del modelo.

III.1.1. Regresión Ridge¹

La Regresión *Ridge* es un método de regularización que introduce una penalización basada en la suma de los cuadrados de los coeficientes de las variables predictoras. Esta penalización impide que los coeficientes adquieran valores extremadamente grandes, reduciendo la influencia de las variables menos relevantes y mejorando la capacidad de generalización del modelo. Como resultado, se minimiza el riesgo de sobreajuste (*overfitting*), logrando un equilibrio entre sesgo y varianza. El problema de optimización en *Ridge* se define como:

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

donde y_i representa la variable de respuesta para la observación i ; x_{ij} son las variables predictoras; β_j son los coeficientes de regresión; y λ es el hiperparámetro de penalización que regula la magnitud de la regularización en el modelo.

La suma de los términos β_j^2 en la penalización restringe la magnitud de los coeficientes, lo que mejora la estabilidad del modelo y favorece su capacidad de generalización a datos no observados. A medida que λ aumenta, los coeficientes se reducen en magnitud, lo que puede ayudar a mitigar problemas de multicolinealidad en los datos.

III.1.2. Regresión Lasso²

La Regresión *Lasso* (*Least Absolute Shrinkage and Selection Operator*) es un método de regularización que introduce una penalización basada en la suma de los valores absolutos de los coeficientes de las variables de predicción en un modelo de regresión lineal. Esta penalización tiene la propiedad de forzar algunos coeficientes a ser exactamente cero, lo que implica una selección automática de variables al eliminar aquellas que no contribuyen significativamente al modelo. El problema de optimización en *Lasso* se define como:

- 1 Fue introducido por Hoerl and Kennard (1970).
- 2 Least Absolute Shrinkage and Selection Operator por sus siglas en inglés, introducido por Tibshirani (1996).

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

El término de penalización $\sum_{j=1}^p |\beta_j|$ introduce un efecto de reducción de coeficientes, con la particularidad de que algunos de ellos se reducen exactamente a cero. Esto convierte a Lasso en un método útil no solo para regularizar el modelo, sino también para realizar selección de variables, identificando aquellas más relevantes y eliminando las irrelevantes.

A medida que λ aumenta, se incrementa la penalización, lo que lleva a una mayor reducción en la magnitud de los coeficientes y a una selección más estricta de variables predictoras. Por otro lado, si λ es demasiado pequeño, el modelo se comporta similar a una regresión lineal ordinaria sin penalización.

Comparado con la Regresión *Ridge*, Lasso es especialmente útil cuando se sospecha que solo un subconjunto de variables es verdaderamente relevante, ya que proporciona un modelo más interpretable con menos predictores.

III.1.3 Regresión Lasso Adaptativo³

La Regresión Lasso Adaptativa (*Adaptive Lasso*) es una extensión del método Lasso que introduce pesos diferenciados en la penalización de los coeficientes, permitiendo una selección de variables más refinada y mejorando la consistencia del estimador. La idea central de este método es aplicar una penalización ponderada a los coeficientes de regresión en función de una estimación previa de su magnitud.

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

La diferencia respecto al modelo Lasso es que este incluye una variable w_j de pesos adaptativos asignados a cada coeficiente β_j . Los pesos adaptativos w_j se calculan usualmente como:

³ Zhang (2010) analiza el problema de sesgo en métodos como Lasso y Adaptive Lasso y propone mejoras.

$$w_j = \frac{1}{|\hat{\beta}_j^{OLS}|^\gamma}$$

donde $\hat{\beta}_j^{OLS}$ es la estimación inicial de los coeficientes obtenida mediante regresión ordinaria (OLS), y $\gamma > 0$ es un parámetro que ajusta la influencia de los pesos. Este enfoque ayuda a evitar la sobre penalización de variables verdaderamente importantes, mejorando la selección de variables en comparación con el Lasso tradicional.

A diferencia del Lasso normal, el Lasso adaptativo tiene mayor precisión en la selección de variables, al utilizar pesos diferenciados, el método mejora la capacidad de distinguir entre variables relevantes e irrelevantes, por otro lado, aumenta la consistencia en selección de variables, lo que significa que puede identificar correctamente las variables significativas en un modelo conforme el número de observaciones aumenta. Por último, reduce el sesgo en la estimación de los coeficientes de variables importantes.

III.1.3. Regresión Elastic Net⁴

La Regresión *Elastic Net* es un método de regularización que combina las propiedades de la Regresión Lasso y la Regresión *Ridge*, ofreciendo una solución más robusta cuando el número de predictores es alto, especialmente en situaciones donde $p > n$ (más variables que observaciones) o cuando existen altos niveles de colinealidad entre las variables.

Según Zou y Hastie (2005), su principal ventaja radica en su capacidad para corregir deficiencias de Lasso, como la incapacidad de seleccionar grupos de variables correlacionadas, y la de *Ridge*, que no realiza una selección automática de variables.

El problema de optimización en *Elastic Net* se define como:

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

λ es el hiperparámetro de penalización global, que regula la magnitud total de la regularización, α es el parámetro de mezcla, que controla la

⁴ Fue introducido por Zou and Hastie (2005).

proporción entre las penalizaciones Lasso y *Ridge*: si $\alpha = 1$, el modelo se convierte en Lasso, si $\alpha = 0$, el modelo se convierte en *Ridge*. Para valores intermedios de α , se obtiene una combinación equilibrada de ambas penalizaciones.

Las ventajas de *Elastic Net* son:

Mejor manejo de colinealidad: A diferencia de Lasso, que puede seleccionar solo una variable entre un grupo de predictores altamente correlacionados, *Elastic Net* tiende a incluir grupos completos de variables relevantes

Mayor estabilidad en alta dimensionalidad: Es útil cuando el número de variables es mayor que el número de observaciones $p > n$, lo que ocurre frecuentemente en problemas de genética, procesamiento de texto y finanzas

Mayor flexibilidad en selección de variables: Permite ajustar la mezcla entre *Ridge* y Lasso, logrando un equilibrio entre la reducción del sesgo y la selección de variables.

Elastic Net es especialmente útil en problemas donde la cantidad de variables es grande y altamente correlacionada, proporcionando una solución más estable y flexible que Lasso o *Ridge* por separado

III.2. Modelos de árboles de decisión (*Decision tree models*)

Los modelos de árboles de decisión son algoritmos de aprendizaje automático que estructuran la toma de decisiones en una representación jerárquica en forma de árbol. Cada nodo interno del árbol representa una característica o atributo del conjunto de datos, mientras que cada rama define una regla o criterio de decisión basado en dicho atributo. El proceso de entrenamiento divide iterativamente los datos en función de estas reglas hasta alcanzar los nodos hoja, que generan las predicciones finales.

Los árboles de decisión individuales pueden ser propensos al sobreajuste, por lo que se han desarrollado métodos avanzados que combinan múltiples árboles para mejorar el rendimiento y la generalización del modelo:

- **Random Forest:** Conjunto de múltiples árboles de decisión donde cada árbol se entrena con una muestra aleatoria del conjunto de datos (bootstrap sampling). Además, en cada nodo, solo se considera un subconjunto aleatorio de las características, lo que reduce la correlación entre los árboles y mejora la robustez del modelo.
- **Boosted Trees:** Método basado en la combinación secuencial de múltiples árboles, donde cada nuevo árbol se entrena para corregir los errores cometidos por los árboles anteriores. Técnicas como *Gradient Boosting Machines* (GBM), *XGBoost*, y *LightGBM* utilizan este enfoque para lograr una alta precisión en problemas complejos

III.2.1. Random forest

El *Random Forest* es un método de ensamble basado en árboles de decisión que mejora la precisión y la generalización del modelo mediante la combinación de múltiples árboles de decisión. Su principal ventaja radica en la reducción del sobreajuste (*overfitting*), un problema común en modelos individuales de árboles de decisión.

Este algoritmo funciona mediante dos principios clave:

- **Selección aleatoria de características:** Para cada árbol en el bosque, se selecciona aleatoriamente un subconjunto de características de la matriz X en cada nodo de decisión, lo que introduce variabilidad y reduce la correlación entre los árboles.
- **Bootstrap sampling:** Cada árbol se entrena con una muestra aleatoria con reemplazo (*bagging*) de los datos de entrenamiento, permitiendo que algunos datos se repitan y otros queden fuera (*out-of-bag data*), lo que ayuda a estimar el error generalizado del modelo.

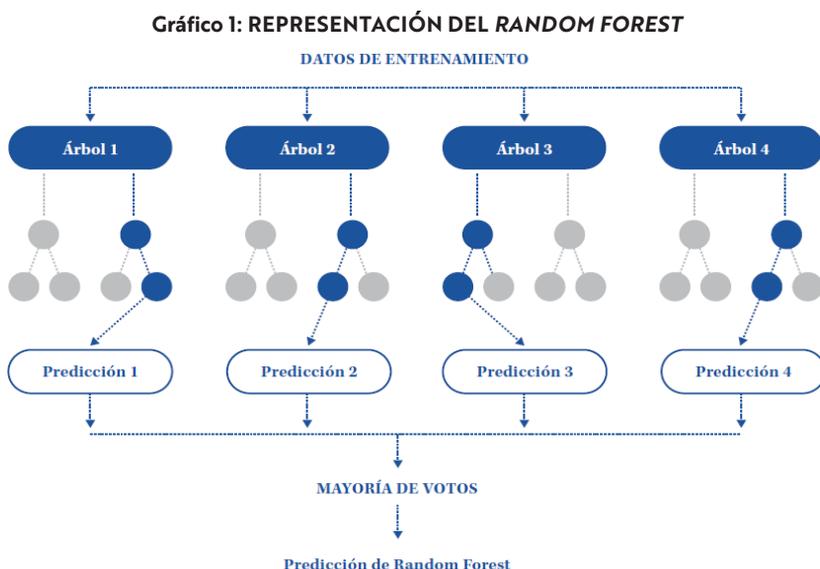
Cada árbol en el *Random Forest* genera una predicción para la variable objetivo (en este caso, el PIB mensual), y el modelo final selecciona la predicción más votada en el conjunto de árboles (para clasificación) o el promedio de todas las predicciones (para regresión).

La función de predicción se puede representar como:

$$\hat{f}(x) = \sum_m \hat{c}_m I(x \in X_r); \quad \hat{c}_m = \text{avg}(y_i | x_i \in X_r)$$

donde $\hat{f}(x)$ es la predicción final del modelo, \hat{c}_m representa la predicción generada por cada árbol m , $I(x \in X_r)$ indica si la observación pertenece a la región X_r en el árbol m . En el caso de regresión, la predicción final es el promedio de las predicciones individuales y, en el caso de clasificación, se utiliza la regla de mayoría (la clase con más votos).

Este método ha sido ampliamente utilizado en análisis económicos, como la predicción del PIB mensual, debido a su capacidad para manejar grandes volúmenes de datos con alta dimensionalidad y relaciones no lineales. (Gráfico 1).



Fuente: Extraído Banco Interamericano de Desarrollo (2021)

III.2.2. Gradient Boosting Machines (GBM)

El GBM es un enfoque de aprendizaje supervisado, basado en la combinación secuencial de múltiples árboles de decisión con el objetivo de mejorar la precisión del modelo. A diferencia de métodos como *Random Forest*, donde los árboles se entrenan de manera independiente, en GBM cada nuevo árbol se construye para corregir los errores cometidos por los árboles anteriores.

El proceso de boosting optimiza iterativamente el modelo, ajustando los errores residuales, permitiendo que el algoritmo se enfoque en las observaciones más difíciles de predecir en cada iteración. Para ello, se utiliza un algoritmo de optimización basado en el descenso del gradiente, que minimiza la diferencia entre las predicciones del modelo y los valores reales de la variable objetivo. El modelo en la iteración m se define como:

$$F_m(x) = F_{m-1}(x) + \eta h_m(x)$$

donde $F_m(x)$ es la predicción del modelo después de m iteraciones, $F_{m-1}(x)$ es la predicción generada en la iteración anterior, $h_m(x)$ representa el nuevo árbol entrenado en la iteración m diseñado para corregir los errores del modelo previo, y η es el factor de aprendizaje que controla cuánto contribuye el árbol nuevo a la predicción final.

El modelo se ajusta iterativamente a los residuos de la predicción anterior, minimizando la diferencia entre las predicciones y las respuestas reales. Los residuos se pueden calcular como:

$$r_i^{(m)} = y_i - F_{m-1}(x)$$

donde y_i representa el valor real de la variable objetivo. El nuevo árbol $h_m(x)$ se entrena para predecir estos residuos, mejorando así la precisión del modelo en cada iteración.

Aunque GBM ofrece una alta precisión, su tendencia al sobreajuste puede ser un problema si no se controlan adecuadamente ciertos parámetros, como:

Tasa de aprendizaje (η): Valores muy altos pueden provocar oscilaciones en el aprendizaje, mientras que valores bajos requieren más iteraciones para converger. número de árboles. Un número excesivo de árboles puede generar sobreajuste, por lo que es importante encontrar un balance y profundidad de los árboles. Árboles demasiado profundos pueden memorizar los datos de entrenamiento en lugar de generalizar.

III.2.3. Regresión de Vectores de Soporte (SVR)⁵

La SVR (por sus siglas en inglés) es una técnica de aprendizaje automático basada en Máquinas de Soporte Vectorial (SVM, por sus siglas en inglés),

5 Cortes and Vapnik (1995), Boser et al. (1992) y Vapnik (1999).

diseñada para encontrar una función que se ajuste a los datos de manera óptima, permitiendo un margen de tolerancia (ϵ). Este margen hace que SVR sea resistente al ruido y a las variaciones menores en los datos, lo que la convierte en una opción robusta para problemas de regresión.

A diferencia de los métodos tradicionales de regresión, SVR no busca minimizar simplemente el error absoluto o cuadrático, sino que intenta encontrar una función que esté lo más cercana posible a los datos dentro del margen permitido, penalizando solo aquellos puntos que excedan dicho margen.

III.2.2. SVR lineal

La Regresión de Vectores de Soporte Lineal (Linear SVR) es una variante de SVR que utiliza un *kernel* lineal, lo que significa que la función ajustada es una función lineal en el espacio de entrada. Su objetivo es encontrar una recta o hiperplano óptimo que minimice los errores, manteniendo un margen de tolerancia (ϵ). La función de regresión se define como:

$$f(x) = wx + b$$

donde w es el vector de pesos (coeficientes) que define la dirección del hiperplano, x es el vector de características de entrada y b es el sesgo o término independiente.

El modelo minimiza una función de pérdida estructurada que combina: regularización, debido a que controla la magnitud de los coeficientes w para evitar el sobreajuste (*overfitting*) y realiza la penalización de errores, porque solo los errores que exceden el margen (ϵ) contribuyen a la función de pérdida, lo que permite una mayor tolerancia al ruido en los datos. El problema de optimización en SVR se define como:

$$\min_{w, \beta} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i$$

sujeto a:

$$|y_i - (wy_i + b)| \leq \epsilon + \xi_i, \quad \xi_i \geq 0, \quad \forall i$$

donde, C es un parámetro de regularización, que equilibra la penalización de los errores y la suavidad del modelo, ξ_i son las variables de holgura,

que permiten manejar los puntos fuera del margen de tolerancia ϵ . $Y \in \epsilon$ es el margen de tolerancia, dentro del cual los errores no se penalizan. SVR Lineal es especialmente útil cuando la relación entre las variables es aproximadamente lineal y se requiere un modelo interpretable y robusto ante ruido en los datos. En casos donde la relación es más compleja, es recomendable utilizar SVR con *kernels* no lineales, como el *kernel* RBF (*Radial Basis Function*) o el *kernel* polinomial

IV. RESULTADOS

a. Datos e información⁶

El conjunto de datos incluye 87 columnas y 204 observaciones, abarcando la variable objetivo, el Indicador Global de Actividad Económica (IGAE), junto con diversas variables predictoras relacionadas con la producción de petróleo y gas, el consumo de combustibles, la inflación, variables monetarias, créditos y depósitos en el sistema financiero por tipo de moneda, tasas de interés, déficit fiscal, ingresos y gastos del sector público, entre otras. Para una descripción detallada de las variables utilizadas, consulte el Apéndice A. El período cubierto por la muestra abarca desde enero de 2007 hasta diciembre de 2023.

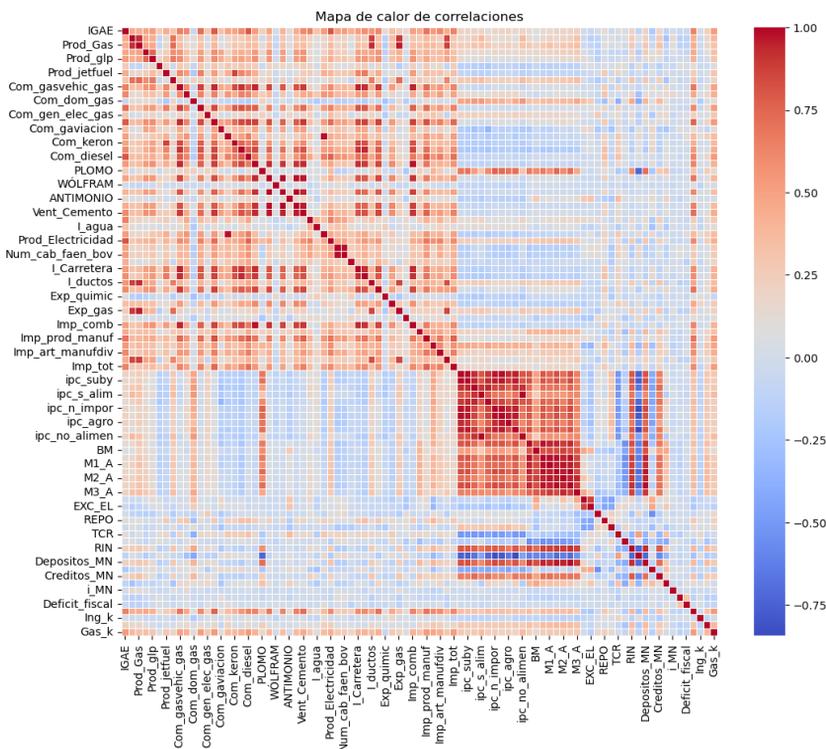
Para analizar la correlación entre las variables, se propone una matriz simétrica que representa la relación entre las variables X e Y. En esta matriz, la diagonal principal contiene valores de 1, ya que cualquier variable está perfectamente correlacionada consigo misma. El color rojo intenso (+1) indica una fuerte correlación positiva entre dos variables, lo que significa que, a medida que una variable aumenta, la otra también tiende a aumentar. Por otro lado, el color azul intenso (-1) señala una fuerte correlación negativa, lo que implica que, cuando una variable aumenta, la otra tiende a disminuir. Los colores más claros, cercanos a 0, representan una relación débil o nula entre las variables.

Se puede identificar agrupaciones de variables que presentan una alta correlación entre sí. Por ejemplo, se observa un bloque de variables económicas asociadas a los agregados monetarios (M1, M2, M3), que muestran una fuerte correlación interna. Asimismo, sectores como la

6 Para mayor detalle de la información utilizada en los modelos véase el Apéndice A.

producción de gas, electricidad, cemento y combustibles también están estrechamente correlacionados entre sí. Las variables correspondientes a los índices de precios al consumidor (IPC) evidencian correlaciones, lo que sugiere que los cambios en los precios de determinados sectores podrían estar interrelacionados. En cuanto a nuestra variable objetivo, el Indicador Global de Actividad Económica (IGAE), se observa una correlación positiva de distinta intensidad con variables del sector real y del sector externo, mientras que la correlación con las variables relacionadas con los precios, aspectos monetarios, financieros y fiscales es de menor intensidad (Gráfico 2).

Gráfico 2: MAPA DE CALOR DE CORRELACIONES



Fuente: Elaboración propia

b. Estimación y calibración de hiperparámetros

La selección adecuada de los hiperparámetros en los modelos de *Machine Learning* es fundamental para optimizar tanto la eficiencia como la precisión de las estimaciones. Según Tenorio y Pérez (2024a), para lograr una calibración óptima, es esencial dividir el conjunto de datos en tres subconjuntos: i) entrenamiento, ii) validación, y iii) prueba. Esta estrategia permite evaluar el desempeño del modelo en distintas etapas del proceso, asegurando una evaluación más robusta y precisa de su rendimiento.

En primera instancia, se entrena el modelo utilizando el conjunto de entrenamiento (*in-sample*) con el objetivo de obtener un conjunto preliminar de hiperparámetros. Luego, se emplea un procedimiento de validación cruzada para refinar estos valores, aprovechando la partición de los datos en cinco grupos (*folds*). Durante este proceso, el modelo se entrena y valida cinco veces, rotando en cada iteración el conjunto de validación, mientras que las demás particiones se usan como conjunto de entrenamiento. Como resultado, se obtiene un conjunto de métricas de desempeño que se promedian para evaluar la estabilidad y precisión del modelo.

Según Snoek et al. (2012), para determinar los valores óptimos de los hiperparámetros, se implementa un enfoque basado en optimización bayesiana, una técnica que permite explorar de manera eficiente el espacio de búsqueda minimizando el error cuadrático medio (MSE) a través de validación cruzada.

Este proceso de calibración implica la predicción del IGAE (y_{t+h}) utilizando la información disponible hasta el tiempo t ($y_{t+h} \parallel I_t$). Posteriormente, se mide la precisión del modelo en el conjunto de prueba (*out-of-sample*) comparando el MSE de las proyecciones obtenidas en t ($y_{t+h} \parallel I_t$), con los valores observados en $t + h$ ($y_{t+h} \parallel I_{t+h}$). Este procedimiento iterativo se repite hasta minimizar el MSE. En este sentido, los hiperparámetros y el valor optimizado para cada modelo de ML se encuentra en la Tabla 1.

7 I_t es el conjunto de información disponible de las variables predictoras, en este caso se está utilizando 86 variables

Tabla 1: Modelos de ML, hiperparámetros y valor óptimo

Modelo	Hiperparámetros	Valor optimizado
Ridge	Lambda	403,7
	Lambda	0,04977
Lasso	Tolerancia de convergencia	0,0001
	Lambda	0,007565
Lasso Adaptativo	Factor de adaptación	2
	Método de normalización de pesos	Lasso inicial con alpha=0,01
Elastic Net	Lambda	0,42919
	L1 Ratio	0,5*
Random Forest	Nro. de Arboles	400
	Nro. de Arboles	400
Gradient Boosting	Tasa de aprendizaje	0,1
	Máxima profundidad del árbol	3
Support Vector Regression (SVR)	C (regularización)	0,1
	Epsilon	0,1
	kernel	lineal

Nota: (*) El L1 Ratio en este caso es 0,5, lo que indica que el modelo este equidistante al modelo LASSO y Ridge en la regularización *Elastic Net*

Fuente: Elaboración propia

c. Resultados del modelo Ridge

Según Hastie et al. (2009), la regresión *Ridge*⁸ es una técnica de regularización que introduce un término de penalización a la magnitud de los coeficientes para evitar sobreajuste. Para determinar el valor óptimo de λ , se implementó un proceso de búsqueda en cuadrícula (GridSearchCV) con validación cruzada de 5-folds, minimizando el MSE (Gráfico 3a).

Para evaluar el impacto de λ en los coeficientes del modelo, se graficó la trayectoria de los coeficientes en función de $\log(\lambda)$. Se observa que, con valores pequeños de λ , los coeficientes tienen mayor magnitud y varianza, mientras que con valores grandes tienden a reducirse a cero, lo que previene el sobreajuste, Zou y Hastie (2005), (Gráfico 3c).

El valor óptimo de λ encontrado fue de 403,7 lo que sugiere una penalización suficiente para reducir la varianza sin comprometer la capacidad predictiva del modelo, James et al. (2013), (Gráfico 3d).

⁸ Ridge Regression ayuda a controlar la multicolinealidad entre variables predictoras, distribuyendo el peso de manera equitativa y evitando la sobre-representación de cualquier variable en particular (Hoerl y Kennard, 1970).

En el Grafico 3b las variables con coeficientes positivos más altos, como L_energia, Prod_Electricidad, Com_Gasolina y Com_Indus_gas, tienen una influencia significativa en el crecimiento del IGAE. Esto indica que un aumento en la producción y consumo de energía está altamente correlacionado con un incremento en la actividad económica, lo que concuerda con la literatura sobre la relación entre el sector energético y el crecimiento económico (Hamilton, 2009).

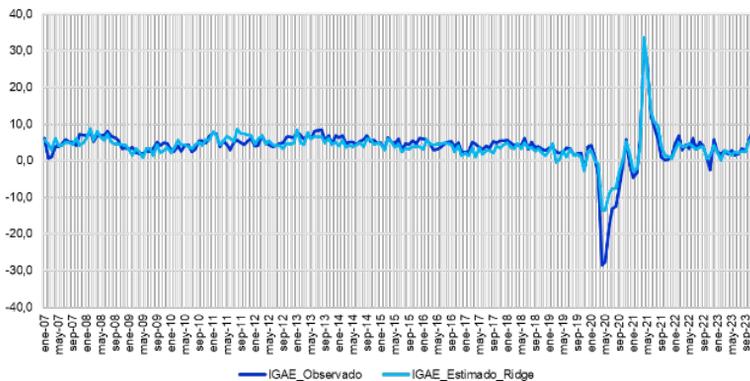
Por otro lado, las variables con coeficientes negativos, como Déficit Fiscal, Depósitos_ME y ipc_impor, sugieren que un aumento en estos factores está asociado a una reducción en la actividad económica. Esto puede explicarse por efectos contractivos en la inversión productiva, restricciones en la liquidez o caídas en el consumo interno.

Las variables con coeficientes cercanos a cero tienen un impacto marginal en el IGAE, lo que sugiere que no son determinantes clave en la predicción del crecimiento económico. Su baja contribución indica que podrían estar capturando efectos secundarios o no tener una relación directa con la variabilidad de la actividad económica.

Finalmente, la predominancia de variables relacionadas con el consumo de combustibles y electricidad en la parte superior del gráfico confirma la hipótesis de que la actividad económica depende en gran medida del suministro energético y de la infraestructura de transporte y producción. Este hallazgo es consistente con estudios previos que destacan el papel del sector energético como un motor del crecimiento macroeconómico.

Grafico 3: MODELO RIDGE

3a) Comparación IGAE observado y estimado Ridge



3b) Importancia de las variables

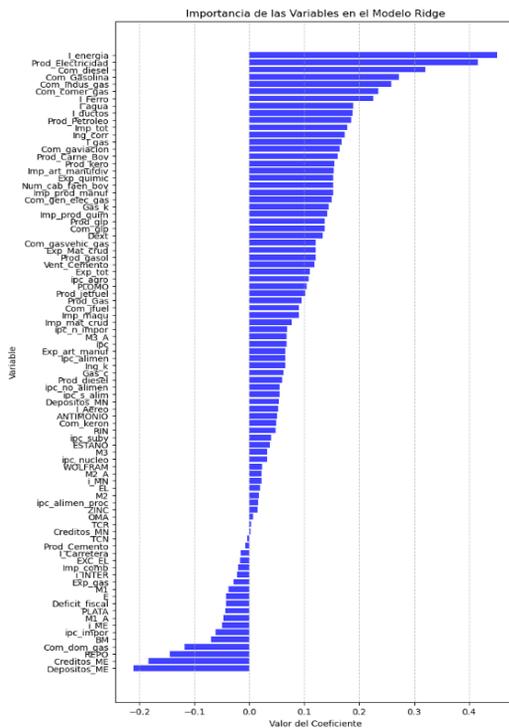
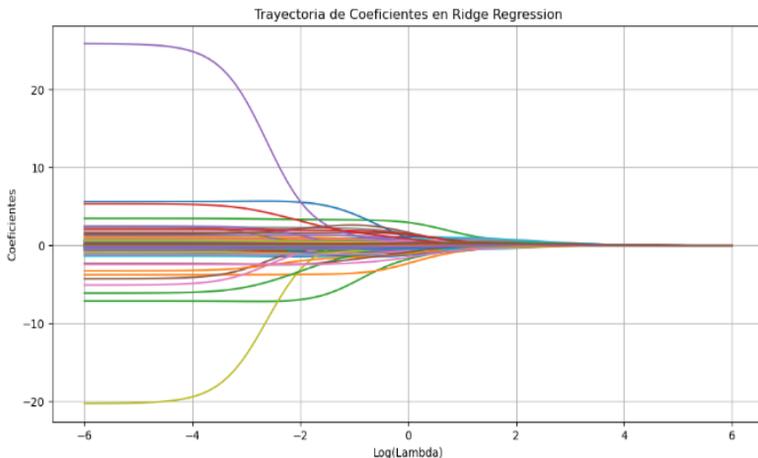
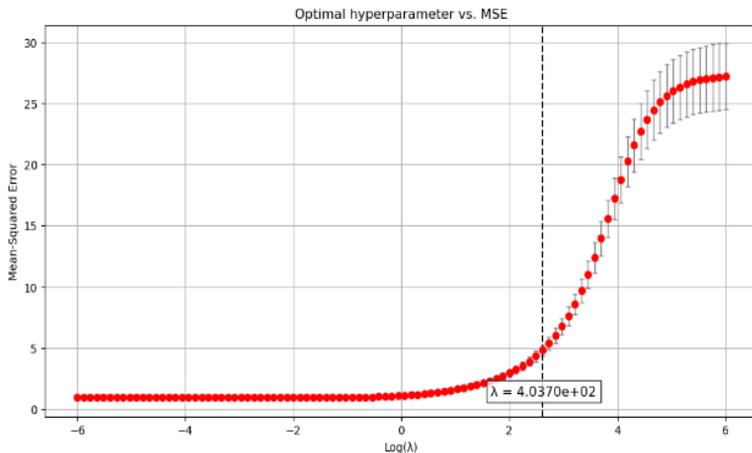


Grafico 3: MODELO RIDGE (Cont.)

3c) Trayectoria de los coeficientes



3d) Hiperparámetros óptimos vs MSE



Fuente: Elaboración propia

d. Resultados del modelo Lasso

El modelo Lasso Regression (*Least Absolute Shrinkage and Selection Operator*) fue optimizado utilizando una búsqueda en grid search con

validación cruzada (Gráfico 4a), logrando identificar el hiperparámetro óptimo $\lambda = 4,977e - 01$. Gráfico 4d). Este valor regula la penalización sobre los coeficientes, reduciendo algunos de ellos a cero (Gráfico 4c) y, por lo tanto, permitiendo una selección automática de variables relevantes en la estimación del IGAE.

El modelo Lasso es ampliamente reconocido por su capacidad de realizar selección de variables al forzar coeficientes no significativos a cero, Tibshirani (1996). Este proceso es crucial en escenarios económicos, donde la existencia de multicolinealidad entre variables puede distorsionar las estimaciones de modelos tradicionales como la regresión lineal (James et al., 2013).

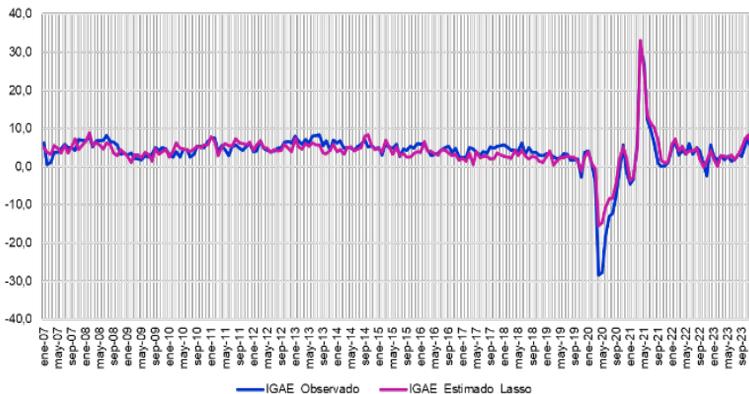
En el Gráfico 4b, se presentan los coeficientes estimados en el modelo Lasso, destacando las variables con mayor impacto en la predicción del IGAE. Las variables con coeficientes positivos más altos incluyen Com_Gasolina, Com_gasvehic_gas y Vent_Cemento, lo que indica que estos factores contribuyen significativamente al crecimiento del IGAE. Estos resultados refuerzan la hipótesis de que el consumo de combustibles y la actividad comercial e industrial desempeñan un papel clave en la dinámica económica, tal como lo han demostrado estudios previos sobre la relación entre energía y crecimiento económico (Apergis y Payne, 2010).

Por otro lado, las variables con coeficientes negativos más altos, como Depósitos_ME y Déficit_Fiscal entre otros, muestran una relación inversa con el IGAE. Esto sugiere que un aumento en los depósitos en moneda extranjera o en el déficit fiscal podría estar asociado con una contracción económica, posiblemente debido a restricciones en la liquidez o menor inversión productiva. Estos hallazgos son consistentes con estudios previos que analizan el impacto de la dolarización y los ciclos de crédito en la estabilidad macroeconómica (Mendoza y Terrones, 2008).

Finalmente, el modelo Lasso ha reducido a cero algunos coeficientes, eliminando variables irrelevantes y mejorando la interpretación del modelo. Esto sugiere que un subconjunto específico de factores es suficiente para explicar la variabilidad del IGAE, lo que valida la capacidad de Lasso para seleccionar variables relevantes en entornos macroeconómicos complejos.

Grafico 4: MODELO LASSO

4a) Comparación IGAE observado y estimado Lasso



4b) Importancia de las variables

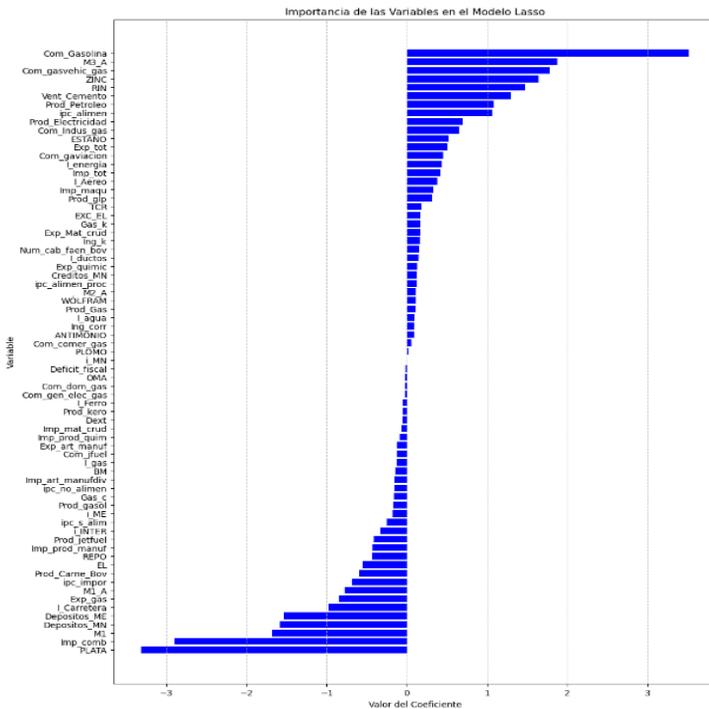
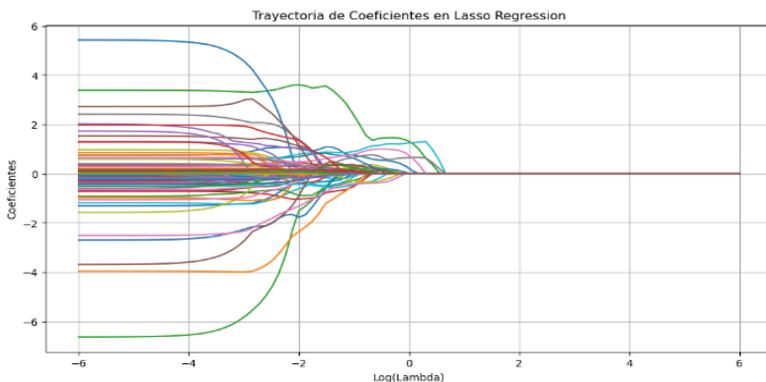
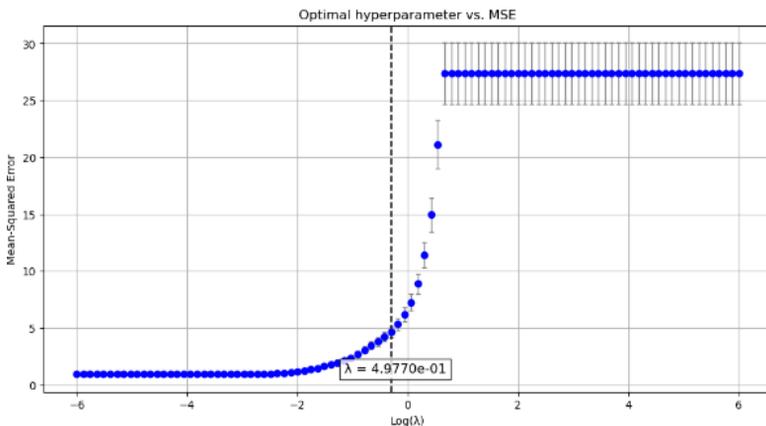


Grafico 4: MODELO LASSO (Cont.)

4c) Trayectoria de los coeficientes



4d) Hiperparámetros óptimos vs MSE



Fuente: Elaboración propia

e. Resultados del modelo Lasso adaptativo

El modelo Lasso adaptativo selecciona automáticamente las variables más relevantes, reduciendo a cero aquellas de menor impacto (Grafico 5a). Se optimizaron los hiperparámetros mediante validación cruzada (GridSearchCV), lo que permitió mejorar la selección de variables y evitar el sobreajuste.

El gráfico de trayectoria de coeficientes revela que, conforme aumenta la penalización $\log(\lambda)$, ciertos coeficientes se reducen a cero, eliminando variables redundantes o irrelevantes (Gráfico 5c). Este proceso mejora la interpretabilidad del modelo y evita el sobreajuste (Tibshirani, 1996).

El modelo encontró un valor óptimo de $\lambda = 0,007565$, un factor de adaptación de 2 y el método de normalización de pesos e inició con un $\lambda = 0,01$ que equilibra la regularización con la precisión predictiva. La curva de error cuadrático medio (MSE) confirma que este punto minimiza el error sin sobreajustar (Gráfico 5d).

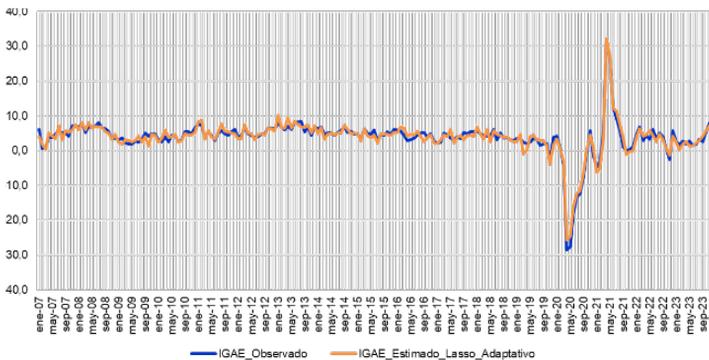
En el Gráfico 5b, se presenta la importancia de las variables en la estimación del IGAE, destacando aquellas con mayor impacto positivo y negativo en la actividad económica. Las variables con coeficientes positivos más altos, como Vent_Cemento, Com_gasvehic_gas y Prod_Electricidad, sugieren que un aumento en la actividad comercial, la demanda de materiales y la producción energética tiene un efecto expansivo sobre el IGAE. Estos resultados reflejan la relación positiva entre el desarrollo del comercio, la construcción y la producción industrial con el crecimiento económico, lo que concuerda con estudios previos que identifican a estos sectores como impulsores clave del desarrollo macroeconómico (Stock y Watson, 2020).

Por otro lado, las variables con coeficientes negativos más altos, como Depósitos_ME, Déficit Fiscal y Crédito, indican que un incremento en estas variables puede estar asociado con una menor actividad económica. Estos resultados son coherentes con la literatura macroeconómica, donde se ha demostrado que la acumulación de deuda y las distorsiones en el crédito pueden generar desequilibrios en la actividad económica (Mendoza y Terrones, 2008).

Finalmente, las variables con coeficientes cercanos a cero han sido identificadas por el modelo como irrelevantes en la predicción del IGAE. Esta es una característica clave de los modelos regularizados que permiten reducir la dimensión y mejorar la estabilidad del modelo, eliminando aquellas variables que no aportan información significativa para la estimación.

Gráfico 5: MODELO LASSO ADAPTATIVO

5a) Comparación IGAE observado y estimado Lasso Adaptativo



5b) Importancia de las variables

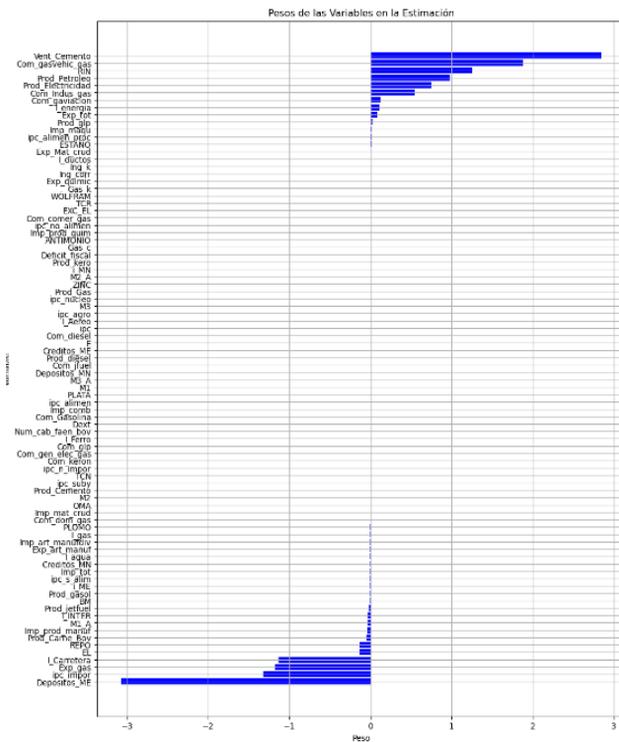
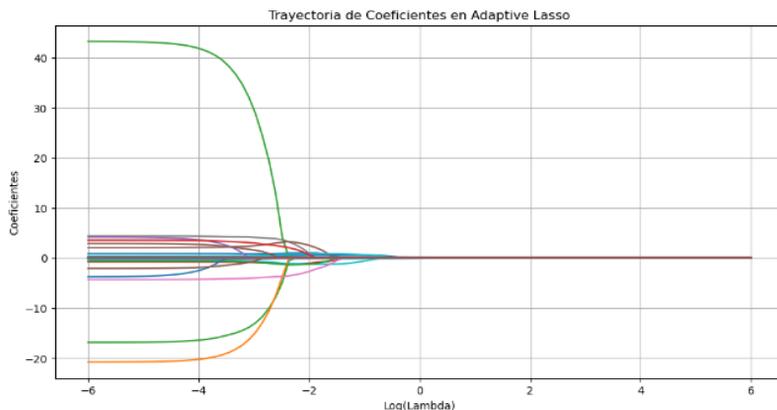
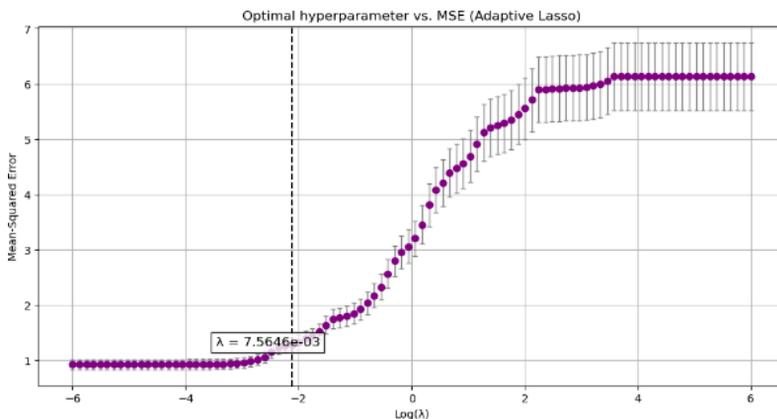


Grafico 5: MODELO LASSO ADAPTATIVO (Cont.)

5c) Trayectoria de los coeficientes



5d) Hiperparámetros óptimos vs MSE



Fuente: Elaboración propia

f. Resultados del modelo Elastic net

El modelo Elastic Net combina las penalizaciones de Lasso (L1) y Ridge (L2), controladas por los hiperparámetros (λ) y $L1_ratio$. El hiperparámetro (λ) regula la intensidad de la penalización, donde valores más altos incrementan la regularización y pueden forzar coeficientes más pequeños.

o incluso a cero. El $L1_ratio$ controla la proporción entre la penalización L1 y L2, donde valores cercanos a 1 favorecen la selección de variables, similar a Lasso, mientras que valores más cercanos a 0 favorecen la regularización de *Ridge*, que distribuye los coeficientes sin anularlos por completo (Grafico 6a).

Para este ejercicio se realizó la búsqueda de hiperparámetros mediante *GridSearchCV* que determinó que los valores óptimos son $\lambda = 0,42919$ y $L1_ratio = 0,5$, lo que indica un equilibrio entre la selección de variables y la reducción del sobreajuste (Grafico 6d).

ElasticNet tiende a asignar pesos nulos a variables que no contribuyen significativamente a la predicción. Esto se debe a la penalización L1, que introduce un mecanismo de selección automática de variables al forzar algunos coeficientes a cero. En este caso, las variables con peso cero pueden corresponder a aquellas con alta colinealidad con otras variables más significativas o a aquellas cuya relación con el IGAE es débil o inconsistente en el tiempo. Según Zou y Hastie (2005), este efecto de *sparsity* permite mejorar la interpretación del modelo y reducir la complejidad sin afectar la precisión predictiva.

El análisis de la trayectoria de los coeficientes sugiere que las variables con mayor peso en la estimación incluyen factores relacionados con la producción eléctrica y el comercio. Se observa que, a medida que se incrementa el valor de la penalización (λ), algunos coeficientes se reducen a cero, destacando la capacidad de *ElasticNet* para realizar selección de variables y evitar el sobreajuste. Esto permite que el modelo retenga solo aquellas variables con mayor capacidad explicativa y descartar aquellas que generan ruido o redundancia (Grafico 6c).

En el Grafico 6b, se observa la importancia de las variables con coeficientes positivos más altos, que explican, en mayor medida, el crecimiento del IGAE e incluyen: *Prod_Electricidad* (Producción de electricidad), *Com_Gasolina* (Consumo de gasolina), *Com_Diesel* (Consumo de diésel), *Com_Indust_gas* (Consumo industrial de gas), *Prod_Petróleo* (Producción de petróleo), *Com_comer_gas* (Consumo comercial de gas). Estos resultados reflejan la importancia del sector energético en la actividad económica. La fuerte relación positiva entre producción de electricidad y combustibles con el IGAE es consistente con la literatura sobre crecimiento económico basado en el consumo energético (Apergis y Payne, 2010).

Las variables con coeficientes negativos más altos, que pueden estar asociadas con efectos contractivos en la economía, incluyen: Depósitos y Créditos_ME y Reportos. Esto sugiere que desequilibrios en el sistema financiero reducirían el consumo y la inversión. Estos resultados concuerdan con la literatura sobre crisis de liquidez y shocks financieros en economías emergentes (Mendoza y Terrones, 2008).

Las variables con coeficientes cercanos a cero han sido consideradas irrelevantes por el modelo en la predicción del IGAE. Esto es una ventaja de los modelos regularizados ya que permiten reducir la dimensión, mejorando la interpretación y estabilidad de la estimación.

Grafico 6: MODELO ELASTIC NET

6a) Comparación IGAE observado y estimado Elastic Net

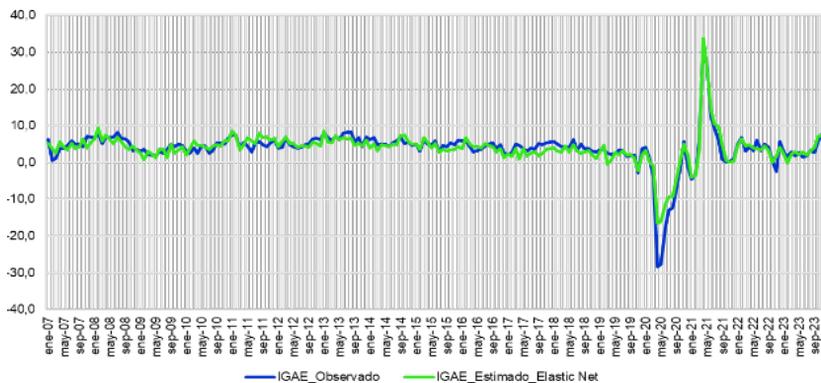
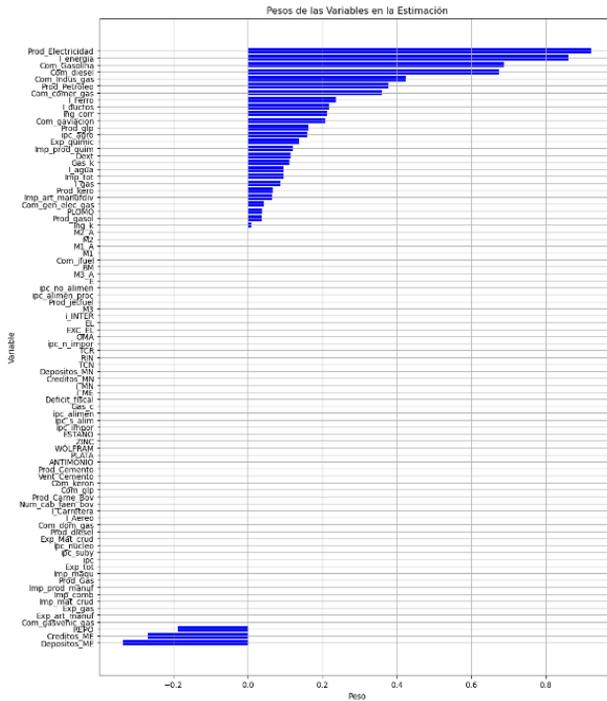


Grafico 6: MODELO ELASTIC NET (Cont.)

6b) Importancia de las variables



6c) Trayectoria de los coeficientes

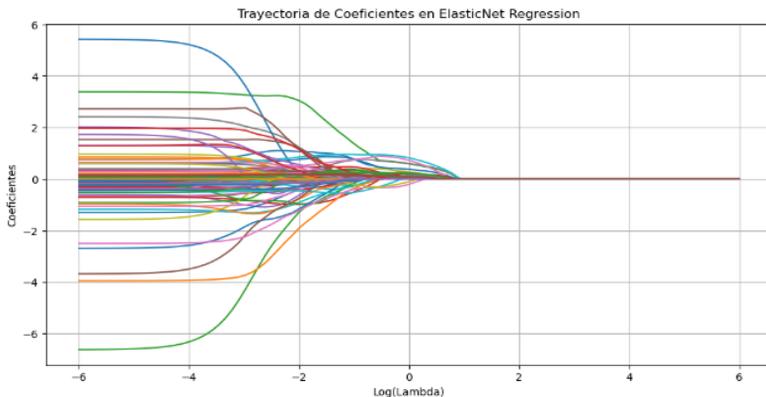
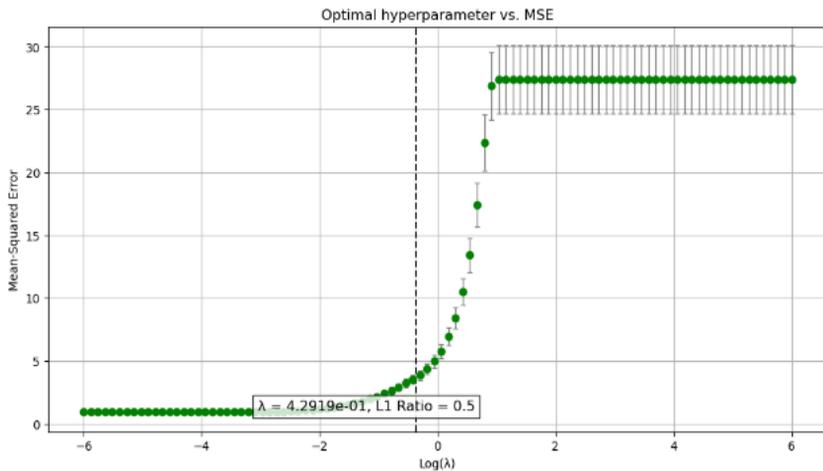


Grafico 6: MODELO ELASTIC NET (Cont.)**6d) Hiperparámetros óptimos vs MSE**

Fuente: Elaboración propia

g. Resultados del Modelo Random Forest

Se emplea un modelo de *Random Forest* (Bosques Aleatorios) para estimar la tasa de crecimiento del IGAE. Esta técnica de ensamble, basada en árboles de decisión, es robusta frente a datos ruidosos y permite capturar interacciones complejas entre las variables predictoras (Grafico 7a).

Se presenta la evolución del MSE en función del número de árboles, mostrando que, con 200 árboles, el error es relativamente bajo, lo que indica que el modelo es eficiente con una cantidad reducida de árboles. Un incremento de hasta 300 árboles genera un aumento en el error, probablemente debido al sobreajuste en la validación cruzada, y a partir de 350 árboles el MSE comienza a disminuir. Alcanzando a 400 árboles, lo que sugiere que no necesariamente aumenta a una mayor cantidad de árboles, mejora la estabilidad del modelo (Grafico 7c).

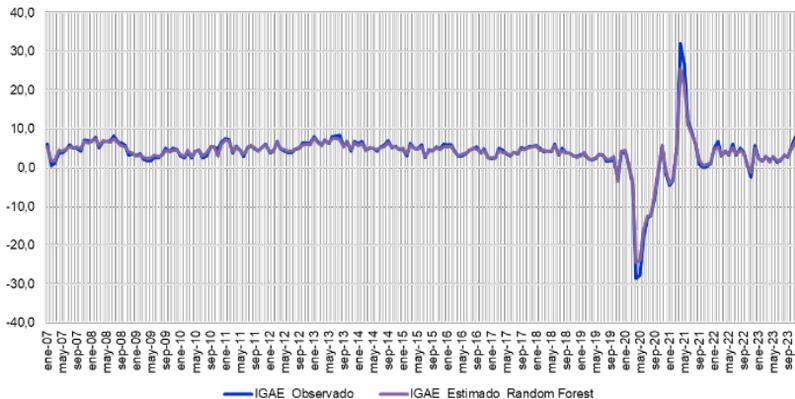
El Gráfico 7b muestra la importancia relativa de cada variable en la predicción del IGAE, destacando que Com_Gasolina, Com_Fuel, y Carretera son las variables con mayor peso en la predicción, reflejando

la fuerte relación entre transporte, consumo de combustibles y actividad económica. Prod_Electricidad y Com_Indust_gas también tienen un impacto significativo, lo que concuerda con la literatura sobre la relación entre energía y crecimiento económico (Apergis y Payne, 2010) y las variables financieras como Depósitos_ME y Créditos_ME tienen pesos negativos.

El modelo *Random Forest* ha demostrado ser una herramienta efectiva para la predicción del IGAE, capturando dinámicas no lineales y proporcionando estimaciones precisas incluso en contextos de alta volatilidad.

Grafico 7: MODELO RANDOM FOREST

7a) Comparación IGAE observado y estimado *Random Forest*



h. Resultados del modelo Gradient Boosting

El modelo *Gradient Boosting* es un modelo ampliamente utilizado en macroeconomía y finanzas debido a su capacidad para capturar relaciones no lineales y manejar conjuntos de datos con alta dimensionalidad. A diferencia de modelos tradicionales como la regresión lineal, *Gradient Boosting* ajusta secuencialmente árboles de decisión para reducir el error residual, optimizando la capacidad predictiva del modelo (Gráfico 8a).

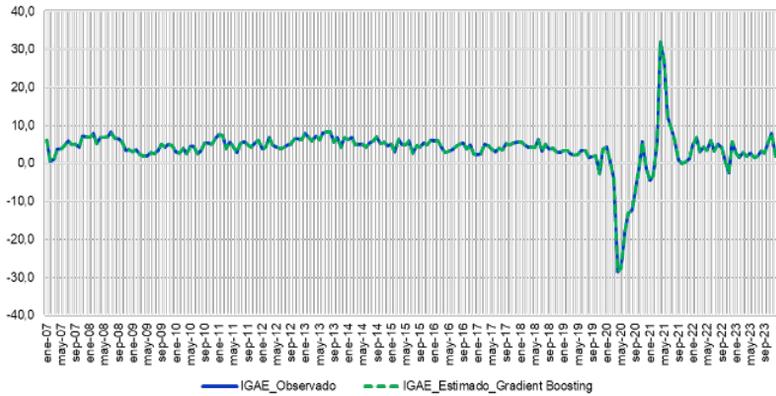
La evolución del MSE, en función del número de árboles, muestra que con 50 estimadores el error es alto debido a una insuficiente complejidad del modelo (*underfitting*). A partir de 100 estimadores, el MSE disminuye significativamente, indicando una mejor capacidad predictiva; con 200 o más estimadores, el MSE se aproxima a cero, lo que sugiere un ajuste óptimo; y, por último, el valor óptimo de 400 estimadores confirma la estabilidad del modelo, evitando sobreajuste (Gráfico 8c).

En el Gráfico 8b, se muestra la importancia relativa de cada variable en la predicción del IGAE, donde *I_carretera*, *Com_Gasolina*, *Prod_Electricidad* y *Prod_cemento* son los principales predictores, lo que resalta la fuerte relación entre energía y crecimiento económico. Asimismo, *Exp_Mat_crud* y *Com_gasVehic_gas* también tienen una influencia significativa, reflejando la importancia del comercio y la actividad industrial. Estos hallazgos son consistentes con la literatura sobre el papel de la energía y el crédito en la actividad económica.

Algunas variables presentan una importancia muy baja, lo que sugiere que no contribuyen significativamente al modelo. Esto puede deberse a una baja correlación con la variable objetivo o a que su información ya está capturada por otras variables con mayor peso.

Grafico 8: MODELO GRADIENT BOOSTING

8a) Comparación IGAE observado y estimado Gradient Boosting



8b) Importancia de las variables

Importancia de las Variables en Gradient Boosting

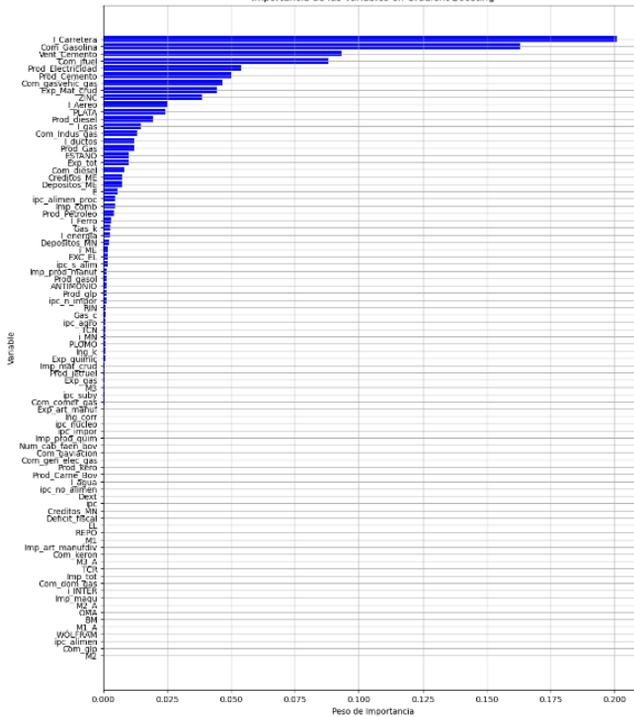
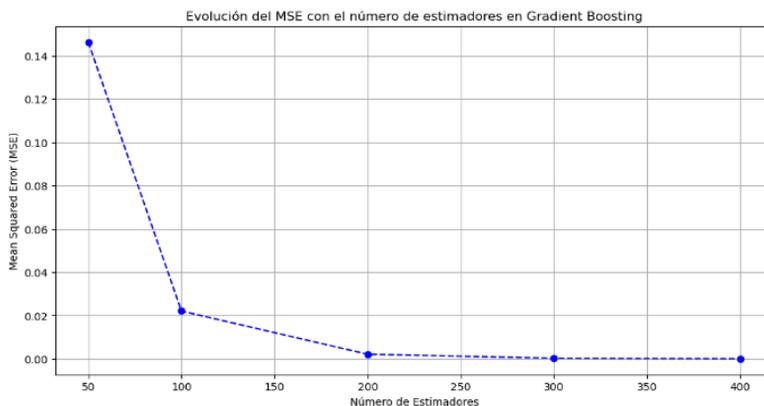


Grafico 8: MODELO GRADIENT BOOSTING (Cont.)**8c) Número de estimadores vs MSE**

Fuente: Elaboración propia

i. Resultados del modelo SVR

En este estudio, se implementa un modelo de Support Vector Regression con un kernel lineal para la predicción del IGAE, aprovechando su capacidad de generalización y robustez frente al ruido presente en los datos (Gráfico 9a).

Con el fin de optimizar el rendimiento del modelo, se llevó a cabo un proceso de ajuste de hiperparámetros mediante validación cruzada, lo que permitió determinar los valores óptimos de los mismos:

- $C = 0,1$: Controla la penalización por errores; valores más bajos reducen el sobreajuste.
- $\epsilon = 0,1$: Define la tolerancia para considerar una predicción como correcta.
- $\text{kernel} = \text{lineal}$ debido a la alta dimensión y la necesidad de interpretación.

Estos valores fueron seleccionados para balancear la precisión y la estabilidad del modelo, evitando el sobreajuste en muestras pequeñas y mejorando la generalización en datos no vistos.

En el Gráfico 9b, se presenta la importancia relativa de cada variable en la estimación del IGAE. Prod_Electricidad, BM, Com_Gasolina y Com_Indus_gas son las variables con mayor peso positivo, lo que indica que el consumo energético y la actividad industrial tienen un fuerte impacto en el crecimiento económico. Estos resultados son consistentes con los resultados de los anteriores modelos. Variables financieras como Depósitos_ME, Créditos_ME, y fiscales, como el Déficit Fiscal presentan un impacto menor.

Estos hallazgos son coherentes con estudios previos sobre la relación entre liquidez, inversión y crecimiento económico, y refuerzan la importancia de considerar tanto factores reales como financieros en modelos predictivos macroeconómicos.

Gráfico 9: MODELO SVR

9a) Comparación IGAE observado y estimado SVR

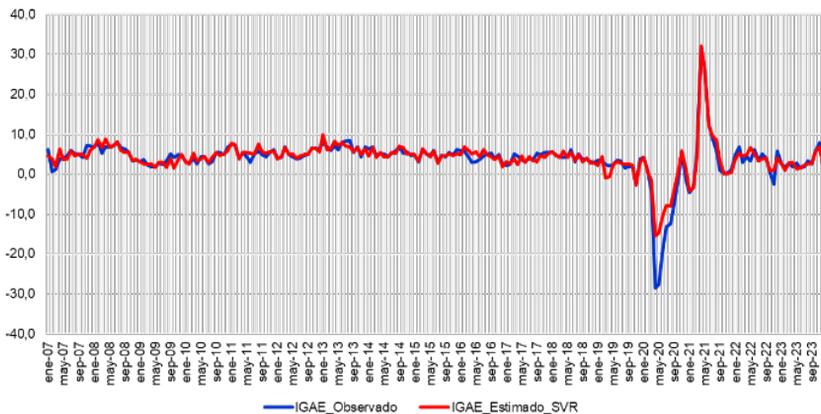
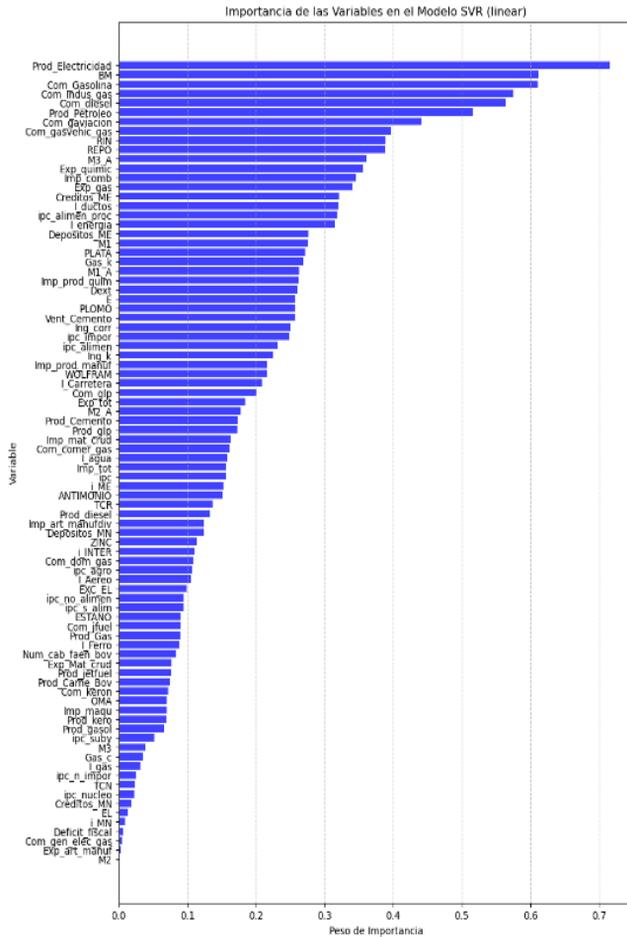


Grafico 9: MODELO SVR (Cont.)

9b) Importancia de las variables



Fuente: Elaboración propia

j. Comparación de modelos de machine learning

Los modelos fueron evaluados a través de las siguientes métricas⁹:

- MSE (*Mean Squared Error*): Medida de error cuadrático medio, donde valores más bajos indican mayor precisión.
- RMSE (*Root Mean Squared Error*): Raíz del MSE, proporcionando una interpretación directa del error en las mismas unidades que el IGAE.
- MAE (*Mean Absolute Error*): Promedio de las desviaciones absolutas entre los valores observados y predichos.
- R² (Coeficiente de Determinación): Explica la proporción de la variabilidad total capturada por el modelo.

Tabla 2: EVALUACIÓN DE LOS PRONÓSTICOS DE MODELOS Y EL IGAE OBSERVADO 2007m01-2023m12

Modelo	MSE	RMSE	MAE	R2
Ridge	4,7960	2,1900	1,3624	0,8249
Lasso	4,6586	2,1584	1,4293	0,8299
Lasso Adaptativo	1,2860	1,1340	0,9011	0,9530
ElasticNet	3,6753	1,9171	1,2907	0,8658
RandomForest	0,7214	0,8493	0,4612	0,9737
Gradient Boosting	0,0000	0,0064	0,0051	0,9999
SVR	3,3698	1,8357	0,9290	0,8769

Nota: MSE: Raíz del error cuadrático medio (RMSE, por sus siglas en inglés), RMSE: Error cuadrático medio (MSE, por sus siglas en inglés), MAE: Error absoluto medio (MAE, por sus siglas en inglés) y R2: Coeficiente de determinación

Fuente: Elaboración propia

Los modelos de regresión regularizada, *Ridge* y *Lasso*¹⁰ presentan los mayores errores, con valores de MSE superiores a 4, lo que indica que no son los métodos más adecuados para este problema. Por su parte, *Elastic Net* mejora respecto a *Ridge* y *Lasso*, gracias a la combinación de L1 y L2, lo

⁹ La explicación de las fórmulas para evaluar los modelos se encuentra en el Apéndice B.

¹⁰ Hastie et al. (2009) señalaron que *Ridge* y *Lasso* pueden no ser óptimos cuando las relaciones entre variables no son completamente lineales, lo que explica sus mayores errores en esta comparación.

que permite una mejor selección de variables sin sacrificar estabilidad. Por último, Lasso Adaptativo supera a los modelos anteriores, con un MSE de 1,2860 y un R^2 de 0,9530, lo que confirma su ventaja en problemas donde la selección de variables es clave.

Los modelos de ensamble (*Random Forest* y *Gradient Boosting*)¹¹ muestran que *Random Forest* mejora sustancialmente la precisión en comparación con los modelos de regresión regularizada, con un MSE de 0,7214 y un R^2 de 0,9737. Por su parte, *Gradient Boosting* (GBM) presenta el mejor desempeño absoluto, reduciendo drásticamente el MSE a 0,0000 y alcanzando un R^2 de 0,9999, lo que indica una capacidad predictiva excepcional.

Por su parte, el modelo SVR muestra un desempeño intermedio, con un MSE de 3,3698 y un R^2 de 0,8769, aunque supera a *Ridge* y Lasso, es menos efectivo que los métodos de ensamble, lo que sugiere que, en este caso, las técnicas basadas en árboles proporcionan un mejor ajuste a los datos macroeconómicos.

En este sentido, los resultados muestran que GBM supera a todos los demás modelos en términos de precisión predictiva, con el menor MSE, RMSE y MAE, y el mayor coeficiente R^2 .

k. Pronósticos con modelos de machine learning fuera de la muestra

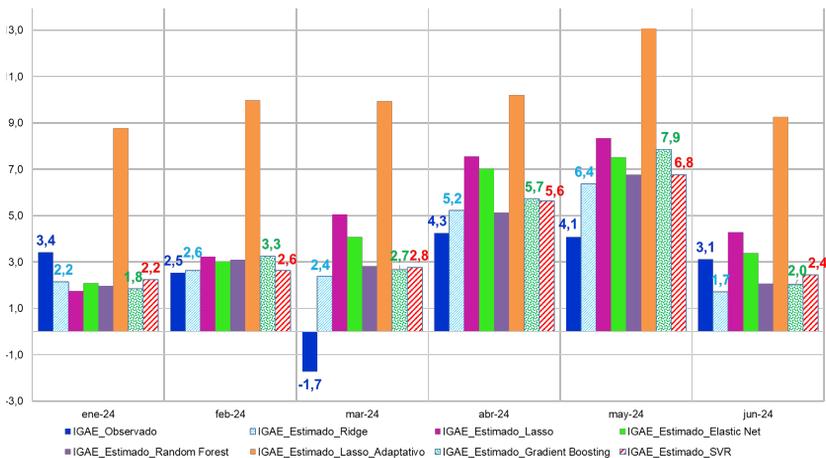
Al evaluar los resultados de los modelos de *nowcasting* aplicados al IGAE observado, se encuentra que el modelo *Gradient Boosting* es el que mejor se ajusta a las cifras reales de la actividad económica en Bolivia dentro de la muestra. Sin embargo, su capacidad predictiva disminuye fuera de la muestra, permitiendo que otros modelos se aproximen mejor al dato observado (Gráfico 10).

En particular, aunque *Gradient Boosting* presenta un MSE de 6,7 fuera de la muestra, existen dos modelos con un menor error cuadrático medio: *Ridge* y SVR (Tabla 3). Este resultado evidencia que un modelo puede tener

11 Stock y Watson (2020) demostraron que los modelos de boosting mejoran significativamente la precisión en la predicción de indicadores macroeconómicos volátiles. Friedman (2001) introdujo el concepto de Gradient Boosting, argumentando que supera a otros métodos en problemas con alta no linealidad, lo que se confirma en este estudio.

un excelente desempeño dentro de la muestra, pero no necesariamente generalizar de la misma manera fuera de ella. Por ello, es fundamental evaluar los modelos tanto dentro como fuera de la muestra para garantizar su robustez predictiva. En conclusión, los modelos de *machine learning* utilizados en este análisis demuestran ser herramientas adecuadas para el *nowcasting* del IGAE en Bolivia en tiempo real.

Grafico 10: IGAE OBSERVADO Y ESTIMACIONES DEL IGAE MEDIANTE MODELOS DE ML, 2024M01-2024M06 (Tasa de crecimiento interanual)



Fuente: Elaboración propia

Tabla 3: PRONÓSTICOS FUERA DE LA MUESTRA

Periodo	Ridge	Lasso	Lasso Adaptativo	ElasticNet	Random Forest	Gradient Boosting	SVR
MSE	4,5	13,3	62,3	9,2	5,3	6,7	5,2
RMSE	2,1	3,6	7,9	3,0	2,3	2,6	2,3
MAE	1,7	3,0	7,6	2,3	1,9	2,2	1,8

Nota: MSE: Raíz del error cuadrático medio (RMSE, por sus siglas en inglés), RMSE: Error cuadrático medio (MSE, por sus siglas en inglés) y MAE: Error absoluto medio (MAE, por sus siglas en inglés)

Fuente: Elaboración propia

V. Conclusiones

Los resultados de este estudio confirman que los modelos de machine learning constituyen una herramienta eficaz para la predicción en tiempo real del PIB, mejorando la disponibilidad de información macroeconómica y optimizando la toma de decisiones en entornos de incertidumbre. Dentro de la muestra, el modelo *Gradient Boosting* demostró ser el más preciso, alcanzando un MSE bajo, lo que refleja su capacidad para capturar con alta exactitud la dinámica de la actividad económica. No obstante, fuera de la muestra, su capacidad predictiva disminuye, permitiendo que otros modelos, como *Ridge* y *SVR*, presenten un menor error cuadrático medio (MSE). Este hallazgo subraya la importancia de evaluar la estabilidad y generalización de los modelos más allá del ajuste en la muestra.

El análisis se basó en un conjunto de 87 variables macroeconómicas que abarcan indicadores del sector real, financiero, externo, monetario y fiscal, con una cobertura temporal de enero de 2007 a diciembre de 2023. La utilización de datos de alta frecuencia permitió capturar con mayor precisión las fluctuaciones económicas en tiempo real, mejorando la capacidad predictiva de los modelos aplicados.

Asimismo, los resultados indican que las variables con mayor impacto en la predicción del PIB incluyen producción de electricidad, consumo de gasolina, consumo industrial de gas, ventas de cemento y exportación de materias primas, lo que pone de manifiesto la estrecha relación entre el crecimiento económico y los sectores energético y comercial, en concordancia con la literatura macroeconómica.

En términos metodológicos, los modelos de regresión penalizada (*Ridge*, *Lasso* y *Elastic Net*) lograron capturar relaciones significativas entre las variables económicas, aunque su capacidad predictiva resultó inferior en comparación con los modelos basados en árboles de decisión. Sin embargo, el modelo *Lasso* Adaptativo mostró una mejora en la selección de variables clave, lo que sugiere que su integración con técnicas más avanzadas podría optimizar el rendimiento predictivo. Por otro lado, los modelos basados en árboles de decisión, particularmente *Gradient Boosting*, demostraron un desempeño superior en la predicción del PIB dentro de la muestra, lo que respalda su uso en contextos de *nowcasting* económico.

Dado el rendimiento sobresaliente de los métodos de ensamble, se recomienda explorar enfoques híbridos que combinen machine learning con modelos econométricos tradicionales, con el objetivo de mejorar la robustez y estabilidad de las estimaciones. Asimismo, la incorporación de fuentes de datos adicionales, como información no estructurada, big data o datos satelitales, podría fortalecer aún más la capacidad predictiva de los modelos, especialmente en escenarios de alta volatilidad económica.

Finalmente, la aplicación de estos modelos en el diseño de políticas económicas podría contribuir significativamente a la generación de estimaciones más precisas y oportunas del PIB, permitiendo una respuesta más ágil y fundamentada ante cambios en la actividad económica. En conclusión, los métodos de *machine learning* analizados en este estudio ofrecen una alternativa sólida y confiable para el nowcasting del PIB en Bolivia, proporcionando herramientas analíticas avanzadas que pueden mejorar sustancialmente la toma de decisiones económicas en tiempo real.

Referencias bibliográficas

ANTOLIN-DIAZ, Juan, DRECHSEL, Thomas and PETRELLA, Iván, 2021. Advances in Nowcasting Economic Activity: Secular Trends, Large Shocks and New Data. Centre for Economic Policy Research, Discussion Paper No. 15926, July. Disponible en: <https://repec.cepr.org/repec/cpr/ceprdp/DPI5926.pdf>

APERGIS, Nicholas and PAYNE, James, 2010. Renewable energy consumption and economic growth: Evidence from a panel of 10 OECD countries. *Energy Policy*, 38 (1), pp. 656 - 660. ISSN en línea: 1873-6777. Disponible en: <https://doi.org/10.1016/j.enpol.2009.09.002>

ARRO-CANNARSA, Milen and SCHEUFELE, Rolf, 2024. Nowcasting GDP: what are the gains from machine learning algorithms? Schweizerische National Bank, SNB Working Paper 2024-06, June. Disponible en: https://www.snb.ch/public/publication/en/www-snb-ch/publications/research/working-papers/2024/working_paper_2024_06/0_en/working_paper_2024_06.pdf

BABII, Andrii, GHYSELS, Eric and STRIAUKAS, Jonas, 2021. Machine Learning Time Series Regressions With an Application to Nowcasting. *Journal of Business & Economic Statistics*, 40 (3), pp. 1094 – 1106. ISSN online: 15372707. Disponible en: <https://doi.org/10.1080/07350015.2021.1899933>

BAÑBURA, Marta, GIANNONE, Domenico and REICHLIN, Lucrezia, 2010. Large Bayesian vector auto regressions. *Journal of Applied Econometrics*, 25 (1), pp. 71 - 92. ISSN en línea: 1099-1255. Disponible en: <https://doi.org/10.1002/jae.1137>

BARRIOS, Juan, ESCOBAR, Julia, LESLIE, Janelle, MARTIN, Lucia y PEÑA, Werner, 2021. 2021. Nowcasting to Predict Economic Activity in Real Time: The Cases of Belize and El Salvador. Banco Interamericano de Desarrollo (BID), IDB Monograph 970. Disponible en: <https://publications.iadb.org/en/nowcasting-predict-economic-activity-real-time-cases-belize-and-el-salvador>

BOK, Brandyn, CARATELLI, Daniele, GIANNONE, Domenico, SBORDONE, Argia and TAMBALOTTI, Andrea, 2018. Macroeconomic Nowcasting and

Forecasting with Big Data. *Annual Review of Economics*, 10, pp. 615 - 643. ISSN en línea: 1941-1391. Disponible en: <https://doi.org/10.1146/annurev-economics-080217-053214>

BOLIVAR, Osmar, 2024. GDP nowcasting: A machine learning and remote sensing data-based approach for Bolivia. *Latin American Journal of Central Banking*, 5 (3). ISSN en línea: 2666-1438. Disponible en: <https://doi.org/10.1016/j.latcb.2024.100126>

BREIMAN, Leo, 2001. Random Forests. *Machine Learning*, 45, pp. 5 - 32. ISSN en línea: 1573-0565. Disponible en: <https://link.springer.com/article/10.1023/a:1010933404324>

CASCALDI-GARCIA, Danilo, LUCIANI, Matteo and MODUGNO, Michele, 2024. Lessons from nowcasting GDP across the world. En: CLEMENTS, Michael and GALVÃO, Ana, eds. *Handbook of Research Methods and Applications in Macroeconomic Forecasting*. United Kingdom: Edward Elgar Publishing Limited, pp. 187 - 217. ISBN 978 1 0353 1004 3

CROUSHORE, Dean and STARK, Tom, 2001. A real-time data set for macroeconomists. *Journal of Econometrics*, 105 (1), pp. 111 - 130. ISSN en línea: 1872-6895. Disponible en: [https://doi.org/10.1016/S0304-4076\(01\)00072-0](https://doi.org/10.1016/S0304-4076(01)00072-0)

DAUPHIN, Jean-François, DYBCZAK, Kamil, MANEELY, Morgan, SANJANI, Marzie, SUPHAPHIPHAT, Nujin, WANG, Yifei and ZHANG, Hanqi, 2022. Nowcasting GDP. A Scalable Approach Using DFM, Machine Learning and Novel Data, Applied to European Economies. *International Monetary Fund, Working Paper WP/22/52*, March. Disponible en: <https://www.imf.org/-/media/Files/Publications/WP/2022/English/wpia2022052-print-pdf.ashx>

DROOGH, Bob, 2022. Nowcasting US GDP growth using Machine Learning: a real-time application. *Erasmus University Rotterdam, Quantitative Finance – Master Thesis*, February. Disponible en: https://www.google.com/url?sa=t&source=web&rct=j&opi=89978449&url=https://thesis.eur.nl/pub/62149/Msc__Thesis-Bob-Droogh.pdf&ved=2ahUKEwi8_PK-wc uNAXWaJrkGHc0zGcwQFnoECBkQAQ&usg=AOvVaw0nii--6CDj7mq_ZEbwUPPM

FERRARA, Laurent and SIMONI, Anna, 2020. When are Google data useful to nowcast GDP? An approach via pre-selection and shrinkage. Université Paris Nanterre, *EconomiX Working Paper 2020-11*, December. Disponible en: https://economix.fr/pdf/dt/2020/WP_EcoX_2020-11.pdf

FLORES, Jairo, GONZAGA, Bruno, RUELAS-HUANCA, Walter and TANG, Juan, 2024. Nowcasting Peruvian GDP with Machine Learning Methods. Banco Central de Reserva del Perú, Documento de trabajo DT. N°. 2024-019, diciembre. Disponible en: <https://investigacion.bcrp.gob.pe/es/ebooks/313-ES>

FRANKEL, Jeffrey and ROMER, David, 1999. Does Trade Cause Growth? *The American Economic Review*, 89 (3), pp. 379 - 399. ISSN en línea: 1944-7981. Disponible en: <https://doi.org/10.1257/aer.89.3.379>

FRIEDMAN, Jerome, 2001. Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29 (5), pp. 1189 - 1232. ISSN en línea: 21688966. Disponible en: <https://www.jstor.org/stable/2699986>

GIANNONE, Domenico, REICHLIN, Lucrezia and SMALL, David, 2008. Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, 55 (4), pp. 665 - 676. ISSN en línea: 1873-1295. Disponible en: <https://doi.org/10.1016/j.jmoneco.2008.05.010>

GONZÁLEZ-ASTUDILLO, Manuel y BAQUERO, Daniel, 2019. A Nowcasting Model for Ecuador: Implementing a Time-Varying Mean Output Growth. *Economic Modelling*, 82 (C), pp. 250 - 263. ISSN en línea: 1873-6122. Disponible en: <https://doi.org/10.1016/j.econmod.2019.01.010>

HAMILTON, James, 2009. Causes and Consequences of the Oil Shock of 2007-08. *Brookings Papers on Economic Activity*, 2009 (Spring), pp. 215 - 261. Disponible en: <https://www.brookings.edu/articles/causes-and-consequences-of-the-oil-shock-of-2007-08/>

HASTIE, Trevor, TIBSHIRANI, Robert and FRIEDMAN, Jerome, 2009. *The Elements of Statistical Learning. Data Mining, Inference, and Prediction*. 2nd edition. New York: Springer Science+Business Media, LLC. ISBN 978-0-387-84857-0

HOERL, Arthur and KENNARD, Robert, 1970. Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometrics*, 12 (1), pp. 55 - 67. ISSN en línea 15372723. Disponible en: <https://doi.org/10.1080/00401706.1970.10488634>

HOPP, Daniel, 2022. Benchmarking Econometric and Machine Learning Methodologies in Nowcasting. arXiv:2205.03318. Disponible en: <https://doi.org/10.13140/RG.2.2.13344.87042>

JAMES, Gareth, WITTEN, Daniela, HASTIE, Trevor and TIBSHIRANI, Robert, 2013. *An Introduction to Statistical Learning, with applications in R*. New York: Springer Science+Business Media, LLC. ISBN 978-1-4614-7137-0

KANT, Dennis, PICK, Andreas and DE WINTER, Jasper, 2022. Nowcasting GDP Using Machine Learning Methods. De Nederlandsche Bank, Working Paper No. 754, November. Disponible en: https://www.dnb.nl/media/kq4pe4cr/working_paper_no_754.pdf

KANT, Dennis, PICK, Andreas and De WINTER, Jasper, 2024. Nowcasting GDP using machine learning methods. *AStA Advances in Statistical Analysis*, 109, pp. 1 - 24. ISSN en línea: 1863-818X. Disponible en: <https://doi.org/10.1007/s10182-024-00515-0>

KING, Robert and LEVINE, Ross, 1993. Finance and Growth: Schumpeter Might be Right. *The Quarterly Journal of Economics*, 108 (3), pp. 717 - 737. ISSN en línea: 1531-4650. Disponible en: <https://doi.org/10.2307/2118406>

KOČENDA, Evžen and POGHOSYAN, Karen, 2020. Nowcasting Real GDP Growth: Comparison between Old and New EU Countries. *Eastern European Economics*, 58 (3), pp. 197 - 220. ISSN en línea: 1557-9298. Disponible en: <https://doi.org/10.1080/00128775.2020.1726185>

LEE, Torng-Her and MSEFULA, Griffin, 2024. Predicting GDP with machine learning technique. *International Journal of Business & Management Studies*, 05 (08), pp. 35 - 46. ISSN en línea: 2694-1449. Disponible en: <https://doi.org/10.56734/ijbms.v5n8a5>

MARCELLINO, Massimiliano and SIVEC, Vasja, 2021. Nowcasting GDP Growth in a Small Open Economy. *National Institute Economic Review*, 256, pp. 127 - 161. ISSN en línea: 1741-3036. Disponible en: <https://doi.org/10.1017/nie.2021.13>

MEDEIROS, Marcelo and VASCONCELOS, Gabriel, 2016. Forecasting macroeconomic variables in data-rich environments. *Economics Letters*, 138, pp. 50 - 52. ISSN en línea: 1873-7374. Disponible en: <https://doi.org/10.1016/j.econlet.2015.11.017>

MENDOZA, Enrique and TERRONES, Marco, 2008. An Anatomy of Credit Booms: Evidence from Macro Aggregates and Micro Data. *National Bureau of Economic Research, Working Paper 14049*, May. Disponible en: <https://www.nber.org/papers/w14049>

NAKAZAWA, Takashi, 2022. Constructing GDP Nowcasting Models Using Alternative Data. *Bank of Japan. Working Paper Series No. 22-E-9*, July. Disponible en: https://www.boj.or.jp/en/research/wps_rev/wps_2022/data/wp22e09.pdf

NARAYAN, Paresh and SMYTH, Russell, 2005. Electricity consumption, employment and real income in Australia: Evidence from multivariate Granger causality tests. *Energy Policy*, 33 (9), pp. 1109 - 1116. ISSN en línea: 1873-6777. Disponible en: <https://doi.org/10.1016/j.enpol.2003.11.010>

PINDYCK, Robert y RUBINFELD, Daniel, 2001. *Econometría: Modelos y pronósticos*. 1ra ed. en español. México D.F.: McGraw-Hill. ISBN 0-07-913292-8

RICHARDSON, Adam, VAN FLORENSTEIN, Thomas and VEHBI, Tuğrul, 2018. Nowcasting New Zealand GDP using machine learning algorithms. En: *IFC – Bank Indonesia International Workshop and Seminar on “Big Data for Central Bank Policies / Building Pathways for Policy Making with Big Data”*. Disponible en: https://www.bis.org/ifc/publ/ifcb50_15.pdf

RICHARDSON, Adam, VAN FLORENSTEIN MULDER, Thomas and VEHBI, Tuğrul, 2019. Nowcasting GDP using machine learning algorithms: A real-time assessment. *Reserve Bank of New Zealand, Discussion Paper Series DP2019/03*, November. Disponible en: <https://www.rbnz.govt.nz/-/media/>

project/sites/rbnz/files/publications/discussion-papers/2019/dp2019-03.pdf?revision=6505b3a5-634e-45bd-9938-a7af3b4317fb

RICHARDSON, Adam, VAN FLORENSTEIN, Thomas and VEHLI, Tuğrul, 2021. Nowcasting GDP using machine-learning algorithms: A real-time assessment. *International Journal of Forecasting*, 37 (2), pp. 941 - 948. ISSN en línea: 1872-8200. Disponible en: <https://doi.org/10.1016/j.ijforecast.2020.10.005>

RUSNÁK, Marek, 2016. Nowcasting Czech GDP in real time. *Economic Modelling*, 54, pp. 26 - 39. ISSN en línea: 1873-6122. Disponible en: <https://doi.org/10.1016/j.econmod.2015.12.010>

SNOEK, Jasper, LAROCHELLE, Hugo and ADAMS, Ryan, 2012. Practical Bayesian Optimization of Machine Learning Algorithms. En: PEREIRA, F., BURGESS, C. J., BOTTOU, L. and WEINBERGER, K. Q., eds., *Advances in Neural Information Processing Systems (NIPS) 25*, pp. 2951 - 2959. Disponible en: <https://proceedings.neurips.cc/paper/2012/hash/05311655a15b75fab86956663e1819cd-Abstract.html>

STERN, David, 2011. The role of energy in economic growth. *Annals of the New York Academy of Sciences*, 1219 (1), pp. 26 - 51. ISSN en línea: 1749-6632. Disponible en: <https://doi.org/10.1111/j.1749-6632.2010.05921.x>

STOCK, James and WATSON, Mark, 2002. Forecasting Using Principal Components from a Large Number of Predictors. *Journal of the American Statistical Association*, 97 (460), pp. 1167 - 1179. ISSN en línea: 1537274X. Disponible en: <https://doi.org/10.1198/016214502388618960>

STOCK, James and WATSON, Mark, 2016. Dynamic Factor Models, Factor-Augmented Vector Autoregressions, and Structural Vector Autoregressions in Macroeconomics. En: TAYLOR, John and UHLIG, Harald, eds., *Handbook of Macroeconomics, Volume 2A*. Amsterdam: Elsevier B.V., pp. 415 - 525. ISBN 978-0-444-59469-3

STOCK, James and WATSON, Mark, 2020. *Introduction to Econometrics*. 4.^a ed. Harlow: Pearson Education Limited. ISBN 9781292264455

TENORIO, Juan and PÉREZ, Wilder, 2023. GDP nowcasting with Machine Learning and Unstructured Data to Peru, Peruvian Economic Association,

Working paper No. 197, November. Disponible en: <https://perueconomics.org/wp-content/uploads/2023/11/WP-197.pdf>

TENORIO, Juan and PÉREZ, Wilder, 2024a. Monthly GDP nowcasting with Machine Learning and Unstructured Data. arXiv preprint 2402.04165v1. Disponible en: <https://doi.org/10.48550/arXiv.2402.04165>

TENORIO, Juan and PÉREZ, Wilder, 2024b. GDP nowcasting with Machine Learning and Unstructured Data, Banco Central de Reserva del Perú, Documento de trabajo 2024-003, abril. Disponible en: <https://investigacion.bcrp.gob.pe/es/ebooks/313-ES>

TENORIO, Juan y PÉREZ, Wilder, 2024c. GDP Nowcasting with Machine Learning and Unstructured Data. Banco Central de Reserva del Perú, Documento de trabajo No. 003-2024. Disponible en: <https://www.bcrp.gob.pe/docs/Publicaciones/Documentos-de-Trabajo/2024/documento-de-trabajo-003-2024.pdf>

TIBSHIRANI, Robert, 1996. Regression Shrinkage and Selection Via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58 (1), pp. 267 - 288. ISSN en línea: 1467-9868. Disponible en: <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>

ZHANG, Cun-Hui, 2010. Nearly unbiased variable selection under minimax concave penalty. *The Annals of Statistics*, 38 (2), pp. 894 - 942. ISSN en línea: 2168-8966. Disponible en: <https://doi.org/10.1214/09-AOS729>

ZOU, Hui and HASTIE, Trevor, 2005. Regularization and Variable Selection Via the Elastic Net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67 (2), pp. 301 - 320. ISSN en línea: 1467-9868. Disponible en: <https://doi.org/10.1111/j.1467-9868.2005.00503.x>

No.	Código	Variable	Unidad de medida	Frecuencia	Fuente
Indicador Principal					
Precios					
50	ipc	Índice de Precios al Consumidor	Índice	Mensual	INE
51	ipc_suby	Índice de Precios al Consumidor subyacente	Índice	Mensual	BCB
52	ipc_nucleo	Índice de Precios al Consumidor núcleo	Índice	Mensual	BCB
53	ipc_s_alm	Índice de Precios al Consumidor sin alimentos	Índice	Mensual	BCB
54	ipc_impor	Índice de Precios al Consumidor importado	Índice	Mensual	BCB
55	ipc_n_impor	Índice de Precios al Consumidor no importado	Índice	Mensual	BCB
56	ipc_alimen	Índice de Precios al Consumidor alimentos	Índice	Mensual	BCB
57	ipc_agro	Índice de Precios al Consumidor agropecuario	Índice	Mensual	BCB
58	ipc_alimen_proc	Índice de Precios al Consumidor alimentos procesados	Índice	Mensual	BCB
59	ipc_no_alimen	Índice de Precios al Consumidor no alimentos	Índice	Mensual	BCB
Monetario					
60	E	Emisión monetaria	Millones de bolivianos	Mensual	BCB
61	BM	Base monetaria	Millones de bolivianos	Mensual	BCB
62	M1	Agregado monetario M1	Millones de bolivianos	Mensual	BCB
63	M1_A	Agregado monetario M1'	Millones de bolivianos	Mensual	BCB
64	M2	Agregado monetario M2	Millones de bolivianos	Mensual	BCB
65	M2_A	Agregado monetario M2'	Millones de bolivianos	Mensual	BCB
66	M3	Agregado monetario M3	Millones de bolivianos	Mensual	BCB
67	M3_A	Agregado monetario M3'	Millones de bolivianos	Mensual	BCB
68	EL	Encaje legal	Millones de bolivianos	Mensual	BCB
69	EXC_EL	Excedente de encaje legal	Millones de bolivianos	Mensual	BCB
70	OMA	Operaciones de Mercado Abierto	Millones de bolivianos	Mensual	BCB
71	REPO	Operaciones de repo BCB	Porcentaje	Mensual	BCB
Externo					
72	TCR	Índice del tipo de cambio real	Índice base 2003=100	Mensual	BCB
73	Dext	Deuda externa	Millones de dólares	Mensual	BCB
74	RN	Reservas internacionales netas	Millones de dólares	Mensual	BCB
75	TCN	Tipo de cambio nominal	Bs/Sus	Mensual	BCB
Financiero					
76	i_INTER	Tasa de operaciones interbancarias	Porcentaje	Mensual	BCB
77	Depositos_MN	Depósitos en moneda nacional	Millones de bolivianos	Mensual	ASFI
78	Depositos_ME	Depósitos en moneda extranjera	Millones de bolivianos	Mensual	ASFI
79	Creditos_MN	Créditos en moneda nacional	Millones de bolivianos	Mensual	ASFI
80	Creditos_ME	Créditos en moneda extranjera	Millones de bolivianos	Mensual	ASFI
81	i_MN	Tasa de interés en moneda nacional	Porcentaje	Mensual	BCB
82	i_ME	Tasa de interés en moneda extranjera	Porcentaje	Mensual	BCB
Fiscal					
83	Deficit_fiscal	Deficit fiscal del Sector Público No Financiero (SPNF)	Millones de bolivianos	Mensual	MEFP
84	Ing_corr	Ingresos corrientes del SPNF	Millones de bolivianos	Mensual	MEFP
85	Ing_k	Ingresos de capital del SPNF	Millones de bolivianos	Mensual	MEFP
86	Gas_c	Gastos corrientes del SPNF	Millones de bolivianos	Mensual	MEFP
87	Gas_k	Gastos de capital del SPNF	Millones de bolivianos	Mensual	MEFP

Apéndice B: Estrategia de evaluación de modelos

Para evaluar las proyecciones, tanto dentro como fuera de la muestra, se utilizarán estadísticos tradicionales, siguiendo el enfoque de Pindyck y Rubinfeld (2001). Supongamos que el pronóstico de la muestra es $j = T + 1, T + 2, T + 3, \dots, T + h$ y los valores observado y proyectado están denotados por y_t y \hat{y}_t respectivamente. Las métricas de error para evaluar estos pronósticos se calculan de la siguiente manera:

- Raíz del error cuadrático medio (RMSE, por sus siglas en inglés)

$$\sqrt{\sum_{t=T+1}^{T+h} \frac{(\hat{y}_t - y_t)^2}{h}}$$

donde:

y_t : valor real en el tiempo t .

\hat{y}_t : valor predicho en el tiempo t .

h : número de predicciones (el horizonte de predicción, es decir, el número de períodos hacia el futuro).

T : último período conocido o de referencia en los datos históricos, y las predicciones se hacen para los $T + 1$ a $T + h$ períodos.

- Error cuadrático medio (MSE, por sus siglas en inglés)

$$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

donde:

y_i : valor real en la observación i .

\hat{y}_i : valor predicho en la observación i .

n : número total de observaciones.

Dado que los dos primeros estadísticos dependen de la escala de la variable dependiente, deben utilizarse como medidas relativas cuando se comparan los pronósticos de la misma serie entre diferentes modelos.

- Error absoluto medio (MAE, por sus siglas en inglés)

$$\sum_{t=T+1}^{T+h} \frac{|\hat{y}_t - y_t|}{h}$$

donde:

y_t : valor real en el tiempo t .

\hat{y}_t : valor predicho en el tiempo t .

h : número de predicciones o el horizonte de predicción (el número de períodos futuros que se están evaluando).

T : último período conocido en los datos históricos, y las predicciones se hacen para los $T + 1$ a $T + h$ períodos



PAISAJE RURAL
Juan Rimsa
1940
Óleo sobre cartón

Proyección del comportamiento de la inflación y descomposición de los choques *

Yara Pérez Foronda

RESUMEN

En el presente documento, se propone un modelo para la proyección de corto plazo de la inflación en Bolivia, tomando en cuenta variables relevantes, tanto endógenas como exógenas, que anticipan la dinámica inflacionaria. Se emplea un modelo de Vectores Autoregresivos con información exógena (VARX) para el periodo 2000 hasta el segundo trimestre de 2024. A diferencia de otros estudios, se analizó el comportamiento de la inflación con un enfoque direccionado a sus determinantes útiles para realizar una proyección que tome en cuenta las variables más relevantes en un contexto heterogéneo de componentes de la canasta del Índice de Precios al Consumidor. Asimismo, se realiza una comparativa con la situación de países de la región tomando en cuenta similitudes y diferencias relevantes para realizar las proyecciones de inflación.

Clasificación JEL: E31, E37, C22, C53, E52

Palabras clave: *Inflación, pronóstico y simulación, modelos de series de tiempo, política monetaria*

* El contenido del presente documento es de responsabilidad de la autora y no compromete la opinión del Banco Central de Bolivia.

Projection of inflation behavior and decomposition of shocks *

Yara Pérez Foronda

ABSTRACT

This document proposes a model for short-term inflation projections in Bolivia, taking into account relevant endogenous and exogenous variables that anticipate inflationary dynamics. A Vector Autoregressive Model with exogenous information (VARX) for the period from 2000 to the second quarter of 2024 is used. Unlike other studies, inflation behavior with a focus on its determinants, useful for making a projection that takes into account the most relevant variables in a heterogeneous context of components in the Consumer Price Index basket, was analyzed. A comparison with the situation of countries in the region, taking into account relevant similarities and differences for making inflation projections also was made.

JEL Classification: E31, E37, C22, C53, E52

Keywords: *Inflation, forecasting and simulation, time series models, monetary policy*

* The content of this document is the responsibility of the author and does not represent the opinion of the Central Bank of Bolivia.

I. Introducción

El comportamiento de los precios se constituye en una de las variables macroeconómicas más relevantes en cualquier economía. Asimismo, como parte del rol de los bancos centrales, se encuentra la preservación de la estabilidad de los precios, más aún en el caso boliviano, donde este es un mandato constitucional para coadyuvar al desarrollo económico.

En el periodo histórico reciente, el país ha gozado de una estabilidad de precios y, comparativamente, se ha posicionado como una de las más bajas a nivel regional y mundial. En este contexto, han sido relevantes las proyecciones realizadas que prevén el comportamiento futuro de esta variable, pues esto permite la toma de decisiones de política monetaria, anclaje de expectativas que coadyuvan a preservar este comportamiento favorable tanto para la economía como para los hogares.

De esta manera, los estudios relevantes sobre los determinantes de la inflación boliviana son numerosos, empero no se encontró ninguno con un abordaje enfocado en la evaluación de metodologías para la proyección de la inflación. Por tal motivo, el presente estudio aborda este punto de vista, es decir, se realiza un diagnóstico del comportamiento de la inflación reciente y sus características relevantes con el fin de que, a partir de ello, se proponga un modelo de proyección de inflación considerado adecuado para el corto plazo. Esta propuesta es relevante bajo un contexto en el cual los choques inflacionarios presentan una dinámica distinta y los seguimientos coyunturales macroeconómicos podrían ser más frecuentes y necesarios para la toma de decisiones.

La estrategia para esta tarea será que, a partir de la revisión de evaluaciones y documentos sobre las metodologías de proyección en otros bancos centrales similares, se tendrá una comprensión más amplia de las ventajas y limitaciones de los distintos enfoques existentes. Considerando tanto los resultados que se encuentren a partir de este ejercicio y también el desempeño interno propio de la dinámica inflacionaria en el país, será factible realizar una propuesta para la proyección de la inflación, priorizando que sea una metodología simple, de fácil manejo e interpretación.

El presente estudio tiene como objetivo proponer un modelo parsimonioso para la proyección de la inflación en Bolivia, tomando en cuenta variables

relevantes tanto endógenas como exógenas que anticipan la dinámica inflacionaria. Considerando los choques recientes ocurridos sobre la inflación, se otorga prevalencia a un modelo que sea útil para la proyección de corto plazo, en este caso de Vectores Autoregresivos con información exógena (VARX). Los resultados encontrados son coherentes con las presiones recientes sobre los precios y la metodología propuesta podría ser tomada en cuenta como parte de la batería de métodos utilizados actualmente para la proyección de la inflación.

Este trabajo de investigación se encuentra organizado de la siguiente forma. En la sección II, se describen algunas metodologías empleadas en la proyección de la inflación de acuerdo a la revisión de la bibliografía. A continuación, se presentan los hechos estilizados relevantes, respecto al comportamiento de la inflación en el periodo de estudio (2000T1 – 2024T2). Seguidamente, se presenta el análisis empírico, metodología y los principales resultados del modelo, así como un ejercicio complementario de la descomposición histórica de los choques que afectan a la inflación. Finalmente, se detallan las principales conclusiones del estudio realizado.

II. Revisión de la literatura

En este apartado se presentan estudios relacionados que evalúan distintas formas utilizadas para las proyecciones de inflación, especialmente a nivel de los bancos centrales. En este sentido, se hace énfasis en trabajos de países de la región, bajo el criterio de que estas economías presentan algunas similitudes en cuanto a las características que explican el comportamiento de su inflación (especialmente factores exógenos como precios de materias primas). Otro criterio relevante para la selección de dichos países es que las ponderaciones¹ dentro de la canasta de su Índice de Precios del Consumidor (IPC) tienen ciertas semejanzas (Mora, 2014) que permiten la comparabilidad de su comportamiento subyacente y, por tanto, de alguna manera, su proyección.

Aunque los criterios sobre presiones inflacionarias pueden ser similares en la región, es necesario resaltar que el caso de la economía boliviana presenta una diferencia sustancial: el régimen de política monetaria opera con metas de agregados, mientras que el resto de los países de la región

¹ Apéndice A.

operan bajo un régimen de metas de inflación. Este contraste es relevante debido a la selección de variables utilizadas para las proyecciones de inflación y el enfoque que se otorga a éstas.

Ampliando un poco más este criterio, bajo un régimen de metas explícitas de inflación, la variable operativa se constituye en la tasa de política monetaria fijada por el banco central. A través de la modificación de esta tasa, dicha señal se transmite a las tasas de interés del sistema financiero, lo cual incide en el costo del dinero repercutiendo en la inflación. Este mecanismo de transmisión de la política monetaria se observa, por ejemplo, en Brasil, Chile, Colombia y Perú que, al mismo tiempo, son los que cuentan con sistemas financieros y mercados de capitales más avanzados, por lo cual se esperaría que el mecanismo de transmisión se comporte de una manera más fluida. Adicionalmente, en este régimen, otros determinantes relevantes de la inflación son el tipo de cambio (cuya calibración es también diferente comparada con Bolivia) y las expectativas de inflación².

En definitiva, un componente importante del esquema de metas de inflación reside en la elaboración de proyecciones, las cuales se basan en la experiencia de sus equipos técnicos y en el uso adecuado de modelos. En esta línea, la mayoría de bancos centrales de la región realiza proyecciones de corto plazo mediante el uso de modelos de series de tiempo y ha incorporado, o se encuentra en proceso de elaboración de modelos DSGE y modelos semiestructurales de proyección (Luna *et al.*, 2019). En el caso del Perú, el Modelo de Proyección Trimestral (Winkelried, 2013) es la principal herramienta para la proyección de la inflación condicionada a diferentes escenarios de política monetaria, el cual se complementa con el uso de un modelo DSGE (Castillo *et al.*, 2009).

La literatura disponible sobre proyecciones de inflación en periodos recientes se concentra en las bondades de algunos modelos sobre otros. En algunos casos, bajo criterios de parsimonia y en otros por un adecuado "ajuste" cuando ocurren choques en determinados contextos macroeconómicos.

En el caso de la economía chilena, Leal *et al.* (2020) realizaron un análisis de la efectividad de los métodos de *Machine Learning* (ML) para predecir

2 Apéndice B.

la inflación en Chile, comparándolos con modelos simples y univariados como el AR, la media y la mediana de la inflación pasada para el periodo 2003 a 2019. Los resultados mostraron que, en la mayoría de los horizontes de predicción, los modelos tradicionales tienen un rendimiento muy cercano o incluso superior al mejor modelo de ML. También se plantea que, en un contexto de metas de inflación estables, como en Chile, los métodos sofisticados y los grandes datos pueden no ofrecer ventajas, lo que justificaría el buen desempeño de los modelos simples. Otros modelos como AR(4) y *Random Forest*, aunque complejos, son muy eficaces a largo plazo.

Previamente, Idrovo y Tejada en 2010 realizaron un análisis de modelos predictivos de la inflación para el mismo país basados en la Curva de Phillips, que incluye componentes *forward-looking* y *backward-looking*, con relación a la brecha del producto y variables externas. Se estimó una batería de modelos de series de tiempo multivariados y se contrastó la precisión y estabilidad predictiva de cada modelo. El análisis de la habilidad predictiva de los modelos fue basado en el error cuadrático medio y complementado por el estadístico *t*. En cuanto a la inflación, entre los principales resultados se obtuvo que los modelos GARCH en los residuos mostraron ser más eficaces en predicciones a corto plazo, destacando su capacidad para capturar la volatilidad inherente a esta variable. El comportamiento heterogéneo de la inflación, en el periodo analizado, limita la posibilidad de identificar un único modelo que supere, en términos de capacidad predictiva, al resto de modelos. Los resultados para el caso de la proyección del producto fueron divergentes, pues se encontró mayor utilidad de los modelos para el mediano y largo plazo. La variabilidad de los resultados de este estudio sugiere que no existe un modelo único que se desempeñe consistentemente mejor que otro, por lo menos en el período analizado. Por tanto, la elección del (de los) modelo(s) de proyección debe tener en cuenta tanto los errores de predicción como la estabilidad a través del tiempo. El estudio abarcó el periodo 1986 hasta 2010.

Para el caso del Perú, de manera *ex post*, Barrera (2005) realizó una evaluación de la precisión de las proyecciones de un conjunto de modelos de corto plazo para el IPC y otras variables. Como parte de los resultados encontrados, el autor afirma que las proyecciones de corto plazo suelen servir como “punto de partida” en las proyecciones que se

realizan utilizando modelos estructurales. Se encuentra que modelos no estructurales desagregados predicen mejor los componentes individuales como el IPC y tienen un mejor rendimiento en predicciones a corto plazo, ya que reducen la sensibilidad a choques internos de los agregados, mientras que modelos estructurales, como el Modelo de Proyección Trimestral (MPT) que son usados para proyecciones de mediano plazo, tienden a ser más útiles para explicar la coyuntura económica, pero sus proyecciones son menos precisas a corto plazo en comparación con los modelos no estructurales. Se calculó la raíz del error cuadrático medio, entre otros, para evaluar la precisión de las proyecciones, favoreciendo comparaciones claras entre los diferentes modelos.

Ulteriores publicaciones realizadas por el Banco Central de Reserva del Perú en 2007, 2012 y 2013 plantearon la evaluación del Sistema de Predicción Desagregada (SPD) y las principales especificaciones de series tiempo. Los enfoques utilizados fueron diferentes en cada caso, aunque un factor común es que con ello se pretende sobrellevar el nivel de sensibilidad ante datos atípicos que tienen los modelos de proyección y, en todos los casos, se reafirma que persisten desafíos como la dificultad de anticipar con precisión puntos de quiebre de la inflación. Asimismo, las covarianzas entre componentes del IPC y las fluctuaciones externas (como los precios de las materias primas) juegan un papel importante en la incertidumbre del pronóstico, lo que requiere ajustes adicionales en los modelos para mejorar su capacidad de predicción. Adicionalmente, se destaca que combinar proyecciones de diferentes modelos puede mejorar la precisión predictiva, incluso cuando un modelo específico muestra dominio en ciertos periodos. Finalmente, aunque el SPD ha priorizado la adición de especificaciones más eficientes, la combinación de proyecciones de múltiples modelos también debe ser considerada para optimizar las proyecciones futuras.

Por su parte, Cuitiño *et al.* en 2010 realizan una evaluación de la batería de modelos univariados de series de tiempo (ARIMA o SARIMA) utilizados para las proyecciones de inflación en Uruguay, utilizando series mensuales desde 1997 hasta 2009. En términos de su poder predictivo, el principal resultado encontrado fue que, en predicciones un paso adelante, el mejor modelo de proyección es el directo con la muestra truncada (M2), destacando como el mejor método para la predicción de la inflación a corto plazo (tanto para el IPC general como para el IPC subyacente) y

dominando a la proyección indirecta. Asimismo, la combinación del modelo M2 combinado con la mediana de expectativas mejoró las predicciones de corto plazo. Finalmente, realizando la comparación entre las predicciones trimestrales de modelos univariados versus el modelo estructural, los primeros resultaron superiores, confirmando la importancia de incluirlos en el marco general de proyecciones del Banco Central de Uruguay.

Para el caso de Colombia González *et al.* en 2006 y la misma autora en 2008, realiza una revisión de modelos de pronósticos de inflación a partir de desagregaciones utilizadas en el Banco de la República de Colombia, específicamente para el IPC de alimentos. Se incluyen mayormente modelos univariados y algunos multivariados (función de transferencia). Se encontró que, cuanto más sub-grupos se consideren mayor es el error de pronóstico. Adicionalmente, la proyección de la inflación a partir de desagregaciones produce menor error de pronóstico que los pronósticos generados a partir de un modelo directo para el corto plazo, mientras que para mediano y largo plazo es mejor la proyección directa. Otro hallazgo encontrado fue que, con algunas combinaciones de pronósticos, se mejoran las proyecciones de modelos individuales.

Como corolario del repaso de la literatura, se encuentra que existe una variedad de resultados de la comparación de distintas metodologías de proyección de inflación de las que se hace uso en los bancos centrales. Por tanto, no se puede realizar una afirmación concluyente sobre la mejor capacidad predictiva de ninguna metodología. Esto se reafirma, considerando que las conclusiones de los estudios dependen de factores como: muestra seleccionada en cuanto a periodos y países, estadísticos utilizados para la evaluación, criterios de agregación y/o combinación, horizonte de la proyección, entre otros. Empero, en cuanto a las semejanzas encontradas se rescata que, al hacer comparaciones de modelos estructurales y no estructurales (series de tiempo y otros con características más parsimoniosas), con los segundos se encuentra una aproximación mejor a los resultados observados y un mejor desempeño para el corto plazo. Por tanto, serían los modelos más apropiados para seguimientos de la coyuntura requeridos con mayor frecuencia para la toma de decisiones.

Para el caso de Bolivia, no se encontró muchos estudios relacionados directamente con esta temática. Aun cuando existe amplia literatura

sobre la relación de la inflación con la actividad económica, análisis de los determinantes inflacionarios y/o la efectividad de la política monetaria para el control de la inflación, dichos documentos no analizan las metodologías utilizadas para las proyecciones de inflación, su efectividad y capacidad predictiva.

El estudio más reciente que se encontró pertenece a Zurita (2024) en el cual se compara modelos de pronóstico de IPC con enfoques tradicionales (como ARIMA) versus aprendizaje automático (*Random Forest*, árbol de decisión y árbol podado). Los resultados encontrados sugieren que los modelos modernos capturan mejor la dinámica de la inflación y representan herramientas más robustas para su proyección. La comparación de este estudio se realizó con datos de 2007 a 2024. Aun cuando la investigación presenta resultados interesantes, no da resultados categóricos respecto a la mejor capacidad predictiva de estas metodologías modernas. En todos los casos, nuevamente será necesario considerar la influencia de la muestra seleccionada y los criterios de evaluación usados.

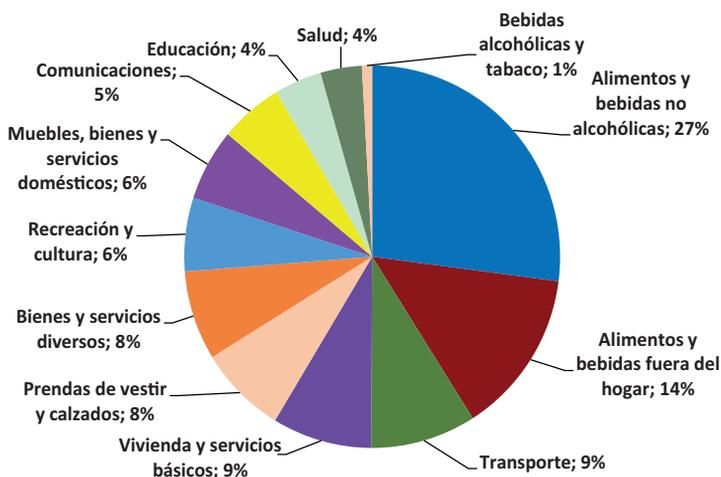
III. Hechos estilizados

III.1. Composición de la canasta del IPC

En base a la Encuesta de Presupuestos Familiares realizada por el Instituto Nacional de Estadística (INE) durante los años 2015 y 2016 se definió una canasta representativa de bienes y servicios consumidos por los hogares. De esta forma, el IPC con Base 2016 asigna ponderaciones a las 12 divisiones del IPC; las más representativas corresponden a las categorías de Alimentos consumidos tanto dentro como fuera del hogar (Gráfico 1).

Esta característica es transversal en economías emergentes y en desarrollo, especialmente de la región. Esto quiere decir que la mayor parte de los hogares bolivianos hace prevalecer su ingreso disponible para el consumo de alimentos. En términos de utilidad para los determinantes de la inflación y su proyección, quiere decir que un mayor consumo (que generalmente tiene un comportamiento correlacionado con el PIB) requieren tomarse en cuenta para dicha proyección.

Gráfico 1. PONDERACIÓN DE LAS DIVISIONES DEL IPC (Porcentaje)



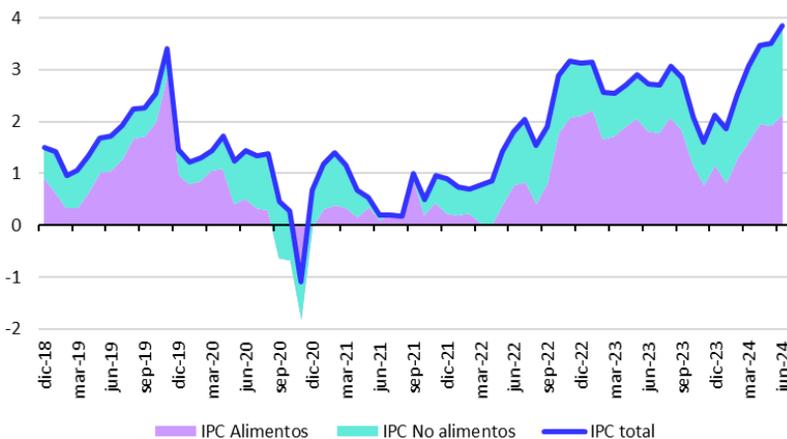
Fuente: Elaboración propia con datos del Instituto Nacional de Estadística (INE)

Por otra parte, otro hallazgo que se debe considerar de esta composición es que, ante un incremento de precios en otras divisiones, será más probable un sacrificio de parte de su consumo. De esta manera, será menos relevante, para realizar la proyección de inflación, tomar en cuenta factores determinantes de precios de divisiones como: Recreación y cultura, Bienes y servicios diversos, Comunicaciones, etc.

III.2. Comportamiento y determinantes de la inflación – Alimentos

Del apartado anterior puede inferirse que solo los alimentos representan el 42% de la canasta del IPC y que el restante de los bienes y servicios el 58%. Si se realiza la sub división entre estas dos categorías, el comportamiento reciente da cuenta que las mayores incidencias respecto a la inflación total, correspondieron al grupo de alimentos (Gráfico 2). En los últimos años, su incidencia llegó a representar más del 50%.

Gráfico 2: INCIDENCIAS DEL IPC-ALIMENTOS Y NO ALIMENTOS EN EL IPC TOTAL (En puntos porcentuales)



Fuente: Elaboración propia con datos del INE

Un instrumento útil para verificar un calentamiento/enfriamiento de la inflación en este sub grupo analizado se realiza a través de un mapa de calor (Gráfico 3)³. En dicho mapa se observa que alimentos no procesados (frutas, vegetales, pescados y carnes) se caracterizan por tener un comportamiento más volátil de precios, presentan precisamente una persistencia de su “nivel de volatilidad” (umbrales azules). Es decir, no se presentaron desvíos significativos de este comportamiento usual y, por tanto, la trayectoria de sus precios no es aleatoria y, en consecuencia, tiene componentes determinísticos.

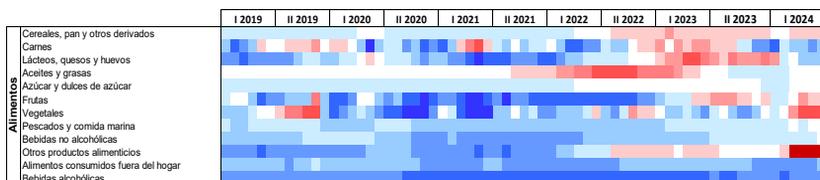
El resultado más relevante de este análisis, en cuanto a la utilidad para seleccionar una metodología de proyección de la inflación, es que dicho método debe ser lo suficientemente representativo de: i) las variables exógenas que influyen en alimentos importados y/o que requieren de insumos importados; así como ii) variables endógenas (productividad) que explica la oferta y movimientos de los precios de alimentos.

³ Umbrales más rojos significan una variación interanual más alta respecto al promedio. Mientras que, los umbrales azules corresponden a variaciones más leves respecto a su promedio.

En el caso de otros alimentos, como cereales, bebidas y otros productos alimenticios, se caracterizan por un comportamiento más estable de precios, que rara vez se apartaría de esta tendencia. Es así que su dinámica es menos representativa sobre el total de la inflación.

Vale la pena destacar que, en el caso boliviano, alimentos como el pan, harinas, aceites están directa o indirectamente influenciados por la subvención a su producción y la regulación de sus precios. Este aspecto dificulta la selección de un método de proyección de precios que capture en su totalidad (ya sea de manera desagregada o agregada) esta heterogeneidad.

**Gráfico 3: MAPA DE CALOR DE LA INFLACIÓN DE ALIMENTOS
(Umbrales de variación respecto al promedio observado)**



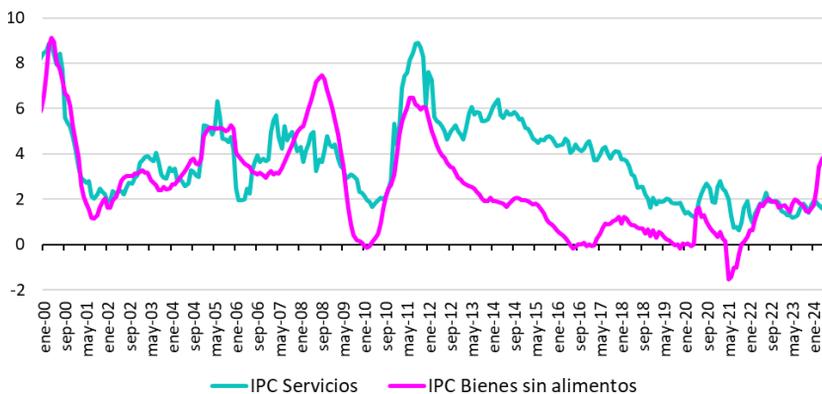
Fuente: Elaboración propia con datos del INE

III.3. Comportamiento de la inflación de bienes y servicios

Otro nivel de desagregación relevante para el análisis del comportamiento de la inflación se realiza entre bienes no alimenticios y servicios (Gráfico 4). A este nivel se observa que los choques externos más relevantes impactaron sobre los precios de servicios en los periodos 2008 y 2012. Durante estos años se tuvo un impacto generalizado en precios que causó sobresaltos y posteriormente se tuvo un comportamiento más estable.

Es relevante el comportamiento de servicios, ya que las tendencias alcistas en el contexto boliviano son distintas al resto de países. En nuestro contexto, están influenciadas por una menor volatilidad de precios de transporte público en todos los ámbitos, por el rol relevante de la subvención a los hidrocarburos desde inicios de los años 2000.

**Gráfico 4: COMPORTAMIENTO DE BIENES Y SERVICIOS DEL IPC
(Variación interanual, en porcentaje)**



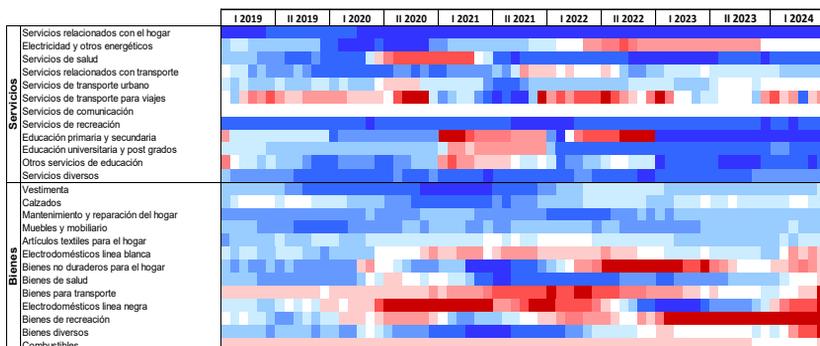
Fuente: Elaboración propia con datos del INE

Por otra parte, algunos servicios básicos como agua, energía eléctrica, gas domiciliario, entre otros, también están sujetos a regulación estatal de precios. Dado el motivo precedente, los factores subyacentes que determinan su comportamiento de precios no pueden ser capturados en su totalidad.

En dicho contexto, no es despreciable la influencia que pueda tener los componentes internos de gasto público, inflación externa relevante para aproximar a la sección predecible de la inflación futura.

La información disponible en el mapa de calor de estas dos categorías reafirma las ideas descritas previamente (Gráfico 5).

**Gráfico 5: MAPA DE CALOR DE LA INFLACIÓN DE BIENES Y SERVICIOS DEL IPC
(Umbrales de variación respecto al promedio observado)**



Fuente: Elaboración propia con datos del INE

En el caso de servicios, tanto la volatilidad como la dispersión respecto a su promedio histórico es muy leve. En el periodo mostrado, existen pocas desviaciones y su comportamiento es estable. Únicamente en el caso de educación los ajustes realizados post pandemia resaltan en el cuadro.

Por su parte, los bienes no alimenticios que tienen características de mayor durabilidad presentan una alta correlación con la inflación importada. Como puede observarse, las desagregaciones de esta categoría pertenecen principalmente a industria extranjera. Para este caso, la estabilidad del mercado cambiario y la inflación externa relevante serán significativas para la proyección de sus precios.

III.4. Inflación importada

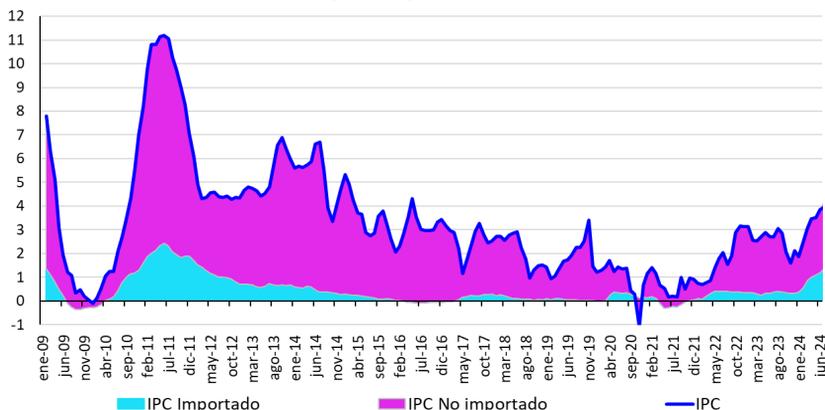
En cuanto a componente importado y no importado de la inflación, la incidencia del primero, en el último periodo histórico, es menor y fluctuó entre el 12% y 20% del total entre los años 2009 hasta junio de 2024, es decir existió cierta estabilidad en el comportamiento de dichos precios (Gráfico 6).

En este caso, es necesario resaltar que, según la metodología del INE para la determinación de la canasta del IPC – Base 2016, se realizó una clasificación diferenciada de cada producto en cada ciudad/conurbación que forma parte de la muestra (por ejemplo, la manzana verde puede ser

clasificada como un producto importado en La Paz, pero no importado en Cochabamba). Sin embargo, al momento de la recolección de datos mensual no se realiza nuevamente esta distinción cuando se consulta el precio del producto, lo cual puede ocasionar problemas de sesgo y/o recolección con ciertos errores⁴. Aun así, se destaca que dicha metodología es válida de acuerdo a parámetros internacionalmente establecidos.

Sin embargo, esto plantea dilemas relevantes al momento de realizar las proyecciones de inflación. Por ejemplo, si se requiriese hacer proyecciones desagregadas, los resultados tendrían muchas distorsiones y probablemente la muestra disponible no sería adecuada.

Gráfico 6: INCIDENCIAS DEL IPC IMPORTADO Y NO IMPORTADO EN EL IPC TOTAL (En puntos porcentuales)



Fuente: Estimaciones en base a datos del INE

En síntesis, tomando en cuenta estas particularidades, para los fines de proyección se requerirá tomar enfoques más simplificados que puedan aglutinar, en la medida de lo posible, factores explicativos de la inflación importada. Por consiguiente, similares variables explicativas a las ya indicadas previamente, como: i) tipo de cambio promedio ponderado y/o preferencial usado por importadores, ii) inflación externa y PIB externo relevantes, parecen ser indicativas y capturan el comportamiento de este componente inflacionario.

4 Para mayor información al respecto, remitirse al documento metodológico del INE para la determinación del IPC Base 2016.

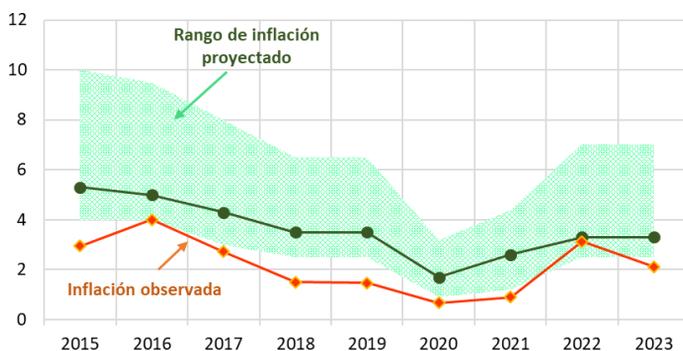
III.5. Proyecciones de inflación e inflación observada

Se consideró apropiado también realizar una comparación del dato observado de la inflación y el rango de inflación proyectado para dicha variable en los Informes de Política Monetaria (IPM) del BCB (Gráfico 7) desde la gestión 2015 hasta el 2023.

Los resultados dan cuenta que el rango inicialmente proyectado para la trayectoria de la inflación estuvo por encima de lo efectivamente observado. Es probable que en una coyuntura reciente de estabilidad mayor de precios se hayan sobrestimado los factores que podrían haber impulsado al alza de la inflación, lo cual explicaría estas diferencias. Esto de ninguna manera quiere decir que las metodologías utilizadas para la proyección de la inflación no hayan sido apropiadas.

Sin embargo, en un contexto de mayor relevancia de choques externos e internos, es menester poner a prueba metodologías de proyección para que se pueda validar su capacidad predictiva. Empero, reforzando lo explicado previamente, ninguna metodología supera todas las debilidades; peor aún, tomando en cuenta las características heterogéneas que influyen en el comportamiento de precios internos del país, si se compara, por ejemplo, con las de otros países de la región.

Gráfico 7: VARIACIÓN INTERANUAL DE LA INFLACIÓN OBSERVADA Y PROYECTADA (En porcentaje)



Fuente: Elaboración propia con datos del INE y de los Informes de Política Monetaria de cada gestión

IV. Análisis empírico

IV.1. Modelo

Para la proyección de la inflación, se empleará un modelo de Vectores Autorregresivos con información exógena (VARX)⁵, este modelo con los modelos de vectores autorregresivos estructurales (SVAR) han demostrado ser instrumentos útiles para el análisis de series temporales multivariantes en economía. Aunque comparten una base metodológica común, existen diferencias entre ambos enfoques, especialmente en el contexto de la generación de pronósticos.

Los modelos VARX se caracterizan por su enfoque parsimonioso. Estos modelos tratan todas las variables como endógenas y utilizan las relaciones temporales entre ellas para realizar pronósticos sin imponer restricciones adicionales. Esto presenta ciertas ventajas:

1. **Facilidad de estimación:** Los VAR pueden estimarse utilizando métodos simples de mínimos cuadrados ordinarios (OLS), lo que reduce la complejidad computacional (Enders, 2015).
2. **Aplicabilidad general:** Al no requerir supuestos sobre la causalidad contemporánea entre las variables, los VAR son adecuados para contextos en los que el objetivo principal es identificar **patrones históricos y extrapolarlos hacia el futuro** (Stock y Watson, 2001).
3. **Incorporación de información exógena:** Los VARX permiten incluir variables externas que influyen en el sistema, pero no son determinadas por él. Esto es útil en escenarios donde factores externos, como políticas gubernamentales o precios internacionales, afectan significativamente la dinámica de las variables endógenas (Enders, 2015).
4. **Mejora en los pronósticos:** **La incorporación de variables exógenas relevantes puede aumentar la precisión de los pronósticos al capturar efectos externos importantes** (Stock y Watson, 2001).

⁵ Las variables empleadas para el desarrollo del modelo están en primeras diferencias y cumplen el criterio de estacionariedad, por tal motivo se corrobora esta premisa con el test de Dickey-Fuller, lo cual indica que no poseen raíz unitaria (Apéndice C).

5. Reducción de la dimensionalidad: Permite mantener un modelo parsimonioso al evitar que todas las variables sean endógenas, lo que reduce la complejidad del sistema.
6. Capacidad de simulación de escenarios: Los VARX son útiles para analizar escenarios específicos relacionados con cambios en las variables exógenas, como por ejemplo el impacto de una reforma fiscal.

Sea un modelo VARX con 5 variables endógenas especificadas como funciones lineales de sus propios rezagos y rezagos de otras variables $K - 1$, el sistema es descrito por:

$$y_t = v + A y_{t-1} + B x_{t-1} + u_t, \quad t = 0, \pm 1, \pm 2, \dots,$$

donde $y_t = (y_{1t}, \dots, y_{5t})'$, es un vector de variables endógenas ($K \times 1$), A , es la matriz de coeficientes ($K \times K$), $v = (v_1, \dots, v_7)$ es un vector fijo ($K \times 1$) que denota los interceptos, permitiendo la posibilidad de una media distinta de cero $E(y_t)$, x_t son las variables exógenas al modelo, de la cual la inflación no influye en el comportamiento de dichas variables, finalmente, $u_t = (u_{1t}, \dots, u_{7t})'$, es el vector de innovaciones (*shocks*) de ruido blanco ($K \times 1$), el cual tiene la propiedades de: $E(u_t) = 0$, $E(u_t u_t') = \Sigma_u$ y $E(u_t u_s') = \Sigma_u$, donde $s \neq t$. Se asume que la matriz de covarianzas (Σ_u) es no singular.

$$y_t = \begin{bmatrix} \pi_t \\ PIB_t \\ EMI_t \\ G_t \\ TCPP_t \end{bmatrix}; \quad x_t = \begin{bmatrix} PIB_t^* \\ oil_t \\ \pi_t^* \end{bmatrix}$$

donde:

π_t : inflación doméstica de Bolivia

PIB_t : Producto Interno Bruto

EMI_t : emisión monetaria

G_t : gasto de gobierno

$TCPP$: tipo de cambio preferencial ponderado de compra

PIB_t^* : Producto externo relevante

oil_t : Precio del petróleo

π_t^* : Inflación externa relevante para Bolivia

IV.2. Resultados

El modelo se estimó utilizando datos trimestrales del período 2000T1–2024T2. El modelo planteado ofrece una buena capacidad predictiva de la inflación doméstica en el sentido de Granger⁶, lo cual indica que las variables incluidas aportan información relevante para anticipar la dinámica de la inflación en Bolivia. Esto se valida mediante la significancia estadística conjunta de los coeficientes asociados a las variables exógenas y endógenas. En particular:

- Las variables exógenas (PIB externo, precio del petróleo, e inflación externa) son determinantes clave que impactan la inflación doméstica a través de sus efectos en los precios de importación, los costos energéticos y las presiones inflacionarias globales.
- Las variables endógenas, como la emisión monetaria y el tipo de cambio son mecanismos internos que amplifican o moderan las presiones inflacionarias.

El modelo satisface la condición de estabilidad, ya que los autovalores de la ecuación característica están dentro del círculo unitario. Este resultado asegura que las perturbaciones en las variables no generan efectos

⁶ El concepto de causalidad de Granger se basa en la idea de predictibilidad. Formalmente, se dice que una variable causa a otra variable en el sentido de Granger si aporta información que mejora la predicción futura de esta última, más allá de la contenida en sus propios valores pasados. Es decir, si los valores pasados de una variable tienen poder explicativo sobre otra, entonces es causal en el sentido de Granger (Granger, 1969). El test parte de una premisa de no causalidad nula, donde se asume que los coeficientes asociados a los rezagos de una regresión sobre son iguales a cero.

El planteamiento del test de causalidad de Granger, se encuentra en el siguiente sentido:

Hipótesis nula (H_0): Los coeficientes de los rezagos de X_t en el segundo modelo son todos cero ($\gamma_j = 0 \forall j$). Esto significa que X_t no causa de Granger a Y_t .

Hipótesis alternativa (H_1): Al menos uno de los coeficientes de los rezagos de X_t es diferente de cero ($\gamma_j \neq 0$ para algún j). Esto sugiere que X_t sí causa de Granger a Y_t . La causalidad de Granger no implica causalidad en el sentido estricto, sino una relación predictiva.

explosivos en el sistema, lo que valida la coherencia dinámica del modelo (Apéndice D).

Para validar el poder predictivo del modelo se recurrió a las métricas de *Root Mean Squared Error* (RMSE)⁷, *Mean Absolute Error* (MAE)⁸, *Mean Absolute Percent Error* (MAPE)⁹ y el coeficiente U de Theil¹⁰. Esta evaluación dentro de la muestra (*in-sample evaluation*) constituye un paso fundamental en el análisis de modelos de pronóstico, ya que permite verificar qué tan bien el modelo reproduce los datos utilizados en su estimación inicial.

La evaluación dentro de la muestra cumple múltiples objetivos. En primer lugar, garantiza que el modelo capture la estructura subyacente de los datos y las relaciones entre las variables, un aspecto crucial en contextos donde las decisiones basadas en el modelo dependen de su precisión para reflejar fenómenos económicos.

- 7 El RMSE mide la magnitud promedio de los errores de predicción, penalizando más fuertemente los errores grandes. Es útil cuando se desea dar mayor importancia a los errores grandes, ya que los eleva al cuadrado antes de promediar.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- 8 El MAE mide el error promedio en las predicciones, sin considerar la dirección del error. A diferencia de RMSE, MAE no penaliza los errores grandes con tanta severidad.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- 9 El MAPE mide el error promedio en términos porcentuales, lo que permite evaluar la precisión de las predicciones en relación con el tamaño de los valores observados. Es fácil de interpretar porque expresa el error como un porcentaje.

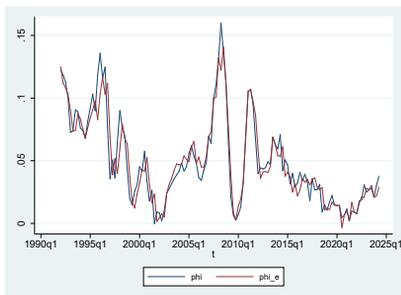
$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

- 10 El coeficiente U de Theil es una medida comparativa que evalúa el rendimiento de un modelo predictivo en relación con un modelo de referencia. Un valor de $U > 1$ indica que el modelo es mejor que el modelo de referencia, mientras que un $U > 1$ sugiere que es peor.

$$U = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_{i-1})^2}}$$

Gráfico 8: PRONÓSTICO DE LA INFLACIÓN DENTRO DE LA MUESTRA

a) Inflación observada y pronosticada



b) Métricas de evaluación

RMSE	0,0116
MAE	0,0080
MAPE	-0,5152
Theil'sU	0,8125

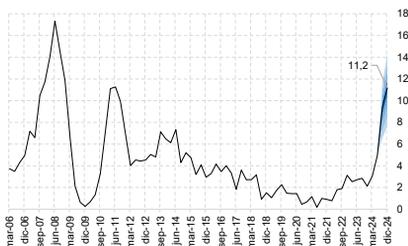
Fuente: Elaboración propia

Los resultados obtenidos indican que el modelo se ajusta de manera adecuada a los valores observados en la muestra (Gráfico 8). Las métricas de evaluación reflejan un error mínimo respecto a dichos valores, lo que respalda la validez del modelo y su capacidad para generar pronósticos fuera de la muestra. Esto sugiere que el escenario proyectado para la inflación fuera de la muestra es altamente probable y consistente con los datos históricos.

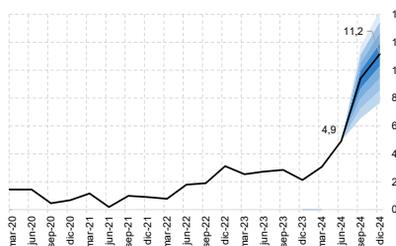
Los resultados sugieren que la inflación de Bolivia cerraría en un nivel del 11,2% al término del año 2024. Este pronóstico refleja tanto las condiciones internas de la economía boliviana como las influencias externas derivadas de la dinámica del petróleo y la inflación global (Gráfico 9).

Gráfico 9: PRONÓSTICO DE LA INFLACIÓN (En porcentaje)

INFLACION 2006 – 2024(e)



INFLACION 2020 – 2024(e)



Fuente: Elaboración propia

IV.3. Descomposición histórica de la varianza

La descomposición histórica de la varianza es una herramienta fundamental en el análisis de modelos VAR que permite evaluar la contribución de los choques en las variables endógenas a la variabilidad de los errores de pronóstico de una variable específica. Este enfoque es clave para comprender la dinámica de los sistemas interrelacionados y cuantificar el impacto de los choques en diferentes horizontes temporales. La descomposición histórica de varianza proporciona una forma de evaluar la importancia relativa de las innovaciones en cada variable para explicar la variabilidad de las demás.

El modelo VARX se puede expresar en una forma MA infinita, pero con la salvedad de que las variables exógenas afectan directamente los valores de Y_t en cada período.

$$Y_t = \sum_{i=0}^{\infty} \Phi_i u_{t-i} + \sum_{j=0}^{\infty} \Psi_j X_{j-i}$$

donde, Φ_i captura la respuesta acumulada a choques en u_t , mientras que Ψ_j mide el impacto acumulado de las variables exógenas¹¹.

La contribución de una variable k a la varianza del error de pronóstico de j se determina de manera similar al VAR:

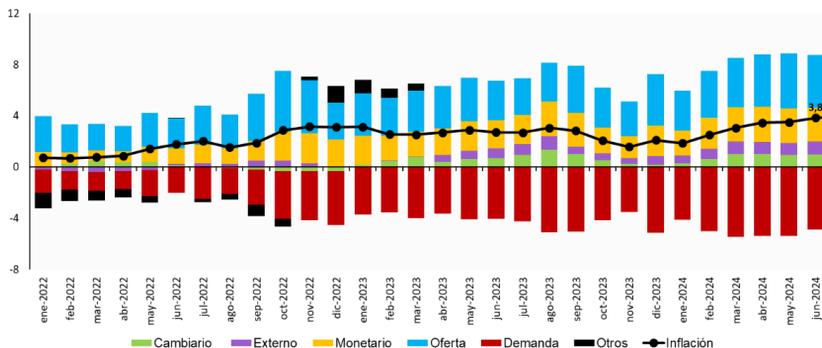
$$VD_{jk}(h) = \frac{\sum_{i=0}^{h-1} (\Phi_i P)_{jk}^2}{\text{Var } e_{j,t+h}}$$

¹¹ Como en el VAR, se calcula la varianza del error de pronóstico para diferentes horizontes, considerando únicamente las innovaciones en las variables endógenas:

$$\text{Var}(e_{j,t+h}) = \sum_{i=0}^{h-1} \Phi_i \Sigma \Phi_i'$$

Choque	Explicación Teórica	Explicación Intuitiva
Demanda (gasto de gobierno, rojo)	Fluctuaciones en la demanda agregada de bienes y servicios. Un exceso de demanda presiona los precios al alza, mientras que una caída reduce la inflación.	Un aumento en el consumo o el gasto público puede generar inflación si la oferta no responde rápidamente.
Monetario (emisión monetaria, amarillo)	Impacto de la política monetaria y la cantidad de dinero en circulación. Más dinero en la economía tiende a aumentar la inflación; menos dinero la reduce.	Si el banco central reduce las tasas de interés, las personas tienen mayor liquidez, lo que puede presionar los precios al alza.
Oferta (Producto Interno Bruto, azul)	Cambios en los costos de producción o disponibilidad de bienes. Problemas en cadenas de suministro o insumos más caros aumentan los precios.	Una sequía que afecta la producción agrícola puede encarecer alimentos, aumentando la inflación.
Cambiarío (Tipo de cambio preferencial ponderado de compra, verde)	Movimientos en el tipo de cambio. Una devaluación encarece bienes importados, lo que incrementa la inflación por este componente.	Si la moneda local pierde valor frente al dólar, los productos importados se vuelven más caros, elevando el costo de vida.
Externo (Producto externo relevante, Precio del petróleo y la Inflación externa relevante para Bolivia, morado)	Choques del entorno internacional, como aumentos en los precios de <i>commodities</i> o fluctuaciones en mercados globales.	Un incremento en el precio del petróleo encarece energía y transporte, impactando los precios de forma generalizada.

Gráfico 10: DESCOMPOSICIÓN HISTÓRICA DE LOS CHOQUES
(En porcentaje y puntos porcentuales)



Fuente: Elaboración propia

V. Conclusiones

Existe una variedad de estudios de comparación de distintas metodologías de proyección de inflación de las que se hace uso en los bancos centrales. En cuanto a las semejanzas encontradas se rescata que modelos no estructurales (series de tiempo y otros con características más parsimoniosas) tienen mejor desempeño para el corto plazo. Por tanto, serían los modelos más apropiados para seguimientos de la coyuntura requeridos con mayor frecuencia para la toma de decisiones.

Los estudios relevantes sobre los determinantes de la inflación boliviana son numerosos, aunque no se encontró ninguno con un abordaje enfocado en la evaluación de metodologías para la proyección de la inflación.

El presente estudio realizó un diagnóstico del comportamiento de la inflación reciente y sus características relevantes y, a partir de ello, se propuso un modelo de proyección de inflación considerado adecuado para el corto plazo. Se priorizó que la metodología sea simple, de fácil manejo e interpretación.

Se propuso un modelo parsimonioso para la proyección de la inflación en Bolivia, tomando en cuenta variables relevantes, tanto endógenas como exógenas, que anticipan la dinámica inflacionaria. El modelo propuesto es de Vectores Autoregresivos con información exógena (VARX).

Los resultados encontrados para la gestión 2024 son coherentes con las presiones recientes sobre los precios y la metodología propuesta podría ser tomada en cuenta como parte de la batería de métodos utilizados actualmente para la proyección de la inflación.

La propuesta de la presente investigación es relevante, bajo un contexto en el cual los choques inflacionarios presentan una dinámica distinta y los seguimientos coyunturales macroeconómicos podrían ser más frecuentes y necesarios para la toma de decisiones.

Referencias bibliográficas

BANCO CENTRAL DE BOLIVIA, 2015. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2016. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2017. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2018. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2019. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2020. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2021. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2022. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BANCO CENTRAL DE BOLIVIA, 2023. *Informe de Política Monetaria*, enero. Disponible en: <https://www.bcb.gob.bo/?q=ipm>

BARRERA, Carlos, 2013. El sistema de predicción desagregada - Una evaluación de las proyecciones de inflación 2006-2011. Banco Central de Reserva del Perú, Serie de Documentos de trabajo DT. N°2013-009, julio. Disponible en: <https://www.bcrp.gob.pe/publicaciones/documentos-de-trabajo/dt-2013-09.html>

BARRERA, Carlos, 2007. Proyecciones desagregadas de inflación con modelos *Sparse* VAR robustos. Banco Central de Reserva del Perú, Serie de Documentos de trabajo, DT. N° 2007-015, septiembre. Disponible en: <https://www.bcrp.gob.pe/docs/Publicaciones/Documentos-de-Trabajo/2007/Documento-Trabajo-15-2007.pdf>

BARRERA, Carlos, 2005. Proyecciones desagregadas de la variación del Índice de Precios al Consumidor (IPC), del Índice de Precios al Por Mayor (IPM) y del crecimiento del producto real (PBI). Banco Central de Reserva del Perú, Serie de Documentos de trabajo DT. N° 2005-006, noviembre. Disponible en: <https://www.bcrp.gob.pe/docs/Publicaciones/Documentos-de-Trabajo/2005/Documento-Trabajo-06-2005.pdf>

CABALLERO, Jhudy, BOHÓRQUEZ, Claudia, CABALLERO, Benigno y CABALLERO, Rolando, 2020. Análisis de la tasa de inflación en Bolivia. Una aproximación con modelos con cambio de régimen con dos estados. *Economía Coyuntural*, 5 (4), pp. 25 - 58. ISSN en línea 2415-0630. Disponible en: http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2415-06222020000400004&lng=es&tlng=es

CABALLERO, Rolando, CABALLERO, Benigno y BOHÓRQUEZ, Claudia, 2022. *Análisis de la inflación en Bolivia: Una aproximación Markov Switching con dos estados*. Ministerio de Economía y Finanzas Públicas de Bolivia, *Cuadernos de Investigación Económica Boliviana*, 3 (1), pp. 47 - 88. ISSN: 2518-4687. Disponible en: https://www.economiayfinanzas.gob.bo/sites/default/files/2023-08/Paper2_CIEB2019.pdf

CASTILLO, Paul, MONTORO, Carlos y TUESTA, Vicente, 2009. Un modelo de equilibrio general con dolarización para la economía peruana. Banco Central de Reserva del Perú, *Revista Estudios Económicos*, 17, pp. 9 - 50. ISSN 1028-6438. Disponible en: <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Estudios-Economicos/17/Estudios-Economicos-17-1.pdf>

CUITIÑO, Fernanda, GANÓN, Elena, TISCORDIO, Ina y VICENTE, Leonardo, 2010. Modelos univariados de series de tiempo para predecir la inflación de corto plazo. En: *XXV Jornadas Anuales de Economía*. Montevideo, Uruguay. Disponible en: <https://www.bcu.gub.uy/Comunicaciones/Jornadas%20de%20Economia/iees03j3101010.pdf>

ENDERS, Walter, 2015. *Applied Econometric Time Series*, 4th edition. John Wiley & Sons Inc. ISBN: 978-1-118-80856-6

GONZÁLEZ, Eliana; GÓMEZ, Miguel; MELO, Luis and TORREZ, Jose, 2006. Forecasting food price inflation in developing countries with inflation targeting regimes: the Colombian case. Banco de la República – Colombia,

Borradores de Economía No. 409, octubre. Disponible en: <https://banrep.gov.co/docum/ftp/borra409.pdf>

GONZÁLEZ, Eliana, 2008. Pronósticos de agregados a partir de desagregados. Caso empírico: Inflación de alimentos en Colombia. Banco de la República – Colombia, Borradores de Economía N°504, abril. Disponible en: <https://dlb4gd4m8561gs.cloudfront.net/sites/default/files/publicaciones/pdfs/borra504.pdf>

IDROVO, Byron y TEJADA, Mauricio, 2010. Modelos de predicción para la inflación de Chile. Cámara Chilena de la Construcción AG, Documentos de trabajo N°61, septiembre. Disponible en: <https://catalogo.extension.cchc.cl/documentos/documentos/22483-2.pdf>

KILIAN, Lutz and LÜTKEPOHL, Helmut, 2017. *Structural Vector Autoregressive Analysis*. Cambridge University Press. ISBN: 978-1-107-19657-5

LEAL, Felipe, MOLINA, Carlos and ZILBERMAN, Eduardo, 2020. Inflation Forecast in Chile with Machine Learning Methods. Banco Central de Chile, Documento de trabajo N° 860, enero. Disponible en: https://www.bcentral.cl/documents/33528/133326/DTBC_860.pdf/e845b1aa-28fd-d125-e646-fa7c76fbff41?t=1693387767543

LUNA, Miriam, PÉREZ, Fernando, MONTORO, Carlos y CASTILLO, Paul, 2019. El esquema de metas de inflación en América del Sur: Evaluación y perspectivas. Banco Central de la Reserva del Perú, *Moneda*, 179, pp. 8 - 12. ISSN en línea 1991-0606. Disponible en: <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-179/moneda-179-02.pdf>

LÜTKEPOHL, Helmut, 2005. *New Introduction to Multiple Time Series Analysis*. Germany: Springer-Verlag

MORA, Mauricio, 2014. Determinantes de la inflación de alimentos y su relación con la inflación de no alimentos en Bolivia. Banco Central de Bolivia, Serie de documentos de trabajo, Documento de trabajo N° 09/2014, diciembre. Disponible en: https://www.bcb.gob.bo/webdocs/publicacionesbcb/2016/06/00/18.%20Inflaci%C3%B3n%20de%20alimentos%20en%20Bolivia_0.pdf

NADAL-DE SIMONE, Francisco, 2001. Proyección de la Inflación en Chile. Banco Central de Chile, *Economía chilena*, 4 (3), pp. 59 – 85. ISSN en línea 0717-3830. Disponible en: <https://repositoriodigital.bcentral.cl/xmlui/handle/20.500.12580/3442>

SIMS, Christopher, 1980. Macroeconomics and reality. *Econometrica*, 48 (1), pp. 1 - 48. ISSN en línea 1468-0262. Disponible en: <https://doi.org/10.2307/1912017>

STOCK, James and WATSON, Mark, 2001. Vector Autoregressions. *Journal of Economic Perspectives*, 15 (4), pp. 101 - 115. ISSN en línea 1944-7965. Disponible en: <https://www.aeaweb.org/articles?id=10.1257/jep.15.4.101>

WINKELRIED, Diego, 2013. Modelo de proyección trimestral del BCRP: Actualización y novedades. Banco Central de Reserva del Perú, *Revista Estudios Económicos*, 26, pp. 9 - 60. ISSN 028-6438. Disponible en: <http://www.bcrp.gob.pe/publicaciones/revista-estudios-economicos/estudios-economicos-no-26.html>

ZURITA, José, 2024. Evaluación de la precisión en el pronóstico de la inflación en Bolivia: *Random Forest* y árboles de decisión vs. Arima. Universidad del Valle, *Compás Empresarial*, 15 (39), pp. ISSN en línea 2075-8960. Disponible en: <https://doi.org/10.52428/20758960.v15i39.1227>

APÉNDICES

Apéndice A

Comparación de ponderación por divisiones de países de la región.

Por división	Bolivia 2016	Peru 2021	Colombia 2019	Chile 2023
ALIMENTOS Y BEBIDAS NO ALCOHOLICAS	27,1	23,9	15,1	22,2
BEBIDAS ALCOHOLICAS Y TABACO	0,9	1,7	1,7	3,7
PRENDAS DE VESTIR Y CALZADO	7,6	4,6	4,0	2,9
VIVIENDA Y SERVICIOS BASICOS	8,6	9,6	33,1	16,8
MUEBLES, BIENES Y SERVICIOS DOMESTICOS	6,1	4,9	4,2	6,2
SALUD	3,6	3,5	1,7	8,2
TRANSPORTE	9,1	12,2	12,9	13,5
COMUNICACIONES	5,4	4,6	4,3	6,6
RECREACION Y CULTURA	6,2	4,0	3,8	4,8
EDUCACION	4,1	8,1	4,4	4,2
BIENES Y SERVICIOS DIVERSOS	7,6	6,8	5,4	3,7
ALIMENTOS Y BEBIDAS CONSUMIDOS FUERA DEL HOGAR	14,0			
RESTAURANTES Y HOTELES		16,1	9,4	6,2
SEGUROS Y SERVICIOS FINANCIEROS				1,1

Apéndice B

Metas de inflación de países de la región.

País	Rango meta
Brasil	3% - 6%
Chile	2% - 4%
Colombia	2% - 4%
Paraguay	2% - 6%
Perú	1% - 3%
Uruguay	1% - 3%

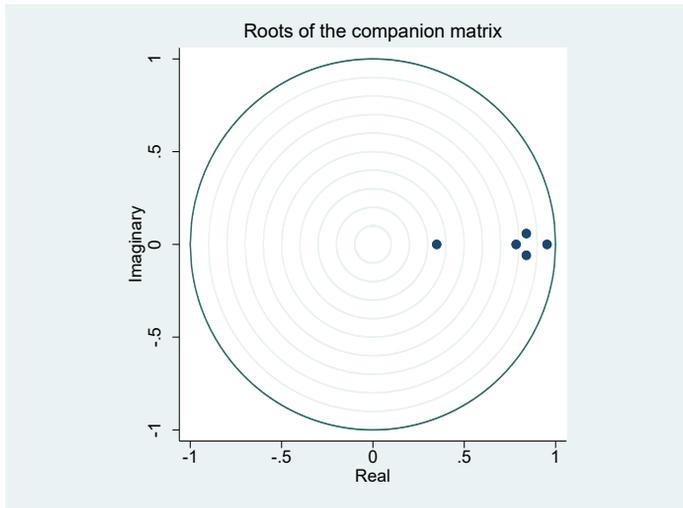
**Test de Raíz Unitaria (Cont.)
(En diferencias)**

. dfuller tcpp , noconstant

Dickey-Fuller test for unit root		Number of obs	=	133
		Interpolated Dickey-Fuller		
Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-2.372	-2.596	-1.950	-1.612

Apéndice D

Condición de estabilidad de Modelos Vectores Autorregresivos (VAR)



Test de Causalidad de Granger

Granger causality Wald

Equation	Excluded	chi2	df	Prob > chi2
phi	y	2.7736	1	0.735
phi	emi	11.499	1	0.042
phi	g	2.277	1	0.810
phi	tcpp	6.9039	1	0.228
phi	ALL	33.546	4	0.029
y	phi	21.763	1	0.001
y	emi	13.385	1	0.020
y	g	4.5606	1	0.472
y	tcpp	8.2762	1	0.142
y	ALL	49.191	4	0.000
emi	phi	2.5561	1	0.768
emi	y	10.505	1	0.062
emi	g	4.3578	1	0.499
emi	tcpp	1.3457	1	0.930
emi	ALL	17.632	4	0.612
g	phi	2.4914	1	0.778
g	y	1.8882	1	0.864
g	emi	11.273	1	0.046
g	tcpp	11.477	1	0.043
g	ALL	21.251	4	0.382
tcpp	phi	1.5907	1	0.902
tcpp	y	2.8491	1	0.723
tcpp	emi	17.27	1	0.004
tcpp	g	5.5954	1	0.348
tcpp	ALL	29.699	4	0.075

Pruebas de autocorrelación

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	29.2710	25	0.25275
2	20.7739	25	0.70515
3	24.4083	25	0.49589
4	23.0158	25	0.57664
5	29.0666	25	0.26114



LA BELLA Y LA BESTIA
Jorge De la Reza
1934
Óleo sobre lienzo

Modelos no lineales para la predicción de indicadores adelantados del PIB con variables monetarias y fiscales *

Pablo Cachaga Herrera

Martin Vallejos Tarqui

RESUMEN

Este documento compara la capacidad predictiva de las variables monetarias y fiscales sobre la actividad económica de Bolivia, utilizando modelos de *machine learning* y TVP-VAR. Los resultados muestran ventajas complementarias: el *machine learning* destaca en contextos estables por su capacidad para captar relaciones no lineales, mientras que el TVP-VAR ofrece mayor precisión ante cambios estructurales. Además, el análisis de impulso-respuesta del modelo TVP-VAR indica que los choques monetarios impulsan el crecimiento inicialmente, mientras que los choques fiscales generan efectos positivos en el largo plazo. Se recomienda el uso combinado de ambos enfoques para mejorar las proyecciones económicas y respaldar la toma de decisiones en política económica.

Clasificación JEL: C3, E51, E62, O47

Palabras clave: Proyecciones del crecimiento económico, Machine Learning, modelo TVP-VAR

* El contenido del presente documento es de responsabilidad de los autores y no compromete la opinión del Banco Central de Bolivia.

Nonlinear models for predicting leading GDP indicators using monetary and fiscal variables *

Pablo Cachaga Herrera

Martin Vallejos Tarqui

ABSTRACT

This document compares the predictive capacity of monetary and fiscal variables on Bolivia's economic activity using Machine Learning and TVP-VAR models. The results show complementary advantages: Machine Learning stands out in stable contexts due to its ability to capture nonlinear relationships, while TVP-VAR offers greater accuracy in the face of structural changes. Additionally, the impulse-response analysis from the TVP-VAR model indicates that monetary shocks initially stimulate growth, while fiscal shocks generate positive effects in the long term. The combined use of both approaches is recommended to improve economic forecasts and support economic policy decision-making.

JEL Classification: C3, E51, E62, O47

Keywords: *Proyecciones del crecimiento económico, Machine Learning, modelo TVP-VAR*

* The content of this document is the responsibility of the authors and does not represent the opinion of the Central Bank of Bolivia.

I. Introducción

La predicción de la evolución futura del crecimiento del Producto Interno Bruto (PIB) es una preocupación central para las autoridades y los hacedores de política económica. Los pronósticos se realizan, típicamente, a partir de modelos basados en la teoría económica o de modelos de series temporales lineales. No obstante, aunque un modelo de series temporales puede ser útil como punto de referencia para evaluar el valor agregado de la teoría económica en comparación con el poder explicativo del comportamiento pasado de la variable, los avances recientes en el análisis de series temporales indican que, enfoques más sofisticados, incluidos los modelos no lineales, podrían ofrecer predicciones más precisas para la proyección de variables económicas. En particular, dado que el PIB no sigue un comportamiento lineal, los modelos no lineales se convierten en una herramienta esencial para realizar pronósticos más ajustados a la realidad económica.

La implementación de modelos no lineales en la predicción del crecimiento del PIB ofrece diversas ventajas. En particular, los avances recientes en el campo del *Machine Learning* han abierto nuevas oportunidades para mejorar la precisión de los pronósticos económicos. En este documento, se estima, por un lado, un modelo de *Machine Learning*, el cual permite identificar patrones no lineales complejos y adaptarse de manera flexible a las dinámicas cambiantes de la economía. Además, se examina el modelo TVP-VAR (Time-Varying Parameter Vector Autoregressive), que permite que los parámetros del modelo varíen a lo largo del tiempo, lo cual lo hace especialmente adecuado para capturar las dinámicas no lineales y la variabilidad estructural que caracteriza al crecimiento del PIB. De esta forma, se busca evaluar si estos enfoques avanzados ofrecen mejoras significativas en términos de precisión y robustez en los pronósticos del crecimiento del PIB para Bolivia.

Luego de esta breve introducción, el documento se divide en cuatro partes: en la sección dos se presenta una revisión de la literatura existente; en la sección tres se expone las metodologías que se desarrollarán a lo largo del trabajo; en la sección cuatro se muestran los principales resultados obtenidos; y, finalmente, en la sección cinco se ofrecen algunas conclusiones y recomendaciones basadas en los hallazgos del estudio.

II. Revisión de la literatura

La literatura existente arguye que la mayoría de los indicadores económicos presentan un comportamiento caracterizado por alta volatilidad que cambia con el tiempo, debido a que se producen transformaciones de regímenes que implican ajustes en la política económica. Según la Crítica de Lucas (Lucas, 1976), los agentes económicos racionales consideran estos cambios estructurales al momento de la toma de decisiones. Esto sugiere que los modelos macroeconómicos, tales como vectores autorregresivos, no pueden asumir que los parámetros permanezcan constantes a lo largo del tiempo ya que los cambios estructurales en la economía exigen una adaptación continua de dichos parámetros para reflejar con precisión las dinámicas económicas.

En este contexto, los modelos de vectores autorregresivos con parámetros variables (TVP-VAR, por sus siglas en inglés) se han consolidado como una herramienta clave para el análisis estructural y la predicción de los principales indicadores macroeconómicos. Entre los primeros trabajos en utilizar modelos VAR con parámetros variables son los de (Cogley & Sargent, *Evolving Post-World War II US Inflation Dynamics*, 2002), Cogley y Sargent (2005) y (Cogley & Sbordone, *Trend Inflation, Indexation, and Inflation Persistence in the New Keynesian Phillips Curve*, 2008) quienes analizan los posibles cambios en la dinámica de la tasa de inflación de EE. UU. Por su parte, (D'Agostino, Gambetti, & Giannone, 2013) arguyen que los modelos TVP-VAR proporcionan pronósticos más precisos de la inflación y la tasa de desempleo de EE. UU. que los VAR de coeficiente fijo.

Entre los principales trabajos que analizan la relación entre las variables monetarias y la actividad económica son (Friedman y Schwartz, 1971), quienes señalan que la evolución de la oferta monetaria en Estados Unidos, desde finales del siglo XIX hasta mediados del siglo XX, ha tenido un impacto profundo y duradero en la economía del país. Los autores argumentan que las fluctuaciones en la cantidad de dinero disponible en la economía han sido un factor crucial para explicar las grandes crisis económicas como la Gran Depresión de 1929. Por su parte, Baumgartner *et al.*, 1997 señalan que agregados monetarios permiten prever, con cierta anticipación, cambios en la actividad económica y ajustar la política monetaria de manera preventiva. En este contexto, la utilización de

indicadores monetarios para efectuar predicciones del PIB constituiría un aporte valioso y estratégico para la economía boliviana. Al anticipar las tendencias económicas a través del análisis de la oferta monetaria, se podría mejorar la precisión en la formulación de políticas económicas. Esto permitiría una gestión económica más proactiva y eficiente, contribuyendo a la estabilidad y al crecimiento sostenido del país.

De similar forma, Benos (2004) identifica un impacto no lineal de los impuestos distorsionantes sobre el crecimiento económico. Sin embargo, la forma de esta no linealidad resulta sensible al método de estimación utilizado. En ocasiones se observa una relación con forma de joroba, mientras que en otras predomina una curva en forma de U. Además, el análisis destaca que el superávit presupuestario ejerce un efecto positivo y significativo sobre el crecimiento económico. Por su parte, Rant *et al.* (2024) analizan cómo los *shocks* fiscales afectan la evolución del PIB en distintos horizontes temporales, evidenciando que las políticas fiscales tienen efectos significativos pero temporales sobre la actividad económica. Además, identifica que ciertas variables fiscales actúan como indicadores adelantados útiles para mejorar la precisión de las proyecciones macroeconómicas. Estos hallazgos sugieren que incorporar variables fiscales en modelos VAR enriquece el análisis económico y facilita una toma de decisiones más informada, especialmente en contextos de incertidumbre o cambios estructurales, resaltando la importancia de entender la interacción dinámica entre las políticas fiscales y la economía real para diseñar medidas más efectivas.

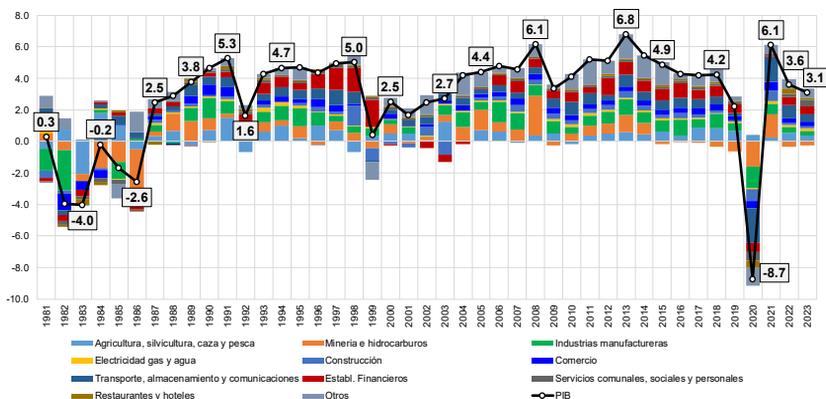
III. Metodología y análisis de datos

III.1. Datos

Entre 1980 y 2023, el crecimiento del PIB mostró un comportamiento dinámico. Durante la década de los 80, casi todos los sectores experimentaron tasas negativas debido al aumento insostenible de los precios (hiperinflación), lo que afectó negativamente al producto total. Sin embargo, en los años 90, como resultado de los ajustes estructurales implementados bajo la Nueva Política Económica, se produjo una recuperación de la actividad económica, destacándose principalmente el sector industrial.

Durante los primeros cinco años de la década de 2000, la economía experimentó una desaceleración atribuida, principalmente, a problemas sociales y a un contexto internacional desafiante. Sin embargo, a partir de 2006 todos los sectores comenzaron a contribuir positivamente a la actividad económica, destacando especialmente los sectores de minería e hidrocarburos. Esto se debió tanto al entorno internacional favorable como a las políticas de renegociación de contratos de exploración y explotación de hidrocarburos, en el marco de la Ley N° 3058 del 25 de mayo de 2005.

Gráfico 1: TASA DE CRECIMIENTO DEL PRODUCTO INTERNO BRUTO, 1981 – 2023 (En porcentaje)



Fuente: Elaboración propia con datos del Instituto Nacional de Estadísticas

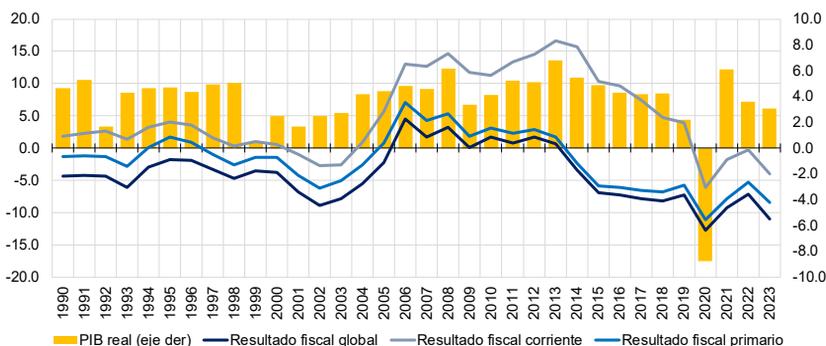
Después de la crisis sanitaria del COVID-19, la mayoría de los sectores no lograron una recuperación plena. Por otro lado, el sector de hidrocarburos experimentó una incidencia negativa debido a la disminución en la producción de los campos hidrocarburíferos. Estos factores representan un desafío significativo para la predicción de la actividad económica en la coyuntura actual, ya que la incertidumbre sobre la recuperación de los sectores afectados por la crisis sanitaria y la falta de estabilidad en el sector de hidrocarburos dificultan la formulación de proyecciones confiables.

Desde 2006, en el marco del Modelo Económico Social Comunitario Productivo (MESCP), el sector público ha desempeñado un papel

fundamental en la economía, implementando una política fiscal expansionista orientada a estimular la actividad económica. Esta estrategia ha estado centrada en un aumento significativo de la inversión pública en sectores estratégicos (producción, infraestructura, social y multisectorial) con el objetivo de impulsar la demanda interna y disminuir la dependencia de las importaciones. En este contexto, el resultado del balance global del sector público registró déficits desde la gestión 2014 explicado por mayor gasto de capital ya que el resultado corriente registraba superávits.

En este contexto, aunque el resultado corriente del sector público mostraba superávits, el aumento en las inversiones públicas y la asignación de recursos para proyectos de infraestructura y desarrollo estratégico generaron un desajuste fiscal, manifestándose en los déficits globales desde 2014. Este comportamiento refleja una estrategia de gasto orientada a la inversión a largo plazo que, si bien puede ser necesaria para el impulso del crecimiento y la mejora de la infraestructura, también plantea riesgos en términos de sostenibilidad fiscal si no se controla adecuadamente el nivel de endeudamiento o no se generan los ingresos suficientes para financiar estos gastos.

Gráfico 2: CRECIMIENTO ECONÓMICO Y BALANCE FISCAL
(En tasa de crecimiento y en porcentaje del PIB)



Fuente: Elaboración propia con datos del Ministerio de Economía y Finanzas Públicas

Dada la relevancia del sector público en la economía, las variables fiscales se configuran como un instrumento esencial para realizar proyecciones de la actividad económica, ya que permiten evaluar de manera más exacta el impacto de las políticas públicas en el crecimiento económico. La

capacidad del Estado para ajustar su política fiscal a través de cambios en los impuestos, el gasto público y la inversión en sectores estratégicos, incide directamente en el desempeño de la actividad económica. Estos ajustes no solo afectan el corto plazo, sino que también influyen en la trayectoria a largo plazo de la economía.

En este contexto, se puede asumir que existe una relación estrecha entre la recaudación tributaria y el crecimiento económico. En términos generales, el crecimiento de una economía se refleja en un aumento en los ingresos monetarios tanto de individuos como de empresas, lo que, a su vez, incrementa la base imponible y puede generar una mayor recaudación tributaria. En este contexto, impuestos como la renta aduanera, renta interna y el impuesto al valor agregado tienden a crecer proporcionalmente con la expansión económica.

Sin embargo, esta relación podría ser no es lineal, ya que la capacidad de recaudación también depende de factores como la eficiencia del sistema tributario, la estructura impositiva vigente y el cumplimiento fiscal. Además, una mayor recaudación tributaria contribuye al financiamiento de políticas públicas y a la inversión en infraestructura, lo que podría potenciar aún más el crecimiento económico.

Por otro lado, la oferta monetaria también desempeña un papel crucial en el crecimiento económico al incidir directamente sobre la demanda agregada, el consumo y la inversión. Un incremento moderado de la oferta monetaria puede estimular el crecimiento económico al facilitar el acceso al crédito y fomentar el gasto tanto de consumidores como de empresas. Sin embargo, un aumento desmesurado de la oferta monetaria puede generar presiones inflacionarias, lo que podría llevar a una pérdida del poder adquisitivo y a una desaceleración de la actividad económica, afectando negativamente tanto la confianza del consumidor como las decisiones de inversión. Por lo tanto, el equilibrio en la gestión de la oferta monetaria es fundamental para sustentar un crecimiento económico sostenido y estable.

La teoría sugiere que, en un escenario ideal donde la velocidad del dinero es constante, el crecimiento de la oferta monetaria debe coincidir con la suma de la inflación y el crecimiento del PIB real.

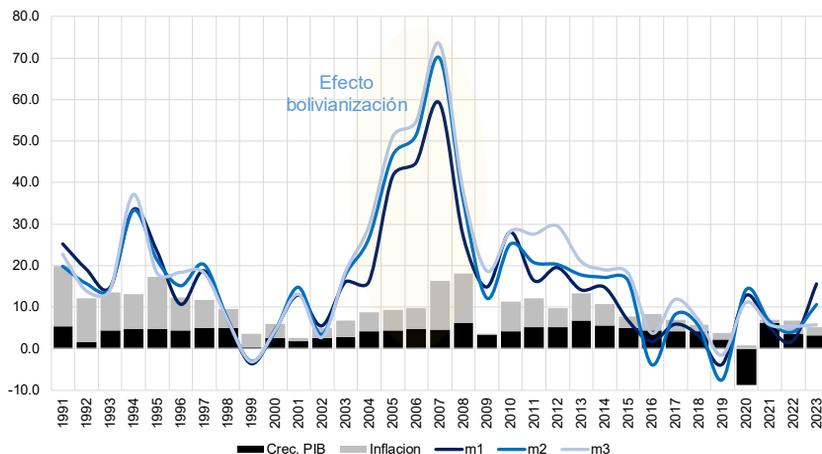
$$MV = PY$$

donde M representa la oferta monetaria, V velocidad de dinero, P nivel de precios y Y es el nivel de la producción. Aplicando logaritmos y considerando que la velocidad del dinero es constante, podemos reescribir la ecuación de intercambio de la siguiente forma:

$$\Delta m_t = \Delta gdp_t + \Delta_t$$

Este modelo es importante para comprender los efectos de la política monetaria sobre la economía, pero debe ser considerado con precaución, ya que en la práctica pueden intervenir múltiples factores que afectan la inflación y el crecimiento económico. Por ejemplo, en la práctica, factores como la preferencia por efectivo ante la incertidumbre económica o las expectativas especulativas sobre el tipo de cambio pueden generar impacto inmediato de un aumento en la oferta monetaria sobre la inflación. Esto es especialmente relevante cuando el crecimiento de la oferta monetaria supera al del producto, ya que tales factores pueden aumentar la demanda de efectivo por parte de la población, lo que a su vez podría generar presiones inflacionarias adicionales.

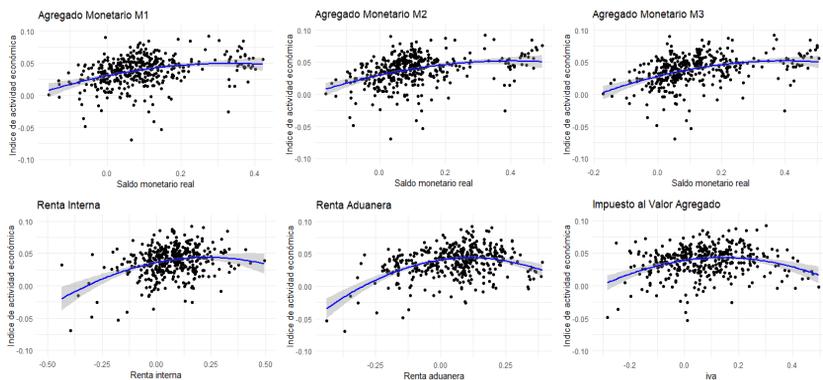
Gráfico 3: TASA DE CRECIMIENTO ECONÓMICO, INFLACIÓN Y VARIABLES MONETARIAS (En porcentaje)



Fuente: Elaboración propia con datos del Instituto Nacional de Estadísticas y Banco Central de Bolivia

El Gráfico 4 revela una correlación positiva entre el crecimiento económico, los saldos monetarios reales y las variables fiscales. Esta relación sugiere que un aumento en la oferta monetaria impulsa la producción, dado que un mayor volumen de dinero en circulación tiende a estimular la actividad económica. Sin embargo, el análisis muestra que un incremento excesivo de los saldos monetarios reales podría tener un efecto adverso, desacelerando la economía, lo que sugiere una relación de tipo no lineal en la que los efectos no son proporcionales ni constantes. Por otro lado, la correlación entre la actividad económica y las variables fiscales tampoco sigue una tendencia lineal. Esto implica que el impacto de las políticas fiscales sobre el crecimiento económico varía según el nivel de actividad, lo que sugiere que tanto el gasto público como la carga tributaria pueden tener efectos dispares en función de la fase del ciclo económico en que se encuentren.

Gráfico 4: DIAGRAMA DE DISPERSIÓN



Fuente: Elaboración propia

III.2. Machine learning

III.2.1. Random Forest

El algoritmo *Random Forest* es un modelo de aprendizaje supervisado basado en árboles de decisión, propuesto por Breiman (2001), que se ha consolidado como una herramienta robusta para la predicción en contextos no lineales y de alta dimensionalidad. Su aplicabilidad en problemas económicos y financieros ha crecido exponencialmente debido

a su capacidad para capturar relaciones complejas entre variables y mitigar el sobreajuste característico de los modelos de árboles individuales.

Random Forest construye un conjunto (o bosque) de árboles de decisión entrenados sobre distintas muestras del conjunto de datos mediante la técnica de *bootstrap aggregating* o *bagging*. Para cada árbol, además de utilizar una muestra aleatoria con reemplazo, se selecciona aleatoriamente un subconjunto de variables predictoras en cada partición del árbol, lo cual introduce diversidad en el modelo y reduce la correlación entre árboles individuales (Hastie et al., 2009).

Matemáticamente, sea $D = \{(x_i, y_i)\}_{i=1}^N$ el conjunto de entrenamiento, donde $x_i \in \mathbb{R}^p$ son los predictores (variables monetarias y fiscales en este estudio), e $y_i \in \mathbb{R}$ es la variable objetivo (indicador adelantado del PIB). Cada árbol T_b del bosque es entrenado sobre una muestra D_b de tamaño N con reemplazo, y el conjunto total de árboles $\{T_1, \dots, T_B\}$ produce una predicción agregada:

$$\hat{f}_{RF}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x)$$

En tareas de regresión, esta agregación se realiza mediante el promedio de las predicciones de todos los árboles.

En el contexto macroeconómico, *Random Forest* permite modelar relaciones no lineales entre los agregados fiscales (como gasto público, impuestos) y monetarios (como tasas de interés, crecimiento del crédito, M2) con indicadores adelantados del PIB, sin requerir una especificación funcional *a priori*. Esta flexibilidad es particularmente valiosa en entornos caracterizados por alta incertidumbre estructural y relaciones dinámicas complejas.

Además, *Random Forest* ofrece medidas internas de importancia de variables, que pueden ser utilizadas para identificar los determinantes más relevantes de la actividad económica, lo que añade valor interpretativo al enfoque no paramétrico (Bhadury et al., 2021).

Las ventajas de este modelo radican en el manejo robusto de la multicolinealidad, muy buena capacidad para capturar efectos de

interacción y no linealidades, además de tener una baja varianza en comparación con modelos de árboles individuales y tienen resistencia al sobreajuste, especialmente con un número adecuado de árboles. Sin embargo, también tiene sus desventajas ya que en algunos casos tienen menor interpretabilidad en comparación con modelos paramétricos tradicionales y mayor carga computacional, especialmente en presencia de grandes conjuntos de datos.

III.2.2. Modelo TVP-VAR

En esta sección se presenta el modelo TVP-VAR en línea con Primiceri (2005), Justiniano y Primiceri (2008), Del Negro y Primiceri (2015), Chan (2023), entre otros, que permite capturar los cambios en las relaciones entre variables a lo largo del tiempo. Esta capacidad lo convierte en una herramienta especialmente útil para el análisis de políticas económicas y para la predicción del crecimiento económico, sobre todo en contextos de cambios estructurales. El modelo TVP-VAR se puede representar de la siguiente forma:

$$A_t y_t = b_t + B_{1,t} y_{t-1} + \dots + B_{p,t} y_{t-p} + \varepsilon_t^y, \quad \varepsilon_t^y \sim \mathcal{N}(0, \Omega_t) \quad (1)$$

donde y_t es el vector $n \times 1$ de variables endógenas, b_t representa el vector $n \times 1$ de interceptos que varían en el tiempo, $B_{1,t} \dots B_{p,t}$ es una matriz de tamaño $n \times n$ de los parámetros variables en el tiempo, A_t representa una matriz triangular inferior $n \times n$ con valores unos en el diagonal, ε_t^y son shocks no observables heterocedásticos con una matriz de varianza-covarianza $\Omega_t = \text{diag}(\exp(h_{1,t}), \dots, \exp(h_{n,t}))^1$. Considerando que $b_{i,t}$ es el elemento i -ésimo de b_t y $B_{i,j,t}$ es la i -ésima fila de $B_{j,t}$, el parámetro variante del modelo VAR de la ecuación i -ésima se podrá expresar de la siguiente forma $\beta_{i,t} = (b_{i,t}, B_{i,1,t}, \dots, B_{i,p,t})$. Efectuando algunas operaciones algebraicas, la ecuación 1 se representa de la siguiente forma:

1 La matriz triangular de Ω_t viene definida por: $A_t \Omega_t A_t' = \Sigma_t \Sigma_t'$, donde A_t es una matriz triangular inferior:

$$A_t = \begin{pmatrix} 1 & 0 & \dots & 0 \\ \alpha_{21,t} & 1 & \ddots & \vdots \\ \vdots & \ddots & 1 & 0 \\ \alpha_{n1,t} & \dots & \alpha_{nn-1,t} & 1 \end{pmatrix}$$

y la matriz diagonal Ω_t está definido por:

$$\Omega_t = \begin{pmatrix} \sigma_{1,t} & 0 & \dots & 0 \\ 0 & \sigma_{2,t} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \sigma_{n,t} \end{pmatrix}$$

$$y_t = X_t' B_t + A_t^{-1} \Omega_t \varepsilon_t$$

$$X_t' = I_n \otimes [1, y_{t-1}', \dots, y_{t-k}'] \tag{2}$$

donde el símbolo \otimes denota el producto de Kroneker. En línea con Cogley (2001), y Cogley y Sargent (2005), es fundamental que la innovación i -ésima de la matriz A_t tenga un efecto variante sobre la j -ésima variable X_t' en el tiempo. Asimismo, los componentes de A_t se consideran como diferentes a cero y a la unidad. La dinámica de los parámetros del modelo que varían en el tiempo se especifica de la siguiente forma:

$$B_t = B_{t-1} + v_t \tag{3}$$

$$\alpha_t = \alpha_{t-1} + \zeta_t \tag{4}$$

$$\log(\sigma_t) = \log(\sigma_{t-1}) + \eta_t \tag{5}$$

Los elementos de B_t y α_t siguen un proceso de caminata aleatoria, mientras que la desviación estándar de los elementos del σ_t evoluciona como una caminata aleatoria geométrica (volatilidad estocástica). Se asume que todas las innovaciones en el modelo están conjuntamente distribuidas de manera normal asumiendo la siguiente matriz de varianza-covarianza:

$$Var \begin{pmatrix} \varepsilon_t \\ v_t \\ \zeta_t \\ \eta_t \end{pmatrix} = \begin{bmatrix} I_n & 0 & 0 & 0 \\ 0 & Q & 0 & 0 \\ 0 & 0 & S & 0 \\ 0 & 0 & 0 & W \end{bmatrix} \tag{6}$$

en la ecuación 6, se asume que los coeficientes de las relaciones contemporáneas entre las variables evolucionan de manera independiente en cada ecuación. Aunque no es crucial, esta suposición simplifica la inferencia y aumenta la eficiencia del algoritmo de estimación, (Shephard, 1994 y Uhlig, 1997). La simulación de los resultados se efectúa mediante la inferencia bayesiana, por ende, la inicialización de la secuencia de la distribución *a priori* de B_t esta dada por: $p(\beta_0) \sim \mathcal{N}(\beta_0, Q_0)$. La simulación *a posteriori* de los parámetros, se efectúa mediante la simulación de Markov Chain Monte Carlo (MCMC) y los estados latentes se ejecutan con filtro de Kalman.

IV. Resultados

IV.1. Resultados del modelo *Random Forest*

Para la estimación del modelo de *Random Forest*, se emplearon 34 variables mensuales de naturaleza monetaria y cambiaria, utilizando el Índice Global de la Actividad Económica (IGAE) como variable dependiente (ver Apéndice A). La muestra abarca el período comprendido entre junio de 2000 y diciembre de 2023.

Como parte del pre procesamiento, las variables nominales fueron convertidas a términos reales mediante la deflactación con el Índice de Precios al Consumidor (IPC), permitiendo así un análisis ajustado por inflación. Posteriormente, se calcularon las tasas de crecimiento interanuales para cada variable, con el objetivo de capturar tendencias y fluctuaciones relativas a lo largo del tiempo. Esta transformación también contribuye a la estabilización de las series y a la mejora del desempeño predictivo del modelo.

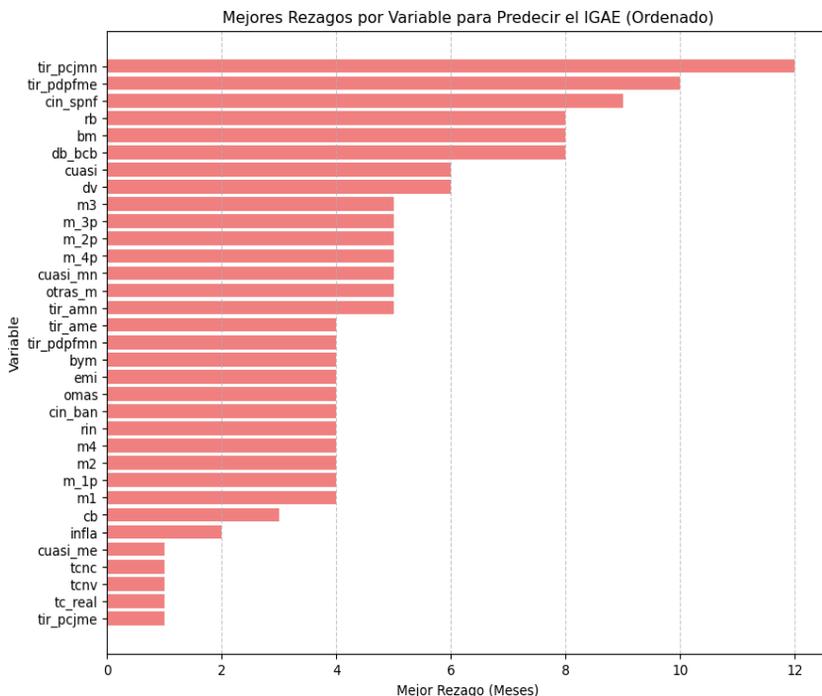
El Gráfico 5 muestra los mejores rezagos, en meses, para diferentes variables macroeconómicas en relación con su capacidad predictiva de los indicadores adelantados del PIB. Destaca que la tasa de interés real pasiva de cajas de ahorro en moneda nacional (*tir_pjmn*) y la tasa de interés real pasiva de depósitos a plazo fijo en moneda extranjera (*tir_ppdfpme*) presentan los mayores rezagos óptimos, alcanzando hasta 12 meses. Estas variables reflejan con mayor sensibilidad las expectativas de los agentes económicos y las condiciones del mercado crediticio (Bernanke y Blinder, 1992 y Mishkin, 1996).

Asimismo, variables monetarias como la base monetaria (*bm*), los depósitos bancarios en el Banco Central de Bolivia (*db_bcb*) y los agregados monetarios (*m3*, *m2*) muestran rezagos entre 6 y 8 meses, lo que sugiere una relación anticipada con la evolución del PIB. Este comportamiento podría estar asociado a la dinámica de liquidez y la respuesta de la política monetaria (Friedman, 1968 y Taylor, 1993).

En contraste, indicadores como el tipo de cambio real y nominal de venta (*tc_real*, *tc_nv*) y la inflación (*infla*) exhiben rezagos más reducidos, lo que implica una menor capacidad predictiva a largo plazo. Estos resultados

subrayan la importancia de seleccionar cuidadosamente los rezagos en modelos de predicción, considerando la naturaleza y la temporalidad de cada variable en el contexto de análisis macroeconómico (Stock y Watson, 2003), (ver Apéndice B).

Gráfico 5: MEJORES REZAGOS POR VARIABLE PARA PREDECIR EL IGAE



Fuente: Elaboración propia

Para la estimación del IGAE se empleó un muestreo con reemplazo para mejorar la estabilidad del modelo y se utilizó el error cuadrático medio como criterio de pérdida, adecuado para problemas de regresión. La profundidad de los árboles no tuvo restricciones, permitiendo una mayor capacidad de captura de relaciones complejas. El modelo incluyó 100 árboles de decisión, equilibrando precisión y tiempo de cómputo. Para las divisiones y creación de hojas, se establecieron valores mínimos de una muestra por hoja y dos muestras por división. Además, se consideraron

todos los atributos disponibles en cada división, maximizando la identificación de patrones. Finalmente, para garantizar la reproducibilidad, se fijó una semilla aleatoria (42) y no se aplicó poda de complejidad posterior.

En el Gráfico 6 se observa un ajuste razonablemente preciso durante la mayor parte del período analizado (2000-2023), con la línea roja de predicción siguiendo de cerca la trayectoria de la serie observada (línea azul). La capacidad del modelo para capturar las fluctuaciones cíclicas y tendencias de la actividad económica sugiere que las variables monetarias y cambiarias incluidas poseen un significativo poder explicativo. Esto coincide con estudios previos que destacan la efectividad de los modelos de Machine Learning en la predicción de indicadores macroeconómicos, especialmente en presencia de relaciones no lineales y complejas (Medeiros *et al.*, 2021 y Varian, 2014).

Sin embargo, se evidencia una discrepancia más pronunciada durante eventos de alta volatilidad, como la crisis financiera global de 2008-2009 y el impacto económico de la pandemia de COVID-19 en 2020. En estos casos, aunque el modelo logra capturar la dirección general de los cambios, no refleja con total exactitud las magnitudes extremas. Este fenómeno es característico de modelos de Machine Learning que, si bien son robustos en la predicción de comportamientos regulares, tienden a subestimar o sobrestimar eventos extremos (Chakraborty y Joseph, 2017).

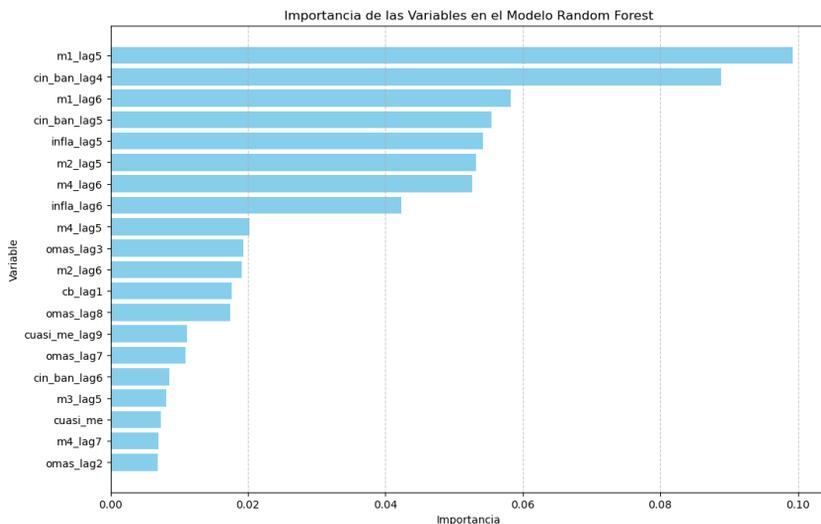
Estos resultados resaltan la importancia de complementar el análisis con otros enfoques, como modelos estructurales o de simulación, para mejorar la interpretación económica en escenarios de crisis. Además, la incorporación de variables adicionales, como indicadores de incertidumbre o variables exógenas de eventos globales, podría fortalecer la capacidad predictiva del modelo.

**Gráfico 6: TASA DE CRECIMIENTO DEL IGAE OBSERVADO
 Y PREDICHO CON MODELO RANDOM FOREST
 (En porcentaje)**



Fuente: Elaboración propia

El análisis de la importancia de las variables en el modelo *Random Forest* revela que los agregados monetarios ($m1$ y $m2$) y el crédito bancario (cin_ban) con rezagos de 4 a 6 meses tienen una influencia significativa en el IGAE. Esto es consistente con la teoría económica, que establece que la liquidez y el crédito impulsan el consumo y la inversión, reflejándose en la actividad económica con cierto desfase temporal (Friedman, 1987 y Bernanke y Gertler, 1989). Asimismo, la inflación pasada (Infla) también muestra una alta relevancia, lo que sugiere que las expectativas inflacionarias impactan en las decisiones económicas (Taylor, 1993 y Svensson, 1997). La predominancia de estos rezagos indica que el modelo captura eficazmente las dinámicas no lineales del sistema económico, proporcionando una herramienta valiosa para proyecciones a corto plazo y para evaluar el impacto de decisiones de política monetaria (Stock y Watson, 2002 y (Diebold F. X., 2015).

Gráfico 7: IMPORTANCIA DE LAS VARIABLES EN EL MODELO RANDOM FOREST

Fuente: Elaboración propia

IV.2. Resultados del modelo Random Forest para las variables fiscales

En este caso, para la estimación del modelo Random Forest, se emplearon 36 variables relacionadas al sector fiscal con frecuencia mensual, utilizando como variable dependiente el IGAE (ver Apéndice A). La muestra abarca el período comprendido entre enero de 2000 y diciembre de 2023.

Durante el pre procesamiento, las series nominales fueron transformadas a términos reales mediante su deflactación con el IPC. Posteriormente, se calcularon las tasas de crecimiento interanual, con el fin de capturar dinámicas relativas y estabilizar las series temporales, mejorando así la capacidad predictiva del modelo.

El Gráfico 5 presenta los mejores rezagos (en meses) de cada variable explicativa, de acuerdo con su importancia en la predicción del IGAE. Entre las variables fiscales, destacan:

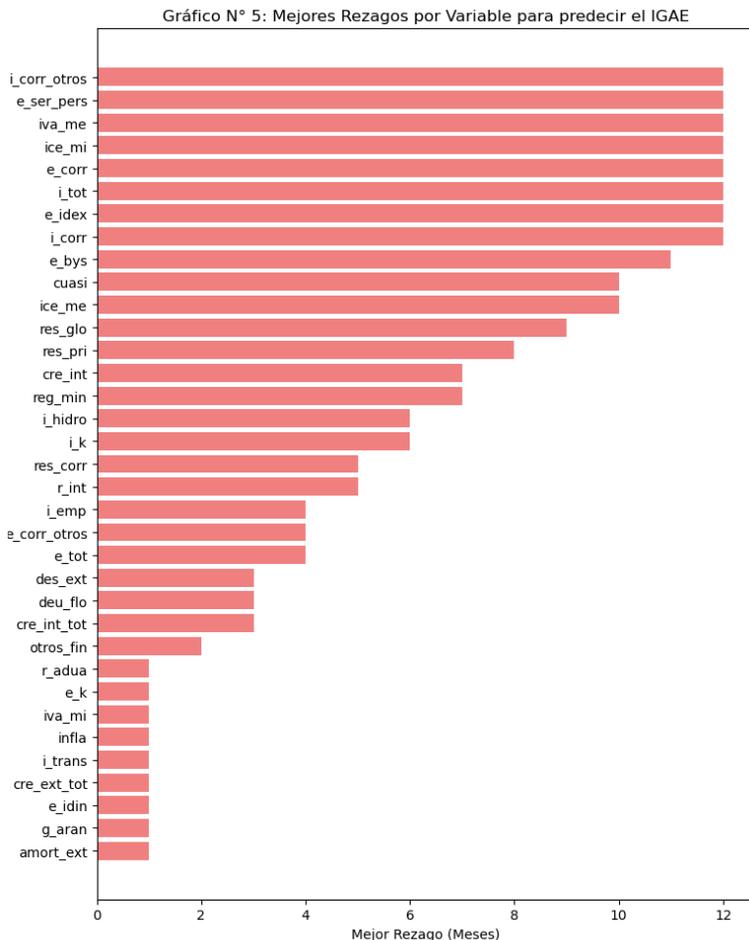
- Ingresos tributarios como el IVA Mercado Interno (*iva_mi*), el ICE Mercado Interno (*ice_mi*) y el IVA Mercado Externo (*iva_me*), cuyos

rezagos óptimos varían entre 8 y 10 meses. Estos ingresos reflejan la actividad económica del sector formal y están correlacionados con los ciclos del consumo interno y externo (Tanzi y Zee, 2000).

- Egresos corrientes del sector público (*e_corr*) y servicios personales (*e_ser_pers*) también presentan altos rezagos predictivos. Estas variables son indicativas del gasto público y reflejan el impulso fiscal sobre la demanda agregada con un retardo estructural.
- El comportamiento de los resultados fiscales (*res_glo*, *res_corr* y *res_pri*), aunque con rezagos intermedios (5-6 meses), también aporta información valiosa sobre las condiciones de sostenibilidad macroeconómica y el espacio fiscal disponible (Blanchard, 1990).
- Créditos internos y externos netos al sector público (*cre_int*, *cre_ext_tot*) y variables de deuda pública como desembolsos externos (*des_ext*) y amortizaciones (*amort_ext*) reflejan la financiación del déficit fiscal y su posible impacto sobre la inversión y la liquidez en la economía.

Estos resultados son consistentes con la literatura sobre el efecto rezagado de la política fiscal en la actividad económica, destacando que los impulsos fiscales no son inmediatos y dependen de la eficiencia del gasto, el tipo de financiamiento y la sensibilidad de la inversión y el consumo privado (Auerbach y Gorodnichenko, 2012 y Ilzetzki *et al.*, 2013).

En contraste, la inflación presenta rezagos más cortos, indicando una menor capacidad predictiva en el largo plazo. Este hallazgo sugiere que las variables fiscales estructurales tienen una mayor capacidad anticipatoria sobre la dinámica del PIB (ver Apéndice B).

Gráfico 8: MEJORES REZAGOS POR VARIABLE PARA PREDECIR EL IGAE

Fuente: Elaboración propia

Para la estimación del IGAE mediante *Random Forest*, se utilizaron exclusivamente variables fiscales con frecuencia mensual, entre las cuales se incluyen ingresos tributarios reales, egresos corrientes y de capital, resultados fiscales, financiamiento interno y externo, y amortizaciones de deuda pública, transformadas en tasas de crecimiento interanual

deflactadas por el IPC. Esta transformación permitió trabajar con series estacionarias y comparables, mejorando la capacidad predictiva del modelo.

Se generaron rezagos de hasta 12 meses para cada variable fiscal, lo que permitió capturar los efectos diferidos de la política fiscal sobre la actividad económica, en línea con la literatura sobre multiplicadores fiscales y rezagos de implementación (Auerbach y Gorodnichenko, 2012). Los rezagos fueron tratados como atributos independientes dentro del modelo, lo que permitió al algoritmo seleccionar aquellos con mayor relevancia de forma automática.

El modelo fue entrenado con 100 árboles de decisión, sin restricción en la profundidad, lo que otorgó una elevada capacidad para modelar relaciones no lineales y estructuras de interacción complejas entre las variables fiscales. Se empleó muestreo con reemplazo (*bootstrap*) en cada iteración, lo que mejoró la robustez del estimador y redujo la varianza.

Para la división de nodos y creación de hojas, se fijaron como parámetros mínimos una muestra por hoja y dos muestras por nodo de división, lo que garantiza que cada árbol explore suficientes combinaciones de variables sin sobre ajustarse. En cada división del árbol, se consideraron todos los predictores disponibles, lo que maximiza la capacidad de detección de patrones relevantes entre las variables fiscales. Se fijó una semilla aleatoria de 42 para garantizar la reproducibilidad de los resultados. No se aplicó poda posterior de complejidad, permitiendo que cada árbol explorara libremente todas las posibles ramificaciones en función de los criterios de división interna.

El Gráfico 6 presenta la comparación entre el IGAE observado y el IGAE predicho a partir del modelo *Random Forest* estimado con 36 variables fiscales transformadas en tasas de crecimiento real interanual. El modelo fue entrenado sobre la muestra mensual comprendida entre enero de 2000 y diciembre de 2023, aplicando rezagos de hasta 12 meses en cada variable explicativa, seleccionados según su capacidad predictiva óptima.

El ajuste observado es notoriamente robusto. El modelo logra replicar con alta fidelidad la trayectoria del IGAE durante la mayor parte del periodo analizado, en particular en las fases de expansión sostenida (2004–2014)

y de moderada desaceleración (2015–2019). Este buen desempeño se atribuye a la incorporación de variables fiscales con fuerte capacidad explicativa, como los ingresos tributarios reales, egresos corrientes del gobierno, y resultados fiscales acumulados, los cuales reflejan adecuadamente las condiciones de liquidez y gasto del sector público.

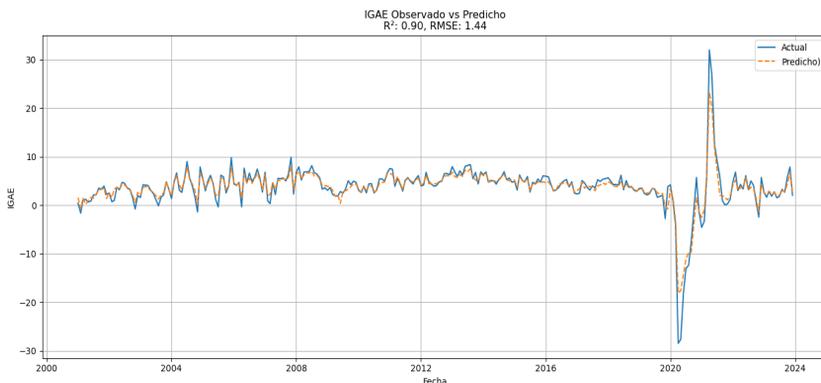
Durante el periodo más disruptivo —el año 2020, asociado a la pandemia de COVID-19— el modelo muestra una leve subestimación de la caída abrupta del IGAE. No obstante, capta correctamente la dirección del choque y, sobre todo, la recuperación económica posterior. Esta limitación se considera esperada, ya que el modelo fue entrenado con datos históricos sin eventos equivalentes de disrupción global y sin información anticipada sobre shocks sanitarios, institucionales o políticos (Stock & Watson, *Disentangling the Channels of the 2007-2009 Recession*, 2012). A pesar de ello, el desempeño posterior a la crisis sanitaria confirma la adaptabilidad del modelo frente a cambios de régimen.

La capacidad del modelo para seguir de cerca la evolución del IGAE en escenarios complejos y variables refuerza su potencial como herramienta de predicción en tiempo real (*nowcasting*). Su rendimiento es particularmente notable considerando que solo se utilizaron variables fiscales, lo que destaca la relevancia de estas para explicar la actividad económica agregada.

Este resultado valida la hipótesis planteada en la literatura económica respecto a que los efectos de la política fiscal sobre la producción operan con rezagos y que la evolución de variables como el gasto público, la recaudación tributaria y el financiamiento del déficit permiten anticipar los movimientos del PIB (Auerbach y Gorodnichenko, 2012, Blanchard, 1990 y Ilzetzki *et al.*, 2013).

En suma, el Gráfico 6 refleja la solidez del modelo *Random Forest* como instrumento predictivo, sustentado en variables fiscales estructurales. Su capacidad para modelar relaciones no lineales y su flexibilidad ante cambios de tendencia lo convierten en una herramienta idónea para la vigilancia económica y la toma de decisiones de política pública.

**Gráfico 9: TASA DE CRECIMIENTO DEL IGAE OBSERVADO Y PREDICHO
 MEDIANTE RANDOM FOREST
 (En porcentaje)**



Fuente: Elaboración propia

El Gráfico 7 muestra las variables más relevantes en el modelo Random Forest, ordenadas de acuerdo con su importancia relativa para la predicción del IGAE. La métrica de importancia utilizada corresponde al aumento medio en la reducción del MSE ponderado por nodos, una medida estándar en modelos de ensamble basada en árboles de decisión (Breiman, 2001). Se destacan los siguientes resultados:

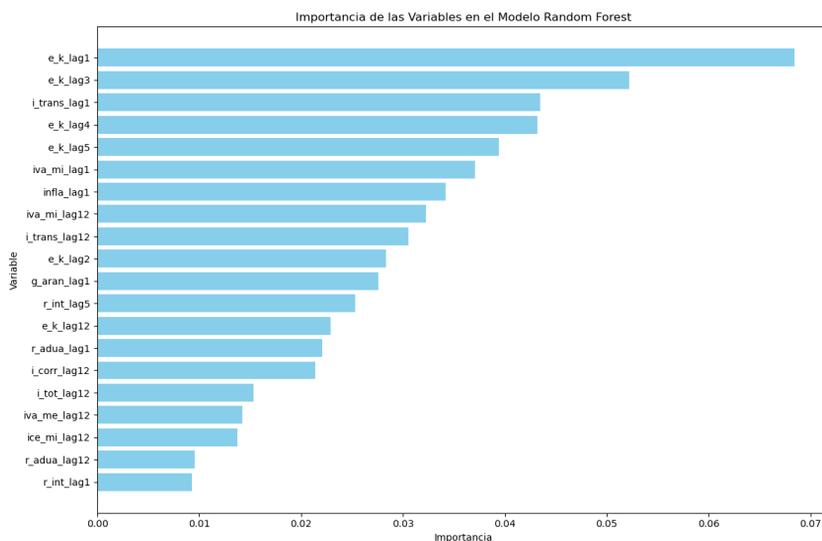
- La variable e_k_lag1 (egresos de capital reales rezagados un mes) emerge como la más importante del modelo. Esta variable captura los flujos de inversión pública en infraestructura y bienes duraderos, cuya sensibilidad al ciclo económico es alta, y cuya variación mensual parece tener un impacto inmediato sobre la actividad productiva. Este resultado refuerza la hipótesis de que el gasto público en capital tiene efectos multiplicadores de corto plazo sobre la economía (Auerbach y Gorodnichenko, 2012 y Ilzetzki *et al.*, 2013).
- Otras variantes de egresos de capital (e_k) también figuran entre las cinco principales variables (e_k_lag3 , e_k_lag4 y e_k_lag5), indicando un efecto persistente y acumulativo del gasto público de inversión sobre el IGAE, lo cual es consistente con la noción de rezagos distribuidos en la política fiscal.

- La variable i_trans_lag1 (ingresos por transferencias) también destaca como altamente significativa, lo que sugiere que ciertos ingresos extraordinarios o pagos transferidos al sector público pueden estar correlacionados con la ejecución del gasto y, por tanto, con el nivel de actividad agregada.
- El IVA mercado interno (iva_{mi}) y la inflación rezagada ($infla_{lag1}$) también aparecen como importantes. En el caso del IVA, se interpreta como un indicador contemporáneo de la demanda agregada formal, mientras que la inflación puede estar actuando como *proxy* de presiones de costos o demanda acumulada.
- Otros agregados fiscales relevantes son los ingresos aduaneros (r_adua), gravamen arancelario (g_aran) y los ingresos fiscales corrientes (i_corr), todos ellos con rezagos que oscilan entre 1 y 12 meses, reflejando diferentes ritmos de transmisión al IGAE.

La presencia simultánea de múltiples rezagos para una misma variable (por ejemplo, e_k en los meses 1, 2, 3, 4, 5 y 12) revela que el modelo *Random Forest* identifica relaciones no lineales y de largo alcance temporal, lo que representa una ventaja respecto a los modelos tradicionales que suelen asumir efectos contemporáneos o de rezago fijo.

En general, este gráfico respalda la hipótesis de que el comportamiento de las finanzas públicas —particularmente del gasto de capital— desempeña un papel central en la explicación y predicción de la dinámica del PIB mensual (IGAE). Además, confirma la utilidad de la metodología *Random Forest* para explorar relaciones económicas complejas con alta dimensionalidad y rezagos variables.

Gráfico 10: IMPORTANCIA DE LAS VARIABLES EN EL MODELO RANDOM FOREST



Fuente: Elaboración propia

IV.3. Resultados del modelo TVP-VAR

Para la predicción de la tasa de crecimiento económico se emplea variables monetarias y fiscales: Índice de Actividad Económica ($igae_t$), saldo monetario real ($m1_t$; $m2_t$; $m3_t$), recaudación tributaria (rt_t), recaudación aduanera (ra_t) e impuesto al valor agregado (iva_t). Adicionalmente, el modelo incluye tasa de Inflación ($infl_t$) y términos de intercambio (tot_t); la información de las variables seleccionadas es de frecuencia mensual que abarca desde 1991m1 hasta 2023m12. La información se recopiló de diversas fuentes, como el Instituto Nacional de Estadísticas, el Banco Central de Bolivia y el Ministerio de Economía y Finanzas Públicas. Para cada variable monetaria y fiscal, se estimó un modelo TVP-VAR distinto, que incluye cuatro variables.

De acuerdo a la estadística descriptiva expuesta en la Tabla 1, se destaca que la media y la mediana difieren en cada variable, lo que implica que las distribuciones son asimétricas. Además, se observan cifras altas de curtosis, lo que sugiere colas más pesadas y puede reflejar una alta volatilidad de

las variables en cuestión. La prueba de Jarque-Bera registra el rechazo de la hipótesis nula de distribución normal.

Por otro lado, de acuerdo a los resultados de raíz unitaria con quiebre estructural, se destaca que todas las variables registran al menos un quiebre durante periodo de estudio y se observa que las variables no son estacionarias (Apéndice A).

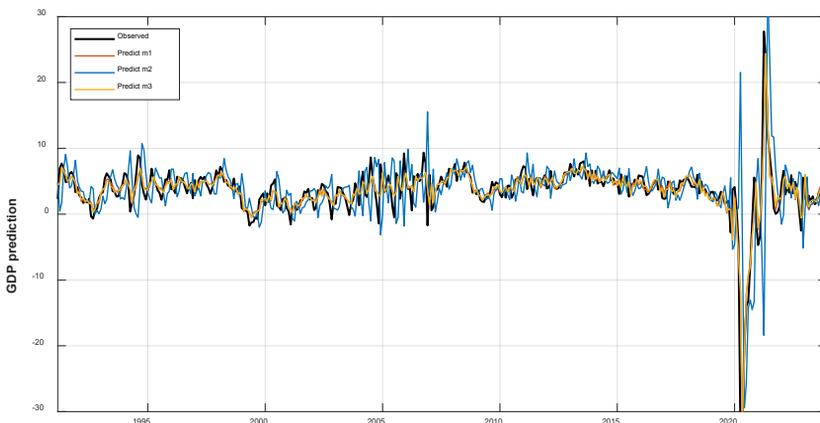
Tabla 1: ESTADÍSTICA DESCRIPTIVA

	igae	m2	m3	m4	ri	ra	iva	infl	tot
Mean	3.6	9.3	10.3	11.8	5.7	5.0	6.6	5.4	-1.4
Median	4.0	7.9	8.4	8.4	6.7	7.2	6.3	4.2	-1.4
Maximum	28.3	42.2	49.4	50.4	43.0	39.0	239.8	22.2	25.4
Minimum	-32.8	-15.7	-16.2	-17.0	-67.1	-43.7	-253.6	-1.3	-33.6
Std. Dev.	4.1	10.9	12.5	13.2	13.2	14.9	26.7	4.3	10.8
Skewness	-3.2	0.9	1.2	1.1	-1.3	-0.5	-0.8	1.4	-0.1
Kurtosis	37.3	4.0	4.5	3.9	7.7	3.3	42.4	5.5	3.1
Sum	1,451	3,759	4,179	4,788	2,309	2,007	2,681	2,181	-581
Sum Sq.	12,004	82,705	105,885	126,686	83,785	99,488	305,593	19,123	48,391
Sum Sq. Dev.	6,805	47,823	62,765	70,087	70,617	89,542	287,842	7,382	47,559
Jarque-Bera	20,593	76	131	90	490	19	26,273	251	2
Probability	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.45
Observations	405								

Fuente: Elaboración propia con datos del Instituto Nacional de Estadísticas y Banco Central de Bolivia

Los resultados obtenidos del modelo TVP-VAR para el análisis del saldo monetario real sobre la actividad económica revelan un buen ajuste de los datos proyectados respecto a los observados dentro de la muestra (Gráfico 11), especialmente los agregados monetarios m1 y m3. Esto refleja que este tipo de modelos podría ser adecuado para capturar las dinámicas cambiantes que caracterizan las relaciones entre las variables monetarias y los indicadores clave de la actividad económica.

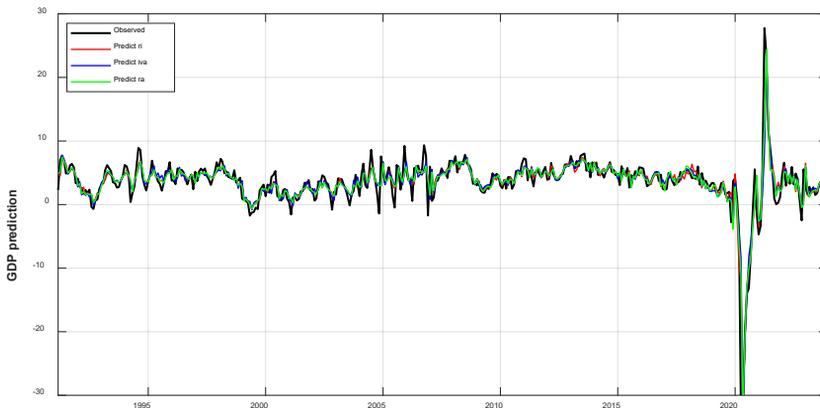
**Gráfico 11: CRECIMIENTO ECONÓMICO OBSERVADO VS
 PROYECTADO CON VARIABLES MONETARIAS**



Fuente: Elaboración propia

Por otro lado, los ingresos tributarios, tales como la renta interna, el Impuesto al Valor Agregado (IVA) y la renta aduanera, representan elementos clave para la proyección de la actividad económica. Según los resultados obtenidos del modelo TVP-VAR, los datos predichos por el modelo se aproximan de manera notable a los valores observados, lo que sugiere que las relaciones entre los ingresos fiscales y los indicadores económicos también pueden ser capturadas con alta precisión y adaptarse de manera efectiva a los cambios en las condiciones económicas a lo largo del tiempo.

Gráfico 12: CRECIMIENTO ECONÓMICO OBSERVADO VS PROYECTADO CON VARIABLES FISCALES



Fuente: Elaboración propia

Este buen ajuste observado en los resultados del modelo con variables monetarias y fiscales, no solo valida su capacidad predictiva, sino que también proporciona una visión más detallada de cómo las intervenciones monetarias y fiscales pueden influir en la economía en distintos contextos temporales. En este sentido, el modelo no solo contribuye a la comprensión de los efectos pasados, sino que también puede ofrecer proyecciones útiles para la formulación de políticas económicas futuras.

IV.4. Comparación de modelos de machine learning y econométricos

En esta sección se efectúa una comparación entre modelos de *Machine Learning* y modelos econométricos del tipo TVP-VAR, con el objetivo de evaluar su capacidad predictiva sobre variables fiscales y monetarias. Ambos enfoques presentan ventajas distintivas: los modelos de *Machine Learning* destacan por su flexibilidad y capacidad para captar relaciones no lineales y complejas en los datos, mientras que los modelos TVP-VAR ofrecen una estructura más interpretable y están diseñados para captar dinámicas cambiantes en series temporales económicas.

Los resultados obtenidos muestran que los modelos TVP-VAR presentan un desempeño superior en términos de precisión predictiva, medido a

través del error cuadrático medio (ECM). Específicamente, estos modelos obtuvieron menores valores de ECM en la predicción tanto de variables fiscales, así como para variables monetarias. Esta superioridad puede atribuirse a la capacidad de los modelos TVP-VAR para adaptarse a los cambios estructurales y a las variaciones temporales en los parámetros del modelo.

En contraste, aunque los modelos de *Machine Learning* muestran un buen desempeño general y pueden ajustarse bien a los datos en el periodo de entrenamiento, su rendimiento fuera de muestra fue inferior al de los TVP-VAR. Esto sugiere que, al menos en el contexto de las series temporales económicas analizadas, los métodos econométricos con parámetros variables en el tiempo capturan mejor la evolución dinámica de las relaciones económicas, especialmente en contextos con alta volatilidad o cambios de régimen.

En conclusión, ambos tipos de modelos se consolidan como herramientas robustas para la predicción de variables macroeconómicas. Si bien los modelos TVP-VAR mostraron un mejor desempeño en términos de menor error cuadrático medio, especialmente en contextos donde los parámetros de las relaciones económicas cambian con el tiempo, los modelos de *Machine Learning* también demostraron ser competitivos. Su flexibilidad y capacidad para capturar patrones complejos los convierten en una alternativa valiosa, particularmente en entornos donde la no linealidad es predominante. Por lo tanto, el uso complementario de ambos enfoques podría enriquecer el análisis económico y mejorar la calidad de las proyecciones.

Tabla 2: VARIABLES FISCALES

Modelo	MSE	RMSE	R2	u_theil
RandomForest	2.10000	1.40000	0.90000	0.10000
TVP-VAR RI		0.01429		
TVP-VAR IVA		0.02386		
TVP-VAR RA		0.02427		

VARIABLES MONETARIAS

Modelo	MSE	RMSE	R2	u_theil
RandomForest	2.1000	0.7000	0.9000	0.2000
TVP-VAR M1		0.02437		
TVP-VAR M2		0.02441		
TVP-VAR M3		0.02438		

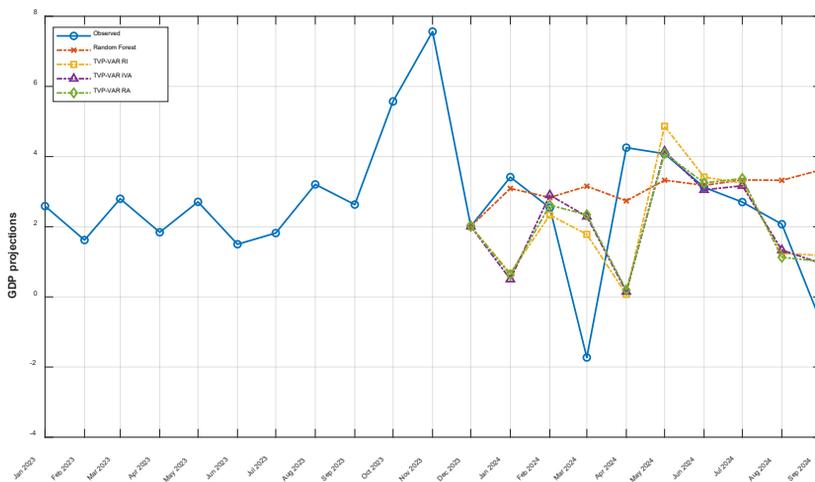
Fuente: Elaboración propia

IV.5. Pronósticos con modelos fuera de la muestra

Los resultados obtenidos al realizar las proyecciones sobre el crecimiento de la actividad económica, desde enero hasta septiembre de 2024, permiten observar que, en general, todas las variables analizadas (M1, M3, renta interna, IVA y renta aduanera) siguen un patrón de comportamiento similar, con la única excepción de M2, que presenta una mayor volatilidad. Mientras que las demás variables muestran una tendencia relativamente estable a lo largo del período proyectado, M2 experimenta fluctuaciones más marcadas, lo que sugiere una mayor sensibilidad a los cambios en las condiciones monetarias y fiscales.

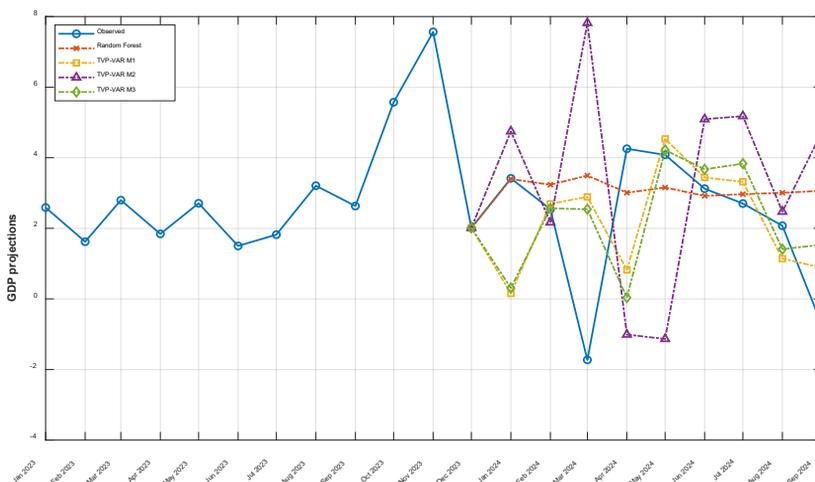
Entre los meses proyectados, se observa que mayo sería el de mayor crecimiento, superando el 4%, seguido de junio y julio, con tasas superiores al 3,5%. En contraste, los meses de enero y abril presentarían las tasas más bajas de crecimiento. En términos generales, la actividad económica podría registrar una tasa de crecimiento promedio mensual cercana al 2% a lo largo del período considerado, lo que refleja una tendencia estable en el comportamiento de las principales variables monetarias y fiscales que inciden en el desempeño económico (Gráficos 13 y 14).

Gráfico 13: CRECIMIENTO ECONÓMICO OBSERVADO VS PROYECTADO CON VARIABLES FISCALES



Fuente: Elaboración propia

Gráfico 14: CRECIMIENTO ECONÓMICO OBSERVADO VS PROYECTADO CON VARIABLES MONETARIAS



Fuente: Elaboración propia

Por otro lado, a través de la función impulso-respuesta (IRF, por sus siglas en inglés), se analiza cómo el crecimiento económico reacciona a lo largo del tiempo ante los choques exógenos provenientes de las variables monetarias y fiscales. Este análisis se realiza considerando un horizonte de 24 periodos. En el caso de las variables monetarias, un *shock* positivo inicial genera un impacto favorable en la actividad económica, promoviendo el crecimiento en los primeros meses tras el choque. Sin embargo, este efecto tiende a disminuir con el paso del tiempo. Este comportamiento sugiere que, a largo plazo, los efectos de un *shock* pueden depender significativamente de la respuesta de la política monetaria. Si la autoridad monetaria decide reducir la oferta monetaria en el futuro como medida para controlar la inflación, el impacto positivo en el PIB podría disminuir progresivamente, reflejando la interacción entre las políticas monetarias y la dinámica económica (ver Apéndice B).

Por su parte, un *shock* en las variables fiscales tiene un impacto negativo en la actividad económica a corto plazo (aproximadamente durante los primeros 5 meses), generando efectos contractivos debido a la reducción en el consumo y la inversión. Este fenómeno es común en los primeros períodos después de un *shock* fiscal. Sin embargo, a mediano y largo plazo el impacto se vuelve positivo, ya que los efectos favorables empiezan a manifestarse a partir del quinto periodo. Este cambio refleja la acumulación de los beneficios derivados de las políticas fiscales. En este contexto, el gasto público adicional, destinado a mejorar la infraestructura y otros sectores productivos o servicios que aumenten la productividad impulsa la expansión económica; por ende, el impacto negativo inicial podría ser compensado por un efecto positivo a largo plazo.

V. Conclusiones

El presente documento subraya la relevancia de utilizar enfoques avanzados, como los modelos no lineales de *Machine Learning* y el TVP-VAR para mejorar la predicción del crecimiento económico, especialmente en economías con dinámicas complejas como la de Bolivia. Estos modelos permiten capturar, de manera más precisa, las interacciones entre diversas variables económicas y adaptarse a los cambios estructurales que afectan el comportamiento del crecimiento económico. Los resultados obtenidos demuestran que estos enfoques ofrecen mejoras significativas en la precisión de los pronósticos, superando las limitaciones de los modelos tradicionales lineales.

El análisis comparativo entre los modelos de *Machine Learning* y los modelos econométricos TVP-VAR para la predicción del IGAE permitió identificar fortalezas complementarias en ambos enfoques. Los modelos de *Machine Learning*, al incorporar variables monetarias y fiscales con múltiples rezagos, demostraron una alta capacidad para capturar relaciones no lineales y complejas entre los determinantes macroeconómicos y la actividad económica, especialmente durante periodos de estabilidad. Las variables más relevantes, como los agregados monetarios, el crédito bancario y los egresos de capital del sector público se alinean con la teoría económica, confirmando su poder explicativo en horizontes de corto y mediano plazo.

Sin embargo, estos modelos tienden a mostrar limitaciones ante eventos extremos o de alta volatilidad como la crisis financiera de 2008 o la pandemia de COVID-19. Aunque logran capturar la dirección general de los cambios, presentan dificultades para reflejar con precisión la magnitud de dichos choques. Esto resalta la importancia de complementar los modelos de *Machine Learning* con enfoques estructurales o el uso de variables exógenas que incorporen elementos de incertidumbre y contexto global.

Por otro lado, los modelos TVP-VAR evidenciaron un mejor desempeño fuera de muestra, con menores errores de predicción y una mayor capacidad para adaptarse a cambios estructurales en las relaciones económicas. Esta ventaja se debe a su diseño flexible, que permite la variación temporal de los parámetros del modelo, haciendo que capten mejor la dinámica evolutiva de la economía.

En síntesis, ambos enfoques son valiosos para la predicción macroeconómica. Mientras los modelos de *Machine Learning* sobresalen por su flexibilidad y capacidad para modelar estructuras complejas, los modelos TVP-VAR aportan solidez analítica y mayor precisión en contextos de cambio. Así, se propone el uso complementario de ambas metodologías como una estrategia robusta para mejorar la calidad de las proyecciones económicas y apoyar la toma de decisiones de política pública.

Finalmente, a través de IRF se examina cómo el crecimiento económico responde a los choques exógenos de las variables monetarias y fiscales durante un horizonte de 24 periodos. Un *shock* positivo en las variables

monetarias inicialmente impulsa la economía, pero su efecto disminuye con el tiempo, dependiendo de la respuesta de la política monetaria. Si la autoridad monetaria reduce la oferta monetaria para controlar la inflación, el impacto positivo sobre el PIB puede disminuir. En cuanto a las variables fiscales, un choque fiscal genera un efecto negativo en el corto plazo debido a la reducción en consumo e inversión. Sin embargo, a mediano y largo plazo, el impacto se vuelve positivo gracias a los beneficios derivados de políticas fiscales, como el aumento en el gasto público para mejorar infraestructura y productividad, por lo tanto, un impacto negativo inicial podría ser compensado por un efecto positivo a largo plazo.

Referencias bibliográficas

AUERBACH, Alan and GORODNICHENKO, Yuriy, 2012. Measuring the Output Responses to Fiscal Policy. *American Economic Journal: Economic Policy*, 4 (2), pp. 1 - 27. ISSN en línea 1945-774X. Disponible en: <http://dx.doi.org/10.1257/pol.4.2.1>

BAUMGARTNER, Josef, RAMASWAMY, Raman and ZETTERGREN, Göran, 1997. Monetary Policy and Leading Indicators of Inflation in Sweden. International Monetary Fund, Working Paper WP/97/34, April. Disponible en: <https://www.imf.org/external/pubs/ft/wp/wp9734.pdf>

BENOS, Nikos, 2004. Fiscal Policy and Economic Growth: Empirical Evidence from OECD Countries. University of Cyprus, Working paper 01-2005, July. Disponible en: <https://www.ucy.ac.cy/econ/wp-content/uploads/sites/48/2022/01/1-2005.pdf>

BERNANKE, Ben and BLINDER, Alan, 1992. The Federal Funds Rate and the Channels of Monetary Transmission. *The American Economic Review*, 82 (4), pp. 901-921. ISSN en línea 1944-7981. Disponible en: <https://www.jstor.org/stable/2117350>

BERNANKE, Ben and GERTLER, Mark, 1989. Agency Costs, Net Worth, and Business Fluctuations. *The American Economic Review*, 79 (1), pp. 14 - 31. ISSN en línea 1944-7981. Disponible en: <https://www.jstor.org/stable/1804770>

BHADURY, Soumya, GHOSH, Saurabh and KUMAR, Pankaj, 2021. Constructing a Coincident Economic Indicator for India: How Well Does It Track Gross Domestic Product? *Asian Development Review*, 38 (2), pp. 237 - 277. ISSN en línea 1996-7241. Disponible en: <https://doi.org/10.1142/S0116110521500104>

BLANCHARD, Olivier, 1990. Suggestions for a New Set of Fiscal Indicators. OECD Economics Department Working Papers No. 79. April. Disponible en: <https://dx.doi.org/10.1787/435618162862>

BREIMAN, Leo, 2001. Random Forests. *Machine Learning*, 45, pp. 5-32. ISSN en línea 1573-0565. Disponible en: <https://doi.org/10.1023/A:1010933404324>

CHAKRABORTY, Chiranjit and JOSEPH, Andreas, 2017. Machine learning at central Banks. Bank of England, Working Paper No. 674, September. Disponible en: <https://www.bankofengland.co.uk/-/media/boe/files/working-paper/2017/machine-learning-at-central-banks.pdf>

CHAN, Joshua, 2023. Large Hybrid Time-Varying Parameter VARs. *Journal of Business & Economic Statistics*, 41 (3), pp. 890 - 905. ISSN en línea 1537-2707. Disponible en: <https://doi.org/10.1080/07350015.2022.2080683>

COGLEY, Timothy, 2001. How fast can the new economy grow? A Bayesian Analysis of the Evolution of Trend Growth. Arizona State University, Department of Economics, Working Paper No. 16/2001, March. Disponible en: <https://dx.doi.org/10.2139/ssrn.275980>

COGLEY, Timothy and SARGENT, Thomas, 2002. Evolving Post-World War II US Inflation Dynamics. En: BERNANKE, Ben and ROGOFF, Kenneth, eds., *NBER Macroeconomics Annual 2001*, 16. Cambridge: The MIT Press, pp. 331 - 373. ISBN 0-262-02520-5

COGLEY, Timothy and SARGENT, Thomas, 2005. Drifts and volatilities: Monetary policies and outcomes in the post WWII US. *Review of Economic Dynamics*, 8 (2), pp. 262 - 302. ISSN en línea: 1096-6099. Disponible en: <https://doi.org/10.1016/j.red.2004.10.009>

COGLEY, Timothy and SBORDONE, Argia, 2008. Trend Inflation, Indexation, and Inflation Persistence in the New Keynesian Phillips Curve. *American Economic Review*, 98 (5). pp. 2101 - 2126. ISSN en línea: 1944-7981. Disponible en: <https://doi.org/10.1257/aer.98.5.2101>

D'AGOSTINO, Antonello, GAMBETTI, Luca and GIANNONE, Domenico, 2013. Macroeconomic forecasting and structural change. *Journal of Applied Econometrics*, 28 (1), pp. 82 - 101. ISSN en línea: 1099-1255. Disponible en: <https://doi.org/10.1002/jae.1257>

DEL NEGRO, Marco and PRIMICERI, Giorgio, 2015. Time Varying Structural Vector Autoregressions and Monetary Policy: A Corrigendum. *The Review of Economic Studies*, 82 (4), pp. 1342 - 1345. ISSN en línea: 1467-937X. Disponible en: <https://doi.org/10.1093/restud/rdv024>

DIEBOLD, Francis, 2015. Comparing Predictive Accuracy, Twenty Years Later: A Personal Perspective on the Use and Abuse of Diebold–Mariano Tests. *Journal of Business & Economic Statistics*, 33 (1), ISSN en línea: 1537-2707. Disponible en: <https://doi.org/10.1080/07350015.2014.983236>

DIEBOLD, Francis, 2024. *Forecasting in Economics, Business, Finance and Beyond*. University of Pennsylvania. Edition 2024, Version Thursday 22nd August, 2024. Disponible en: <https://www.sas.upenn.edu/~fdiebold/Teaching221/Forecasting.pdf>

FRIEDMAN, Milton, 1968. The Role of Monetary Policy. *The American Economic Review*, 58 (1), pp. 1 - 17. ISSN 0002-8282. Disponible en: <https://www.aeaweb.org/aer/top20/58.1.1-17.pdf?version=meter+at+null&module=meter-Links&pgtype=article&contentId=&mediald=&referrer=&priority=true&action=click&contentCollection=meter-links-click>

FRIEDMAN, Milton, 1987. Quantity Theory of Money. En: EATWELL, John, MILGATE, Murray and NEWMAN, Peter, eds. *Money*. New York: The Macmillan Press Limited, pp. 1 - 40. ISBN 978-0-333-49527-8

FRIEDMAN, Milton and SCHWARTZ, Anna, 1971. *A Monetary History of the United States, 1867 - 1960*. United States of America: Princeton University Press. ISBN 0-691-00354-8

HASTIE, Trevor, TIBSHIRANI, Robert and FRIEDMAN, Jerome, 2009. *The Elements of Statistical Learning. Data Mining, Inference, and Prediction*. 2nd Edition. Springer Science+Business Media LLC. ISBN 978-0-387-84857-0

ILZETZKI, Ethan, MENDOZA, Enrique and VÉGH, Carlos, 2013. How big (small?) are fiscal multipliers? *Journal of Monetary Economics*, 60 (2), pp. 239 - 254. ISSN en línea: 1873-1295. Disponible en: <https://doi.org/10.1016/j.jmoneco.2012.10.011>

JUSTINIANO, Alejandro and PRIMICERI, Giorgio, 2008. The Time-Varying Volatility of Macroeconomic Fluctuations. *American Economic Review*, 98 (3), pp. 604 - 641. ISSN en línea: 1944-7981. Disponible en: <https://doi.org/10.1257/aer.98.3.604>

LUCAS, Robert, 1976. Econometric policy evaluation: A critique. *Carnegie-Rochester Conference Series on Public Policy*, 1, pp. 19 - 46. ISSN 0167-2231. Disponible en: [https://doi.org/10.1016/S0167-2231\(76\)80003-6](https://doi.org/10.1016/S0167-2231(76)80003-6)

MEDEIROS, Marcelo, VASCONCELOS, Gabriel, VEIGA, Álvaro and ZILBERMAN, Eduardo, 2021. Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. *Journal of Business & Economic Statistics*, 39 (1), pp. 98 - 119. ISSN 0735-0015. Disponible en: <https://doi.org/10.1080/07350015.2019.1637745>

MISHKIN, Frederic, 1996. The Channels of Monetary Transmission: Lessons for Monetary Policy. National Bureau of Economic Research, Working paper 5464, February. Disponible en: https://www.nber.org/system/files/working_papers/w5464/w5464.pdf

PRIMICERI, Giorgio, 2005. Time Varying Structural Vector Autoregressions and Monetary Policy. *The Review of Economic Studies*, 72 (3), pp. 821 - 852. ISSN en línea: 1467-937X. Disponible en: <https://doi.org/10.1111/j.1467-937X.2005.00353.x>

RANT, Vasja, PUC, Anja, ČOK, Mitja and VERBIČ, Miroslav, 2024. Macroeconomic impacts of monetary and fiscal policy in the euro area in times of shifting policies: A SVAR approach. *Finance Research Letters*, 64. ISSN en línea: 1544-6131. Disponible en: <https://doi.org/10.1016/j.frl.2024.105406>

SHEPHARD, Neil, 1994. Local scale models: State space alternative to integrated GARCH processes. *Journal of Econometrics*, 60 (1-2), pp. 181 - 202. ISSN en línea: 1872-6895. Disponible en: [https://doi.org/10.1016/0304-4076\(94\)90043-4](https://doi.org/10.1016/0304-4076(94)90043-4)

STOCK, James and WATSON, Mark, 2003. Forecasting Output and Inflation: The Role of Asset Prices. *Journal of Economic Literature*, 41 (3), pp. 788 - 829. ISSN en línea 2328-8175. Disponible en: <https://doi.org/10.1257/002205103322436197>

STOCK, James and WATSON, Mark, 2012. Disentangling the Channels of the 2007-2009 Recession. National Bureau of Economic Research, Working paper 18094, May. Disponible en: <https://doi.org/10.3386/w18094>

STOCK, James and WATSON, Mark, 2002. Forecasting Using Principal Components From a Large Number of Predictors. *Journal of the American Statistical Association*, 97 (460), pp. 1167 - 1179. ISSN en línea: 1537274X. Disponible en: <https://doi.org/10.1198/016214502388618960>

SVENSSON, Lars, 1997. Inflation forecast targeting: Implementing and monitoring inflation targets. *European Economic Review*, 41 (6), pp. 1111 - 1146. ISSN en línea: 1873-572X. Disponible en: [https://doi.org/10.1016/S0014-2921\(96\)00055-4](https://doi.org/10.1016/S0014-2921(96)00055-4)

TANZI, Vito and ZEE, Howell, 2000). Tax Policy for Emerging Markets: Developing Countries. *National Tax Journal*, 53 (2). ISSN en línea: 1944-7477. Disponible en: <https://doi.org/10.17310/ntj.2000.2.07>

TAYLOR, John, 1993. Discretion versus policy rules in practice. *Carnegie-Rochester Conference Series on Public Policy*, 39, pp. 195 - 214. ISSN 0167-2231. Disponible en: [https://doi.org/10.1016/0167-2231\(93\)90009-L](https://doi.org/10.1016/0167-2231(93)90009-L)

UHLIG, Harald, 1997. Bayesian Vector Autoregressions with Stochastic Volatility. *Econometrica*, 65 (1), pp. 59 - 73. ISSN en línea: 1468-0262. Disponible en: <https://doi.org/10.2307/2171813>

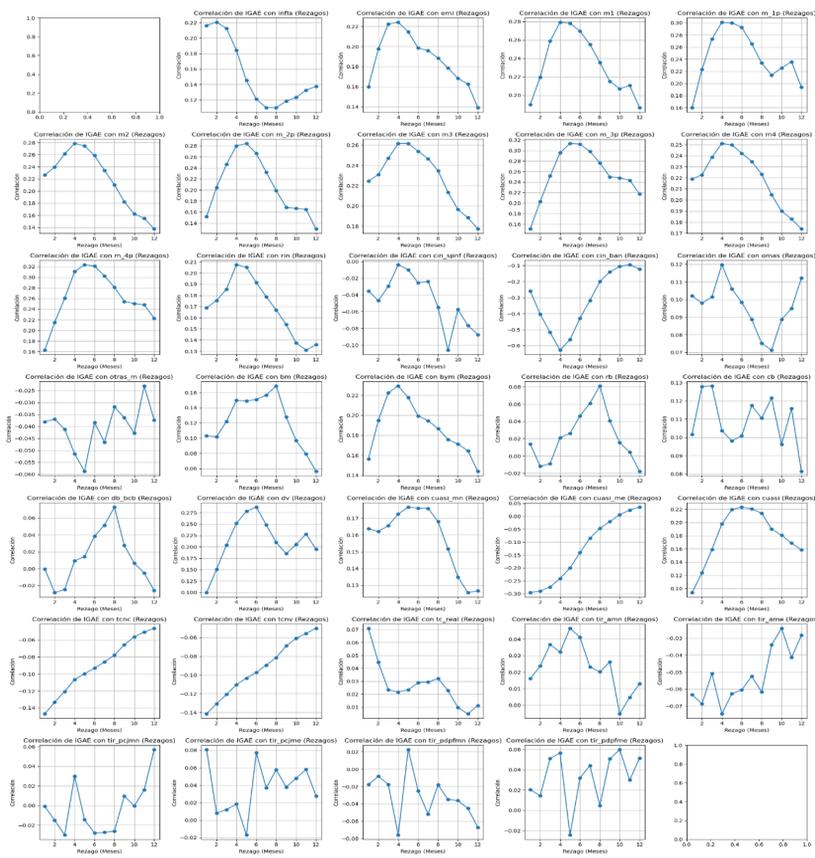
VARIAN, Hal, 2014. Big Data: New Tricks for Econometrics. *Journal of Economic Perspectives*, 28 (2), pp. 3 - 28. ISSN en línea: 1944-7965. Disponible en: <https://doi.org/10.1257/jep.28.2.3>

APÉNDICES

Apéndice A: Variables utilizadas en el modelo Random Forest con variables monetarias

No.	Código	Variable	Unidad de medida	Frecuencia	Fuente
			Indicador Principal		
1	IGAE	Índice Global de Actividad Económica	Índice 1990=100	Mensual	INE
			 Hidrocarburos 		
2	infla	Inflación	Porcentaje	Mensual	INE
3	emi	Emisión monetaria	Millones de bolivianos	Mensual	BCB
4	m1	Agregado monetario M1	Millones de bolivianos	Mensual	BCB
5	m_1p	Agregado monetario M1'	Millones de bolivianos	Mensual	BCB
6	m2	Agregado monetario M2	Millones de bolivianos	Mensual	BCB
7	m_2p	Agregado monetario M2'	Millones de bolivianos	Mensual	BCB
8	m3	Agregado monetario M3	Millones de bolivianos	Mensual	BCB
9	m_3p	Agregado monetario M3'	Millones de bolivianos	Mensual	BCB
10	m4	Agregado monetario M4	Millones de bolivianos	Mensual	BCB
11	m_4p	Agregado monetario M4'	Millones de bolivianos	Mensual	BCB
12	rii	Reservas Internacionales Netas	Millones de bolivianos	Mensual	BCB
13	cin_sprf	Credito Interno Neto al Sector Público	Millones de bolivianos	Mensual	BCB
14	cin_ban	Credito Interno Neto al Sector Bancario	Millones de bolivianos	Mensual	BCB
15	omas	Operaciones de Mercado Abierto	Millones de bolivianos	Mensual	BCB
16	otras_m	Otras Cuentas Monetarias	Millones de bolivianos	Mensual	BCB
17	bm	Base monetaria	Millones de bolivianos	Mensual	BCB
18	bym	Billetes y Monedas	Millones de bolivianos	Mensual	BCB
19	rb	Reservas Bancarias	Millones de bolivianos	Mensual	BCB
20	cb	Caja en Bancos	Millones de bolivianos	Mensual	BCB
21	db_bcb	Depositos de Bancos en el BCB	Millones de bolivianos	Mensual	BCB
22	dv	Depositos Vista	Millones de bolivianos	Mensual	BCB
23	cuasi_mn	Cuasidnero MN CVM UFV	Millones de bolivianos	Mensual	BCB
24	cuasi_me	Cuasidnero ME	Millones de bolivianos	Mensual	BCB
25	cuasi	Cuasidnero total	Millones de bolivianos	Mensual	BCB
26	tcnc	Tipo de Cambio nominal de compra	Bs/\$us	Mensual	BCB
27	tcnv	Tipo de Cambio nominal de venta	Bs/\$us	Mensual	BCB
28	tc_real	Tipo de Camnio real	Índice	Mensual	BCB
29	tir_amm	Tasa de interes real activa MN	Porcentaje	Mensual	BCB
30	tir_ame	Tasa de interes real activa ME	Porcentaje	Mensual	BCB
31	tir_pjmn	Tasa de interes real pasiva caja de ahorro MN	Porcentaje	Mensual	BCB
32	tir_pjme	Tasa de interes real pasiva caja de ahorro ME	Porcentaje	Mensual	BCB
33	tir_pdpfmn	Tasa de interes real pasiva dpf MN	Porcentaje	Mensual	BCB
34	tir_pdpfme	Tasa de interes real pasiva dpf ME	Porcentaje	Mensual	BCB

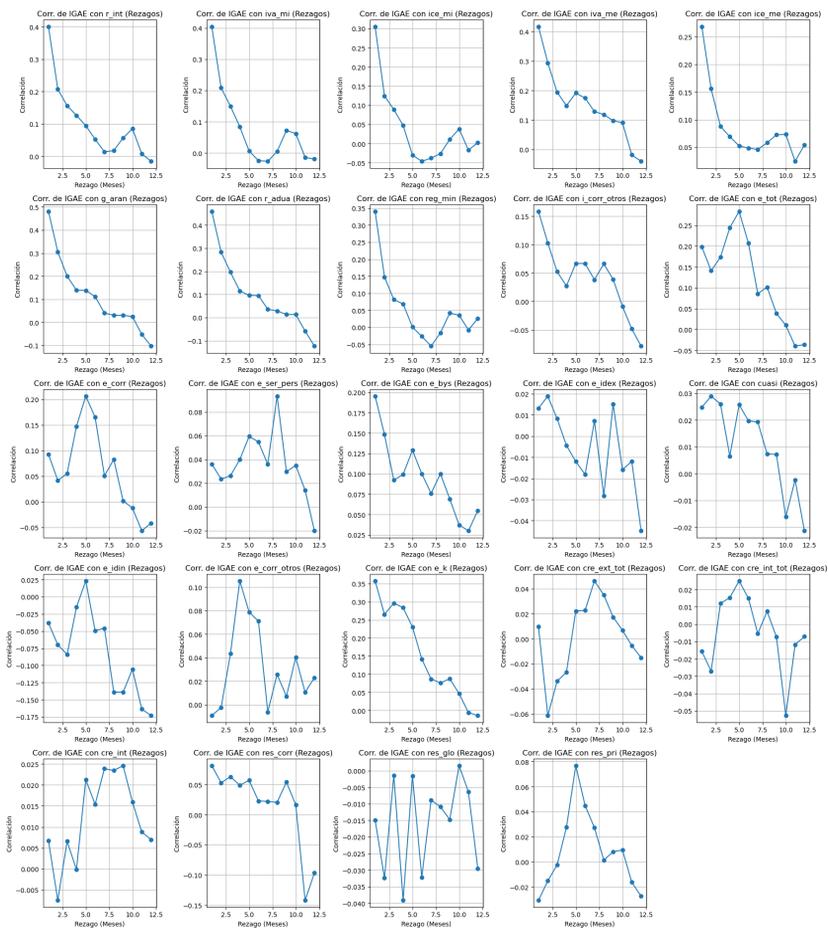
Apéndice A: Correlación del IGAE con variables monetarias rezagadas



Apéndice A: Variables utilizadas en el modelo *Random Forest* con variables fiscales

No.	Codigo	Variable	Unidad de medida	Frecuencia	Fuente
			Indicador Principal		
1	IGAE	Indice Global de Actividad Economica	Indice 1990=100	Mensual	INE
2	infla	Inflación	Porcentaje	Mensual	INE
3	i_tot	Ingresos totales del SPNF	Millones de bolivianos	Mensual	MEFP
4	i_corr	Ingresos Corrientes del SPNF	Millones de bolivianos	Mensual	MEFP
5	r_int	Renta Interna del SPNF	Millones de bolivianos	Mensual	MEFP
6	iva_mi	Impuesto al Valor Agregado Mercado Interno	Millones de bolivianos	Mensual	SIN
7	i_trans	Impuestos a las transacciones	Millones de bolivianos	Mensual	SIN
8	ice_mi	Impuesto al Consumo Especifico Mercado Interno	Millones de bolivianos	Mensual	SIN
9	iva_me	Impuesto al Valor Agregado Mercado Externo	Millones de bolivianos	Mensual	SIN
10	ice_me	Impuesto al Consumo Especifico Mercado Externo	Millones de bolivianos	Mensual	SIN
11	g_aran	Gravamen Arancelario	Millones de bolivianos	Mensual	AN
12	r_adua	Renta Aduanera del SPNF	Millones de bolivianos	Mensual	MEFP
13	reg_min	Regalías Mineras del SPNF	Millones de bolivianos	Mensual	MEFP
14	i_hidro	Ingresos por venta de Hidrocarburos SPNF	Millones de bolivianos	Mensual	MEFP
15	i_emp	Ingresos de otras Empresas Públicas del SPNF	Millones de bolivianos	Mensual	MEFP
16	i_corr_otros	Transferencias y otros ingresos corrientes del SPNF	Millones de bolivianos	Mensual	MEFP
17	i_k	Ingresos de capital del SPNF	Millones de bolivianos	Mensual	MEFP
18	e_tot	Egresos Totales del SPNF	Millones de bolivianos	Mensual	MEFP
19	e_corr	Egresos Corrientes del SPNF	Millones de bolivianos	Mensual	MEFP
20	e_ser_pers	Egresos por Servicios Personales del SPNF	Millones de bolivianos	Mensual	MEFP
21	e_bys	Egresos por Bienes y Servicios del SPNF	Millones de bolivianos	Mensual	MEFP
22	e_idx	Egresos por Intereses de Deuda Externa del SPNF	Millones de bolivianos	Mensual	MEFP
23	cuasi	Resultado Operativo del BCB	Millones de bolivianos	Mensual	MEFP
24	e_idin	Egresos por Intereses de Deuda Interna del SPNF	Millones de bolivianos	Mensual	MEFP
25	e_corr_otros	Transferencias y otros egresos corrientes del SPNF	Millones de bolivianos	Mensual	MEFP
26	e_k	Egresos de Capital del SPNF	Millones de bolivianos	Mensual	MEFP
27	cre_ext_tot	Credito Externo Neto del SPNF	Millones de bolivianos	Mensual	MEFP
28	des_ext	Desembolsos Externos del SPNF	Millones de bolivianos	Mensual	MEFP
29	amort_ext	Amortizaciones de Deuda Externa del SPNF	Millones de bolivianos	Mensual	MEFP
30	cre_int_tot	Credito Interno Neto total del SPNF incluye cuasifiscal	Millones de bolivianos	Mensual	MEFP
31	cre_int	Credito Interno Neto del SPNF	Millones de bolivianos	Mensual	MEFP
32	deu_flo	Deuda Flotante	Millones de bolivianos	Mensual	MEFP
33	otros_fin	Colocación de títulos y otras fuentes de financiamient	Millones de bolivianos	Mensual	MEFP
34	res_corr	Resultado Fiscal Corriente del SPNF	Millones de bolivianos	Mensual	MEFP
35	res_glo	Resultado Fiscal Global del SPNF	Millones de bolivianos	Mensual	MEFP
36	res_pri	Resultado Fiscal Primario del SPNF	Millones de bolivianos	Mensual	MEFP

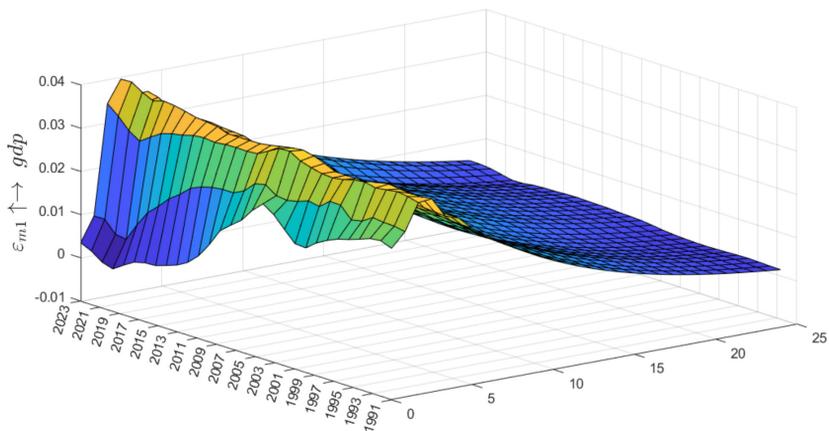
Apéndice A: Correlación del IGAE con variables fiscales rezagadas



Apéndice B: Función impulso respuesta del modelo TVP-VAR

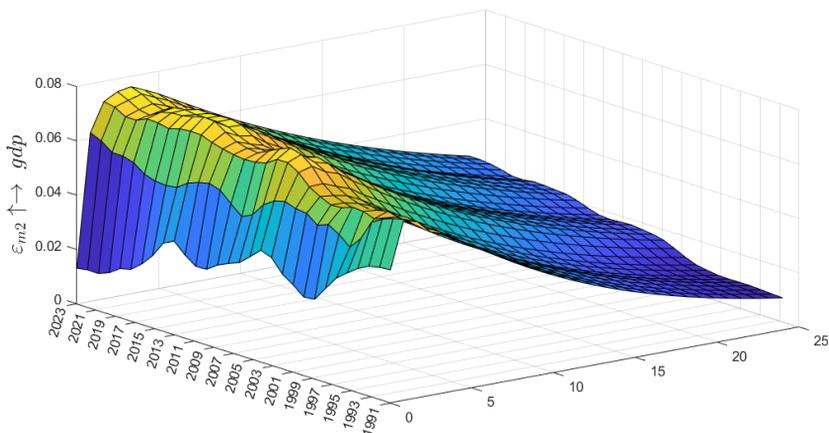
Se efectúa una simulación dinámica en el tiempo para 24 periodos:

Gráfico B.1: FUNCIÓN IMPULSO RESPUESTA: SHOCK DEL M1 SOBRE CRECIMIENTO ECONÓMICO



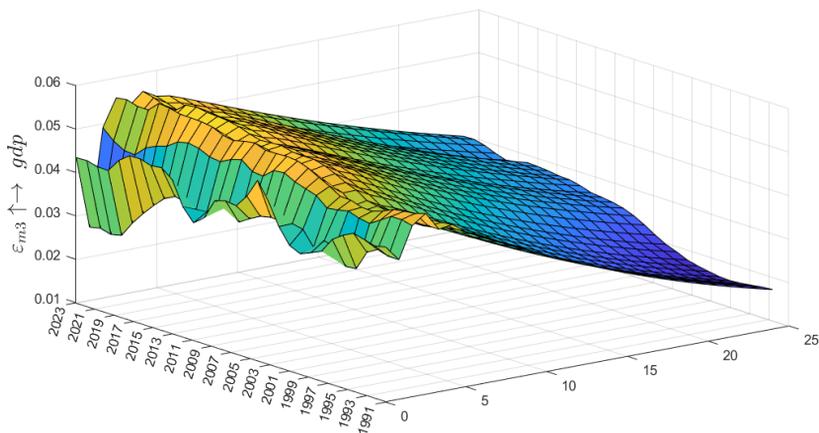
Fuente: Elaboración propia

Gráfico B.2: FUNCIÓN IMPULSO RESPUESTA: SHOCK DEL M2 SOBRE CRECIMIENTO ECONÓMICO



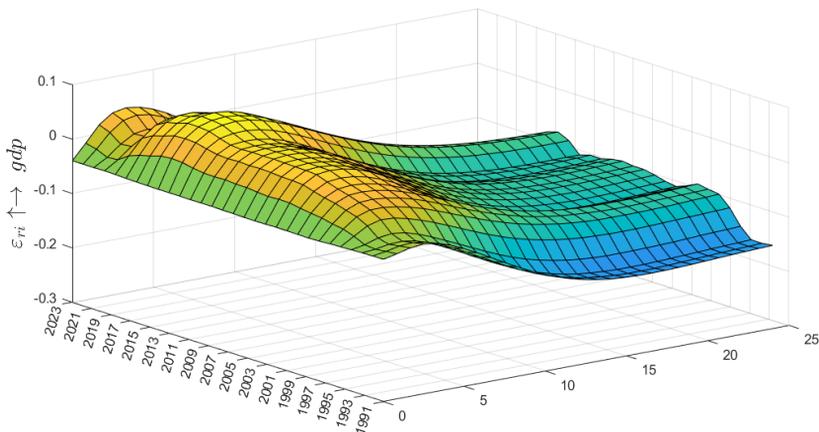
Fuente: Elaboración propia

**Gráfico B.3: FUNCIÓN IMPULSO RESPUESTA: SHOCK DEL M3
SOBRE CRECIMIENTO ECONÓMICO**



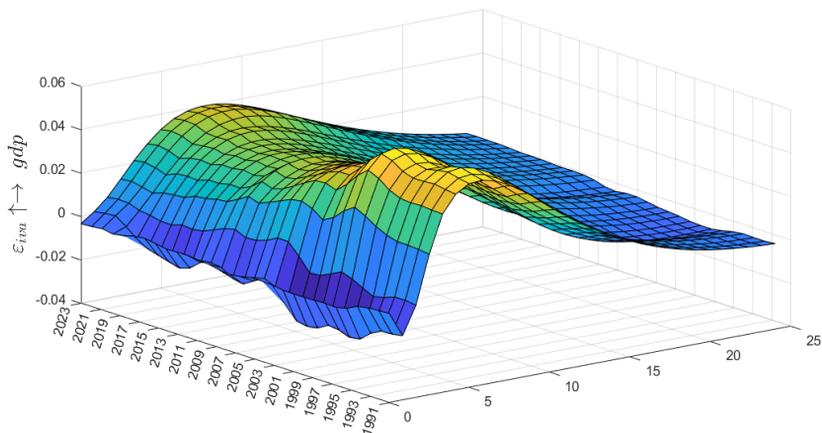
Fuente: Elaboración propia

**Gráfico B.4: FUNCIÓN IMPULSO RESPUESTA: SHOCK DE
RENDA INTERNA SOBRE CRECIMIENTO ECONÓMICO**



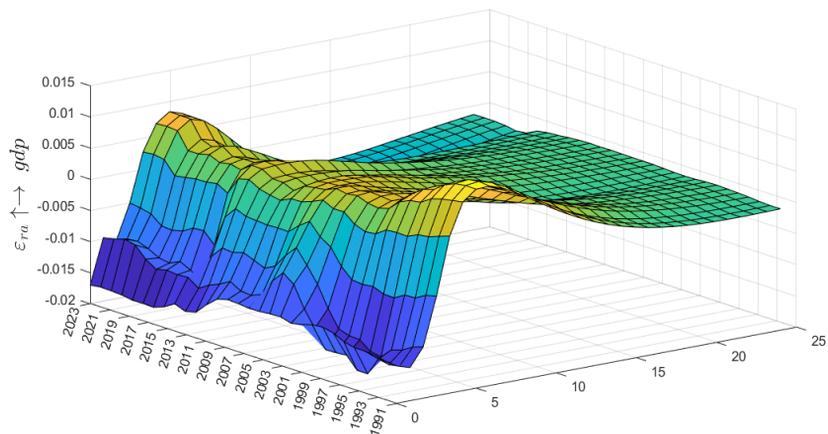
Fuente: Elaboración propia

Gráfico B.5: FUNCIÓN IMPULSO RESPUESTA: SHOCK DEL IMPUESTO AL VALOR AGREGADO SOBRE CRECIMIENTO ECONÓMICO



Fuente: Elaboración propia

Gráfico B.6: FUNCIÓN IMPULSO RESPUESTA: SHOCK DE RENTA ADUANERA SOBRE CRECIMIENTO ECONÓMICO



Fuente: Elaboración propia

Apéndice C: Criterios de selección de modelo

Para este modelo, se estima el modelo TVP-VAR en una ventana de datos de 1991m1 a 2024m6 (frecuencia mensual) y se pronostica el índice de actividad económica para 9 meses (desde enero hasta septiembre de 2024). El modelo TVP-VAR se estima para cada indicador monetario y variable fiscal de forma individual. En total, estimamos el modelo en 6 ventanas. Para evaluar el rendimiento de los pronósticos del modelo, se utiliza la medida del error cuadrático medio (RMSE).

Para diferentes horizontes de pronóstico, se debe considerar los criterios de evaluación de proyecciones: se calculan de la siguiente manera.

- **Error Cuadrático Medio (ECM):** es una medida que evalúa la magnitud de los errores de predicción en función de su cuadrado. Es particularmente sensible a grandes errores, ya que penaliza más los errores grandes. Sin embargo, es sensible a los valores extremos debido a la elevación al cuadrado de los errores y, tiene unidades cuadradas, lo que puede dificultar la interpretación directa en algunos contextos.

$$ECM = \frac{\sum_{t=1}^n (y_t - \bar{y}_t)^2}{n}$$

- **Error absoluto medio (MAE):** mide la magnitud promedio de los errores sin considerar su dirección (positivo o negativo). A diferencia del ECM, el MAE no penaliza de manera desproporcionada los errores grandes.

$$MAE = \frac{\sum_{t=1}^n |y_t - \bar{y}_t|}{n}$$

- **Error Porcentual Absoluto Medio (MAPE):** mide el error relativo en términos porcentuales, lo que permite evaluar el desempeño del modelo en términos de proporciones del valor real. Es particularmente útil cuando se quiere comparar el desempeño del modelo entre diferentes series temporales con escalas distintas.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \bar{y}_t}{y_t} \right| * 100$$

- **Coefficiente U de Theil:** es una métrica de precisión para evaluar la capacidad predictiva de un modelo comparando los valores predichos con los valores reales. Es particularmente útil en modelos econométricos como un modelo VAR (*Vector Autoregressive*), ya que analiza las diferencias entre valores observados y valores predichos en una serie temporal.

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

donde y_t es el valor observado en el tiempo, \hat{y}_t es el valor predicho en el tiempo y n es el número total de observaciones; cuando $U > 1$ la predicción es mejor que la de un modelo trivial; $U = 1$ la predicción es igual que la de un modelo trivial y $U < 1$ la predicción es peor que la de un modelo trivial.



FLORES
Walter Solón Romero
Acuarela sobre papel

Pruebas de tensión integral como herramienta de política macroprudencial mediante un enfoque de aprendizaje profundo (*deep learning*) *

Patricia Aranda Blanco
Boris Alfredo Luna Acevedo

RESUMEN

Las pruebas de estrés en sistemas bancarios son esenciales para evaluar la capacidad de las entidades de intermediación financiera de resistir situaciones extremas y garantizar la estabilidad del sistema financiero. Este trabajo explora un nuevo método de estimación para la prueba de tensión mediante modelos de aprendizaje de redes neuronales profundas aplicados al sistema financiero boliviano. Utilizando un enfoque basado en datos históricos y simulaciones, se desarrollan modelos predictivos que permiten analizar los efectos de condiciones económicas adversas en la solvencia bancaria. Se presenta una metodología para integrar el análisis de estrés dinámico con redes neuronales profundas, conocida como *Deep-Stress*, que mejora la precisión de los resultados en comparación con métodos tradicionales. Los resultados obtenidos proporcionan una herramienta robusta para la toma de decisiones estratégicas y la gestión del riesgo en entornos bancarios complejos.

Clasificación JEL: G10, G21 y G32

Palabras claves: Pruebas de tensión, *deep learning*, redes neuronales y riesgos integrados

* El contenido del presente documento es de responsabilidad de los autores y no compromete la opinión del Banco Central de Bolivia.

Comprehensive stress testing as a macroprudential policy tool using a deep learning approach

Patricia Aranda Blanco
Boris Alfredo Luna Acevedo

ABSTRACT

Stress testing in banking systems is essential for assessing the ability of financial intermediaries to withstand extreme situations and ensure the stability of the financial system. This paper explores a new estimation method for stress testing using deep neural network learning models applied to the Bolivian financial system. Using an approach based on historical data and simulations, predictive models are developed to analyze the effects of adverse economic conditions on bank solvency. A methodology for integrating dynamic stress analysis with deep neural networks, known as Deep-Stress, is presented, which improves the accuracy of the results compared to traditional methods. The results provide a robust tool for strategic decision-making and risk management in complex banking environments.

JEL Classification: *G10, G21 y G32*

Keywords: *Stress testing, deep learning, neural networks, and integrated risks*

* The content of this document is the responsibility of the authors and does not represent the opinion of the Central Bank of Bolivia.

I. Introducción

De manera general, la estabilidad financiera es un componente esencial en el crecimiento y funcionamiento de la economía. La crisis financiera de 2007 generó quiebras y el deterioro patrimonial de varias instituciones financieras, lo que implicó la intervención del Estado con programas de salvataje y un elevado costo social e impacto negativo para el sector real de la economía.

Una oportuna detección de fragilidad financiera de las entidades bancarias permite implementar medidas correctivas necesarias para la restauración de la solidez y evitar potenciales pérdidas, por lo que es una prioridad para las entidades rectoras y reguladoras, más aún, si la probabilidad de contagio entre bancos es alta.

En esta línea, volvió a tomar relevancia el análisis de las pruebas de tensión o de estrés (*tension testing*), en un contexto de riesgos financieros y desempeño económico. Particularmente, el Fondo Monetario Internacional (FMI) ha ido desarrollando este tipo de modelos, considerándolo como una herramienta clave para evaluar la solidez y resiliencia de un sistema financiero en un país, frente a escenarios adversos. En particular, el FMI utiliza las pruebas de tensión como parte de su evaluación de la estabilidad financiera en países miembros, mediante el Programa de Evaluación del Sector Financiero (FSAP, por sus siglas en inglés), permitiendo analizar la relación entre la calidad de activos de las entidades financieras y el entorno macroeconómico.

Conceptualmente, según el Oura y Schumacher (2012) el *stress testing* es una técnica que mide la vulnerabilidad de una cartera, una institución o todo un sistema de entidades financieras bajo diferentes eventos o escenarios hipotéticos. Es un ejercicio cuantitativo de “que pasaría si”, con el capital, las ganancias, los flujos de efectivos, etc., si ciertos riesgos se materializarían.

Según la guía de *stress testing* de Ong (2014), una prueba de tensión suele evaluar dos aspectos del desempeño de las entidades financieras: la prueba de solvencia y la de liquidez. La prueba de solvencia, se centra en la solidez del balance general de la entidad para cumplir con sus obligaciones financieras en escenarios adversos, evaluando si dispone

de capital suficiente para absorber pérdidas potenciales y continuar operando, sin comprometer su capital mínimo.

La prueba de liquidez, mide la capacidad de la entidad financiera de cumplir con sus obligaciones de corto plazo en escenarios adversos. Se busca determinar si la entidad tiene suficientes recursos líquidos (o activos fáciles de convertir en efectivo) para enfrentar retiros de depósitos, pagos a proveedores y otras demandas de efectivo en situaciones de estrés financiero, es decir, se evalúa la suficiencia de los activos líquidos de la entidad para cubrir las salidas de fondos en escenarios de alta demanda de efectivo.

Considerando que la solvencia es un elemento clave para garantizar la estabilidad financiera, ya que asegura que las entidades financieras puedan cumplir con sus obligaciones a largo plazo, incluso en condiciones adversas, su evaluación adquiere especial relevancia. En el caso boliviano, la solvencia no solo es fundamental desde una perspectiva prudencial, sino que también constituye un requisito legal indispensable para el funcionamiento de las entidades financieras. Por ello, en este documento se evaluará la resistencia del indicador de solvencia bajo un contexto de estrés.

En este marco, cada tipo de prueba de estrés aporta una perspectiva específica para analizar la resiliencia de las instituciones y del sistema financiero en su conjunto. Combinando estos tipos de pruebas, el FMI busca proporcionar una evaluación integral que permita a los reguladores y a las propias instituciones financieras anticipar y mitigar el impacto de crisis potenciales, asegurando así la estabilidad financiera.

Aunque gran parte de la literatura se enfoca en analizar un tipo de riesgo específico de forma aislada, este trabajo presenta una prueba de tensión integral que considera simultáneamente tres tipos de riesgo: crédito, liquidez y mercado. Este enfoque tiene como objetivo proporcionar una visión más completa y precisa sobre la resiliencia del sistema financiero.

Este tipo de pruebas demanda una herramienta econométrica avanzada, sin embargo, la econometría clásica presenta ciertas restricciones, por lo que fue necesario la búsqueda de métodos alternativos, como el aprendizaje autónomo y/o el *deep learning*, que permita establecer

modelos no lineales, principalmente, porque las relaciones entre variables en un contexto financiero y de riesgos están interconectados y estos efectos de contagio son difíciles capturar con métodos econométricos tradicionales.

En línea con la metodología del FMI, se plantea dos escenarios: a) escenario base, examina las condiciones normales del mercado y proyecta ganancias y pérdidas; b) escenario estresado, que simula situaciones extremas que podrían perturbar el sistema financiero como una recesión económica profunda, una crisis financiera global, o un colapso en los precios de los activos.

En este sentido, el trabajo se enfocará en realizar una prueba de solvencia, evaluando la resistencia del sistema bancario boliviano en un escenario estresado de las variables macroeconómicas, a través de un nuevo método de estimación denominado de aprendizaje profundo. En primera instancia se hará una revisión de la literatura y las principales características de este tipo de modelos, luego se presentará el planteamiento del modelo con la selección de variables y el desarrollo del modelo como tal, con la exposición de resultados, validación y posteriormente los resultados.

II. Revisión de la literatura

En el marco del nuevo acuerdo de Basilea III, las pruebas de estrés se han consolidado como un componente esencial para evaluar la capacidad de los bancos de absorber pérdidas y mantener su estabilidad ante situaciones extremas. Estas pruebas, alineadas con los requisitos de capital y liquidez establecidos por Basilea, aseguran que las instituciones bancarias cuenten con la fortaleza necesaria para enfrentar crisis, contribuyendo así a la estabilidad del sistema financiero global.

Desde una perspectiva teórica, las pruebas de estrés tienen como base los principios de gestión de riesgos financieros, donde se evalúa la exposición a riesgos externos poco probables y se relaciona también con la teoría de la estabilidad financiera sistémica que pretende prevenir efectos negativos en las entidades financieras o en el sistema en su conjunto.

Danielsson *et al.* (2001), explican que los modelos tradicionales subestiman los riesgos sistémicos por un enfoque individualista, sin

considerar las interacciones entre ellas. Sin embargo, si a las pruebas de estrés se incorporan externalidades, interconexiones y mecanismos de contagio, estas pueden ofrecer una perspectiva más integral del sistema financiero.

En los últimos años, las pruebas de estrés tomaron relevancia y han sido debatidas ampliamente. Čihák (2004) realizó una revisión de la literatura y los métodos cuantitativos con que se puede medir las vulnerabilidades del sistema financiero, identificando elementos clave para el diseño de escenarios específicos que reflejan con precisión las dinámicas del sistema financiero.

Según el Banco Central de Europa (BCE), las pruebas de estrés son procesos de evaluación que miden la resistencia, principalmente de los bancos, ante escenarios adversos, permitiendo determinar su capacidad para soportar crisis financieras o económicas severas sin comprometer su solvencia, estabilidad y capacidad de operación. En línea con el FMI, el BCE examina la solidez de los balances bancarios, evaluando el impacto en términos capital y liquidez, determinando como objetivos del ejercicio: evaluar la capacidad de absorción de pérdidas de las entidades bancarias; identificar los bancos que podrían necesitar más capital o ajustes al modelo de negocio; guiar decisiones regulatorias y de supervisión, relacionadas con la constitución de capital adicional o alguna implementación de medidas de contingencia; y aumentar la transparencia del sector para fortalecer la confianza del público y los inversionistas del sistema financiero.

Para llevar a cabo pruebas de estrés, se recurre a una amplia variedad de modelos cuantitativos, que suelen ser complejos y altamente demandantes en términos de información. Si bien estas herramientas permiten entender y gestionar los riesgos financieros, es fundamental complementarlas con análisis cualitativos y otras metodologías para obtener una visión integral de los posibles efectos sobre el sistema financiero. Entre los enfoques utilizados, destacan los modelos basados en simulaciones, los cuales permiten estimar probabilidades de incumplimiento y evaluar el impacto de choques económicos sobre los balances de las entidades. Estos modelos se pueden clasificar en tres tipos: i) modelos históricos, que replican eventos pasados que afectaron al sistema financiero; ii) modelos hipotéticos, que simulan escenarios extremos pero plausibles para analizar la respuesta del sistema ante situaciones inesperadas; y iii)

modelos de sensibilidad, que evalúan el efecto de variaciones drásticas en un único factor de riesgo sobre las instituciones financieras.

Uribe *et al.* (2008), estudiaron la resiliencia del sistema bancario colombiano frente a escenarios de estrés económico, simulando diversos factores adversos que podrían afectar la estabilidad del sistema bancario de Colombia. Con la metodología planteada por Čihák, evaluaron la resiliencia del sistema bancario colombiano ante diversos choques económicos simultáneos, identificando factores de riesgos individuales como el riesgo de crédito, tasa de interés, tipo de cambio, liquidez y contagio interbancario y el desarrollo de escenarios conjuntos, con *shocks* simultáneos en los diferentes factores de riesgo identificados. Con la ayuda de modelos econométricos como vectores autorregresivos, lograron capturar las interrelaciones dinámicas entre variables econométricas y financieras, lo que permitió simular choques en variables macroeconómicas y evaluaron sus efectos en el sistema bancario en el largo plazo.

Pérez y Trucharte (2011) abordaron la evolución de las pruebas de estrés tras la crisis financiera de 2007, resaltando la necesidad de integrar múltiples modelos y herramientas para reflejar con mayor precisión los riesgos emergentes. Desde otra perspectiva, Chafik *et al.* (2022) emplearon un modelo DSGE para analizar políticas macroprudenciales en Marruecos, incluyendo la interacción entre bancos, hogares y empresas, demostrando su utilidad en la formulación de políticas orientadas a mitigar riesgos sistémicos.

Desde otro enfoque, a través de un modelo de Equilibrio General Dinámico y Estocástico (DSGE), Chafik *et al.* (2022), presentaron un análisis de la política macroprudencial en Marruecos, incluyendo el comportamiento de los bancos, hogares y empresas, y su interrelación en la economía real y su efecto en la estabilidad financiera, proporcionando una herramienta valiosa para la formulación y evaluación de políticas destinadas a mitigar los riesgos sistémicos. Si bien existe una amplia literatura sobre el desarrollo de los modelos econométricos, estos presentan muchas limitaciones frente a modelos más avanzados y métodos de *machine learning* como el *deep learning*, principalmente en el contexto de pruebas de estrés financiero. Entre las principales limitaciones, se identifican la relación lineal que existe entre las variables, lo que no permite la captura compleja y no lineal en los mercados financieros, ya que los supuestos de los modelos son muy

rígidos sobre la distribución de errores y otras propiedades estadísticas que pueden no cumplirse en condiciones de estrés, restringiendo su capacidad para adaptarse a cambios en las condiciones de mercado.

Las pruebas de estrés en el ámbito financiero se utilizan para evaluar la resiliencia de un sistema bancario ante situaciones extremas. Los modelos econométricos y los modelos de aprendizaje profundo (*deep learning*) son dos enfoques diferentes para realizar estas pruebas, y cada uno tiene sus propias ventajas y limitaciones.

Gai y Kapadia (2010) destacaron las interacciones no lineales y los efectos de retroalimentación entre los participantes del sistema financiero, analizando cómo estas características afectan la estabilidad sistémica y se pierden en modelos lineales convencionales, ya que los modelos econométricos como los ARIMA asumen una relación lineal entre las variables de entrada y las variables de salida y suelen tratar los riesgos como independientes y de forma aislada, sin capturar las interacciones entre las instituciones y los mercados financieros, por lo que es necesario implementar modelos de correlación dinámica que permitan comprender el contagio financiero y su impacto simultáneo. En cambio, los modelos *deep learning* son más efectivos para capturar relaciones no lineales complejas, útil en el contexto de las pruebas de estrés. Estos modelos pueden capturar interacciones complejas entre diferentes variables (por ejemplo, variables macroeconómicas, tasas de interés y variables del balance de los bancos) sin la necesidad de especificar explícitamente estas relaciones (Lecun *et al.*, 2015).

Varian (2014) revisó los desafíos de los métodos econométricos tradicionales que luchan con la dimensionalidad y el manejo de los grandes volúmenes de datos, reduciéndose a una selección cuidadosa de variables y limitando la capacidad predictiva de dichos modelos, sugiriendo nuevas herramientas como *machine learning* para superar estas barreras. Los modelos de aprendizaje profundo son más flexibles, ya que pueden aprender automáticamente representaciones complejas de los datos.

Considerando que los modelos econométricos tradicionales presentan limitaciones en pruebas de estrés financieras, se han ido desarrollando enfoques y herramientas más avanzadas, como *machine learning* y

deep learning, teoría de redes y análisis de valores extremos, que buscan complementar o reemplazarlos cuando se compromete la precisión de las evaluaciones de riesgo y la identificación de vulnerabilidades sistémicas.

En esta línea, Petropoulos *et al.* (2019) propusieron un modelo con técnicas de aprendizaje profundo para las pruebas de estrés en balances financieros, denominado *deep stress*, que permitió simular de manera más precisa y eficiente los escenarios adversos en el balance de las instituciones financieras, capturando interacciones complejas entre variables financieras y macroeconómicas, reflejando decisiones de gestión y cambios en el entorno económico.

Por su parte, Chronopoulos *et al.* (2023) exploró la aplicación de redes neuronales profundas en modelos de datos de panel, ofreciendo una alternativa a los métodos econométricos tradicionales para capturar relaciones no lineales complejas en modelos de datos de panel, principalmente en la estimación del promedio condicional, con una mayor comprensión de los procesos subyacentes, principalmente en la estimación del pronóstico, no solo en la economía sino en otras ramas.

En el trabajo de Huang y Cho (2020) se realizó una revisión general de las diversas técnicas de aprendizaje profundo en el sector financiero y bancario utilizados para la clasificación, predicción y regresión de datos financieros para series temporales, que sean capaces de capturar dependencias de largo plazo en secuencias de datos muy comunes en mercados financieros.

Tsaryk (2020) destacó la capacidad de los modelos de aprendizaje profundo para manejar grandes volúmenes de datos y detectar patrones complejos en los estados financieros de los bancos, mejorando así la precisión de las pruebas de estrés ante escenarios adversos, en la evaluación de la solidez financiera de las instituciones bancarias.

III. Metodología

III.1. Modelo de deep learning

La técnica de *deep learning* (redes neuronales profundas), es un conjunto de algoritmos que forma parte del aprendizaje automático, cuyo propósito

es la simulación de datos que funcionan en base a un proceso de capas, denominadas neuronas, para modelar y entender patrones complejos en grandes volúmenes de información.

Este tipo de algoritmos, están inspirados en el funcionamiento de un cerebro biológico, al simular la interconexión de neuronas en múltiples capas que le permite aprender representaciones jerárquicas, que se distingue de una red neuronal simple porque son caracterizados por una arquitectura de múltiples capas y comprenden dos o más capas ocultas¹.

El entrenamiento en este tipo de modelos tiene dos pasos principales: 1) la propagación hacia adelante, donde los datos se introducen a la red y los cálculos se realizan capa por capa para producir una salida que se compara con la salida deseada y se calcula una señal de error; 2) la retropropagación, paso crucial, que consiste en ampliar la señal de error hacia atrás a través del error de la red, ajustado por parámetros de la red (pesos y sesgos) para minimizar el error.

Este tipo de entrenamiento interactivo de propagación y retropropagación, es apoyado por algoritmos de optimización que permite a las redes neuronales profundas aprender y mejorar su rendimiento en el tiempo.

Los procesos de múltiples capas permiten mapear funciones complejas no lineales. Su aplicación ha ganado relevancia en diferentes disciplinas de la ciencia, en particular, en el ámbito financiero debido a la creciente disponibilidad de datos y a la necesidad de herramientas avanzadas para procesarlos y analizar grandes volúmenes de información estadística y extraer patrones financieros².

1 Siguiendo a Elhoseny et al. (2022), la primera distinción entre la red neuronal clásica y deep neuronal es el número de capas ocultas y el procedimiento de entrenamiento.

2 Por su parte Tsaryk (2020) explora la aplicación de técnicas avanzadas de inteligencia artificial para abordar problemas financieros que enfrentan los bancos y las autoridades regulatorias. El trabajo se centra en cómo las redes neuronales artificiales (ANNs) y el *deep learning* pueden mejorar las pruebas de estrés en sistemas bancarios, especialmente en la evaluación de la resiliencia de estos sistemas ante choques adversos y en la identificación de las principales fuentes de riesgo. Tsaryk argumenta que muchos problemas financieros reales exhiben comportamientos no lineales que son difíciles de capturar con herramientas estadísticas tradicionales. Por ello, propone la implementación de ANNs para abordar estas no linealidades.

Siguiendo a Elhoseny *et al.* (2022), el modelo *deep learning* utiliza redes neuronales para procesar datos complejos y realizar análisis predictivos, según las siguientes definiciones:

Paso 1: Función de propagación

Etapas inicial en el entrenamiento donde los datos se introducen a la red y los cálculos se realizan capa por capa para producir una salida que se compara con la salida deseada y se calcula una señal de error.

1. Cálculo de la entrada ponderada, este cálculo es fundamental en cada neurona de la red, ya que permite combinar las entradas de forma ponderada antes de aplicar una función de activación. Se define como:

$$z_j = \sum_{i=1}^n W_{kj} a_i + \beta_j \quad (1)$$

donde:

z_j : Es el valor que genera la neurona j como resultado de las entradas ponderadas y su sesgo. El valor puede ser procesado por una función de activación en etapas posteriores.

$\sum_{i=1}^n$: Representa la suma de las contribuciones de todas las neuronas en la capa anterior (n entradas).

W_{kj} : Es el peso que conecta la entrada k de la capa previa con la neurona j en la capa actual. El peso determina la influencia de cada entrada en el resultado z .

a_i : Es la a -ésima entrada o activación proveniente de una capa anterior o de los datos de entrada iniciales si es la primera capa.

β_j : Ayuda a gestionar la salida del nodo.

2. Función sigmoide, función de activación más común. Permite introducir la no linealidad en el modelo y transformar el valor de entrada en (z_j) valor de salida con un rango de (0,1). Se multiplica por los pesos de cada conexión y se aplica una función de activación. Siendo útil para problemas de clasificación binaria o normalización de valores en redes neuronales.

La sigmoide transforma la función de la siguiente manera:

$$f_j(x) = \frac{1}{1+e^{-z_j}} \quad (2)$$

3. Para la salida de una neurona o el **resultado final** de una capa de la red se calcula la siguiente ecuación:

$$\hat{y}_k = \sum_{i=1}^m W_{ki} f_i + \beta_k \quad (3)$$

donde:

\hat{y}_k : Es la k -ésima neurona en la capa actual, es el resultado antes de aplicar cualquier función de activación o transformación final.

W_{kj} : Es el peso asociado a la conexión entre el nodo j en la capa previa y el nodo k en la capa actual.

f_i : Representa la activación de la i -ésima neurona en la capa interior. Usualmente es el resultado de aplicar una función de activación como ReLU, sigmoide o Tanh sobre la suma ponderada de entradas en la capa anterior.

β_k : Es el sesgo de la k -ésima neurona. Proporciona un valor adicional que ayuda a ajustar la salida del nodo, permitiendo que el modelo sea más flexible al capturar patrones complejos.

A partir de la ecuación, se obtiene una salida preliminar que se compara con la salida real para calcular el error.

Paso 2: Retropropagación

La función **de la retropropagación** es el proceso que permite a las redes neuronales ajustar los pesos (W) y los sesgos (β) minimizando el error de las predicciones \hat{y} y las salidas reales y . Este ajuste se realiza mediante el cálculo del gradiente³ de la función de pérdida y su propagación. Para el efecto, se utilizan las siguientes formulas:

a) Función de pérdida

Mide el error entre las salidas reales y las predichas por la red. Un ejemplo común es el Error Cuadrático Medio (MSE)

3 El **gradiente** es un vector que contiene las derivadas parciales de una función de pérdida con respecto a los parámetros del modelo (por ejemplo, los pesos y sesgos de las redes neuronales). Este gradiente indica cómo cambiar los parámetros para minimizar la función de pérdida y mejorar el rendimiento del modelo en una tarea específica.

$$E = \frac{1}{2} \sum_{k=1}^n (y_k - \hat{y}_k)^2 \quad (4)$$

donde:

y_k : Salida real para la k -ésima entrada.

\hat{y}_k : Salida predicha por la red para la k -ésima entrada.

n : Número total de ejempls.

b) Gradiente del error respecto de los pesos y sesgos

Es el vector que contiene las derivadas parciales de una función de pérdida. Este gradiente indica cómo cambiar los parámetros para minimizar la función de pérdida y mejorar el rendimiento del modelo en una tarea específica respecto de los pesos y sesgos. Así, respecto de los pesos W_{ij} , que tiene por objetivo el ajustar los pesos minimizando la función de pérdida. El gradiente respecto a un peso específico W_{ij} es:

$$\frac{\partial E}{\partial W_{ij}} = \delta_j a_i \quad (5)$$

δ_j : Error de la neurona j de la capa actual

a_i : Activación de la neurona i en la capa anterior.

Gradiente respecto al Sesgo, el gradiente respecto al sesgo de la neurona j es:

$$\frac{\partial E}{\partial \beta_j} = \delta_j \quad (6)$$

c) Cálculo del error de las neuronas δ_j

Para la capa de salida, se calcula directamente a partir de la función de pérdida.

$$\delta_j = \frac{\partial E}{\partial z_j} = (y_j - \hat{y}_j) f'(z_j) \quad (7)$$

$z_j = \sum_{i=1}^n W_{ij} a_i + \beta_j$: entrada ponderada a la neurona j

$f'(z_j)$: Derivada de la funcion de activacion en la salida z_j

Para las capas ocultas, el error de las capas ocultas de propaga desde la capa siguiente:

$$\delta_j = f'(z_j) \sum_{k=1}^m \delta_k W_{kj} \quad (8)$$

m : Número de neuronas en la capa siguiente.

δ_k : Error de las neuronas en la capa siguiente

W_{kj} : Pesos que conectan las neuronas de la capa actual con la capa siguiente.

d) Actualización de los pesos y sesgos

Los pesos y sesgos se actualizan utilizando el método del descenso del gradiente:

$$W_{ij} = W_{ij} - \eta \frac{\partial E}{\partial W_{ij}} \quad (9)$$

$$\beta_{ij} = \beta_{ij} - \eta \frac{\partial E}{\partial \beta_{ij}} \quad (10)$$

η : Tasa de aprendizaje

$\frac{\partial E}{\partial W_{ij}}$: Gradiente del error respecto al peso

$\frac{\partial E}{\partial \beta_{ij}}$: Gradiente del error respecto al sesgo

El modelo realiza el proceso completo en varias iteraciones en cuatro pasos:

1. **Propagacion hacia adelante:** Se calcula las salidas de todas las capas mediante

$$z_j = \sum_{i=1}^n W_{kj} a_i + \beta_j, \quad a_j = f(z_j) \quad (11)$$

2. **Cálculo del Error en la Capa de Salida:** Usa la función de pérdida para calcular δ_j .
3. **Propagación hacia atrás:** Calcula los errores (δ_j) para cada capa de manera iterativa, desde la capa de salida hasta la primera capa oculta.
4. **Actualización de parámetros:** Se ajusta W_{kj} y β_j utilizando las formulas del gradiente descendente.

IV. Aplicación del modelo *deep learning*

Considerando que la tarea es realizar una prueba de tensión integral, el objetivo de la utilización de la *deep learning* es aprovechar la capacidad

del modelo para realizar relaciones complejas y no lineales entre tres tipos de riesgos y evaluar simultáneamente el impacto combinado de escenarios en el sistema financiero boliviano.

IV.1. Datos y fuentes

La base de datos contiene 1.041 observaciones en un panel de datos de 13 bancos en un periodo de marzo de 2005 hasta diciembre de 2023 con una periodicidad trimestral. La fuente de información para las variables financieras proviene de la Autoridad de Supervisión del Sistema Financiero (ASFI) y el Banco Central de Bolivia (BCB), mientras que para las variables macroeconómicas se utiliza el Instituto Nacional de Estadística (INE). Los datos están aglutinados en 38 variables financieras y 5 variables macroeconómicas (ver Apéndice A).

Cabe destacar que el panel de datos utilizado es balanceado, es decir, cada entidad bancaria cuenta con observaciones completas y continuas para todos los periodos del análisis. Esta característica resulta fundamental para la aplicación de modelos de *deep learning*, en particular, aquellos diseñados para capturar patrones temporales como las redes neuronales recurrentes (RNN) y las LSTM (*Long Short-Term Memory*). Contar con un panel balanceado asegura una estructura homogénea en las secuencias de entrada, mejora la estabilidad del entrenamiento, reduce la necesidad de imputación de datos faltantes, y permite una comparación consistente entre las distintas entidades financieras a lo largo del tiempo.

Normalización de datos

Previo a la estimación mediante un modelo de *deep learning*, los datos reciben un tratamiento de normalización que forma parte del proceso de modelación. Esta normalización se debe realizar dentro de un rango uniforme con la finalidad de prevenir que los números/valores grandes anulen números/valores pequeños y evitar una saturación prematura de las capas ocultas con una consecuencia en la tasa de aprendizaje más lenta, considerando que los números del mundo real no son uniformes y están distribuidos sobre un rango demasiado diferente.

Siguiendo a Tsaryk (2020) y Basheer y Hajmeer (2000), la normalización de datos consiste en un vector de variables de entrada y variables de salida z_i en un intervalo $[\lambda_1, \lambda_2]$ que corresponde al rango de la función de activación.

$$x_1 = \lambda_1 + (\lambda_2 - \lambda_1) \left(\frac{z_i + z_i^{\min}}{z_i^{\max} - z_i^{\min}} \right) \quad (12)$$

donde x_i es el valor escalado de z_i , z_i^{\max} y z_i^{\min} representan valores máximo y mínimo del vector z_i en la base de datos.

IV.2. Selección de variables

Como parte de la selección de variables, se presenta un análisis de las variables que serán utilizadas como entrada para entrenar una red neuronal, reflejando las variables que pueden influir en los riesgos analizados (riesgo de crédito, liquidez y mercado) con el objeto que el modelo capture las interacciones y dependencias relevantes entre ellos.

Se realizó un ejercicio que tiene por objeto validar las variables que se utilizarán y que capturen los riesgos de crédito, liquidez y mercado, empleando el modelo de clasificación denominado "árbol de decisión" que se volvió recurrente en temas financieros, ya que permiten optimizar la toma de decisiones⁴ principalmente en situaciones de incertidumbre.

⁴ Según Berlanga et al. (2013), los árboles de decisión son una herramienta analítica que permite, en primer lugar, expresar de forma gráfica y, posteriormente, bajo una esquematización matemática, los diferentes caminos, variables, causas y efectos que pueden materializarse como resultado de las acciones de los individuos involucrados. Esto es especialmente relevante bajo condiciones de incertidumbre y riesgo donde, en cada fase, convergen elementos estocásticos o aleatorios, representados en términos de probabilidades. Este tipo de clasificación de variables se basa en la teoría de juegos y ofrece varias ventajas:

- i) **Facilidad de interpretación:** generan reglas claras que permiten entender cómo y por qué una variable es clasificada como relevante.
- ii) **Efectividad en entornos mixtos:** funcionan bien en entornos donde los datos son una mezcla de variables categóricas y continuas.
- iii) **Ajustabilidad:** pueden ajustarse con estrategias como asignación de pesos por clase o poda de nodos.
- iv) **Aplicabilidad en riesgos financieros:** son útiles para distintos tipos de análisis de riesgos financieros.

Estos modelos permiten dividir los datos en subconjuntos más homogéneos y tomar decisiones informadas basadas en las variables disponibles.

Árbol de decisión simple (ajustado): Un árbol de decisión ajustado emplea un proceso de división recursiva basado en algún criterio de optimización, como la entropía o la impureza de Gini. El modelo se ajusta seleccionando, para cada división, la característica que mejor segmenta los datos. Este ajuste puede implicar la reducción de la complejidad del árbol a través de la poda, eliminando ramas que no contribuyen significativamente al rendimiento del modelo. La poda ayuda a prevenir el sobreajuste (overfitting) y mejora la capacidad de generalización.

Árbol de Decisión con Validación Cruzada: El árbol de decisión con validación cruzada, también conocido como validación cruzada de k-fold, implica dividir los datos en varias particiones (por ejemplo, 10 particiones en un esquema de validación cruzada de 10-fold) y luego entrenar y evaluar el árbol de decisión en diferentes subconjuntos de datos. Este enfoque permite evaluar el rendimiento del modelo de manera más robusta y mitigar el riesgo de sobreajuste, proporcionando una medida más confiable de la capacidad de generalización del modelo.

Este tipo de modelo se ha consolidado como herramienta útil en la gestión de riesgos financieros, debido a su capacidad para identificar patrones, clasificar eventos, y predecir resultados relacionados con el riesgo.

En este contexto, se elaboró un árbol de decisión por tipo de riesgo y fue diseñado para clasificar las variables objetivo y relevantes que explican los tres tipos de riesgo que se describen a continuación, de un conjunto de variables predictivas que sugiere la literatura⁵, que muestran la jerarquía de las variables para cada tipo de riesgo, lo que permitirá entender de mejor manera las predicciones que se podrían realizar.

Determinación de datos de ensayo y predicción en un árbol de decisión

El proceso para construir y validar un árbol de decisión implica dos etapas clave:

i) División de los datos

- Los datos se dividen en conjuntos de entrenamiento y prueba (*test*), típicamente en proporciones como 80%-20%, equivalente al periodo de diciembre de 2020.
- El conjunto de entrenamiento se utiliza para ajustar el árbol, determinando las reglas y divisiones óptimas a través del método simple, ajustado y de validación cruzada, para riesgo de crédito, mercado y liquidez.
- El conjunto de prueba se reserva para evaluar el desempeño del árbol con datos no vistos, lo que permite medir su capacidad de generalización.

ii) Predicción y evaluación

- Una vez ajustado, el árbol predice el resultado para los datos del conjunto de prueba.
- Los resultados predichos se comparan con los valores reales utilizando métricas como precisión, sensibilidad o el error promedio.

⁵ Al no ser el objetivo de este trabajo determinar las variables más relevantes por riesgo, se presenta el árbol de decisiones de manera general, pudiendo mejorar los resultados con otros modelos, para otro tipo de trabajo como determinantes de los riesgos financieros.

iii) Determinación de las variables objetivo para el riesgo de crédito, de mercado y de liquidez

Se tienen tres variables objetivo que buscan predecir o explicar los riesgos de crédito, mercado y liquidez, apoyados en la literatura y el criterio experto. Estas son: índice de mora, diferencial *spread*, y cobertura de corto plazo.

Estas variables se transforman en variables categóricas de 0 y 1 con los siguientes umbrales (en todos los casos las variables tratadas son balanceadas):

Cuadro 1: VARIABLES Y UMBRALES POR TIPO DE RIESGOS

Riesgo	Variable	Umbral	Justificación
Riesgo de Crédito	Índice de Mora (IM)	3,60%	Promedio de países
Riesgo de Mercado	Spread	0,1166%	Percentil 75
Riesgo de Liquidez	Cobertura de Corto Plazo (ccp)	39,41%	Percentil 75

Fuente: Elaboración propia

iv) Presentación de resultados

Riesgo de crédito. El modelo identifica las variables más relevantes que influyen en la clasificación, a partir de un árbol de decisión de validación cruzada. Entre las principales se encuentran: mora, variación de ingresos financieros, cobertura de previsiones, y pueden servir de guía para elegir las variables que se pueden incluir en el modelo de aprendizaje profundo. Las métricas de validación tienen un excelente rendimiento en términos generales de 95,86%, especialmente cuando el IM es menor a 3,6%.

**Cuadro 2: VARIABLES PRINCIPALES PARA LA PREDICCIÓN
 Y MÉTRICAS DE PRECISIÓN DE RIESGOS DE CRÉDITO**

	precisión	recall	f1-score	support
0	0,96	0,99	0,98	148
1	0,94	0,71	0,81	21
ACCURACY			0,96	169
MACRO AVG	0,95	0,85	0,89	169
WEIGHTED AVG	0,96	0,96	0,96	169

Variable	Importancia
mora	31,12
var_ing_fin	30,51
cob_prev	118,69
c_prom	9,22
apr	3,58
patrimonio_eficiente	2,76
prom_var_if	1,35
t_prom_c	1,13
t_prom_d	0,83
dpr	0,58
cf	0,18
prom_var_gf	0,06
roa	3,41553E-16

Riesgo de mercado

Para el riesgo de mercado (tasa de interés) la variable más relevante es la tasa promedio de cartera y depósitos y, en menor grado, la variación de los ingresos financieros. En este caso el modelo clasifica correctamente el 96% de toda la muestra, impulsado por el desempeño de observaciones por debajo del percentil 75, aunque con un desempeño moderado de la clase 1. El modelo tiene alta precisión, *recall* y F1-score para la clase 0, lo que indica que clasifica bien los casos comunes.

Cuadro 3: VARIABLES PRINCIPALES PARA LA PREDICIÓN Y MÉTRICAS DE PRECISIÓN DE RIESGOS DE MERCADO

	precisión	recall	f1-score	support
0	0,99	0,96	0,97	163
1	0,36	0,67	0,47	6,00
ACCURACY			0,96	169
MACRO AVG	0,68	0,81	0,72	169
WEIGHTED AVG	0,97	0,95	0,96	169

Variable	Importancia
t_prom_c	94,0387
t_prom_d	3,8999
var_ing_fin	1,7168
mora	0,3446

Riesgos de liquidez

Las variables más relevantes, por importancia, según arboles de decisión, determina la proporción de liquidez respecto de activos, lo que indica que esta variable es el factor principal en el modelo. Siendo la principal variable, nos sugiere que las entidades de intermediación financiera (EIF) con mayores niveles de liquidez tienden a tener un menor riesgo asociado. En segunda instancia esta la variable disponibilidades sobre obligaciones de corto plazo, relacionado con la capacidad de una EIF para cubrir obligaciones inmediatas. El modelo clasifica correctamente el 96% de todas las instancias, pero esto está sesgado por la predominancia de la clase mayoritaria (clase 1)

Cuadro 4: VARIABLES PRINCIPALES PARA LA PREDICIÓN Y MÉTRICAS DE PRECISIÓN DE RIESGOS DE LIQUIDEZ

Variable	Importancia
liquidez_tot_act	74,73
disp_oblig_cp	7,60
dep_pub	3,90
t_prom_d	3,01
c_prom	2,09
net_loan	1,37
cap	1,06
brecha	1,01
ing_ope	0,91
act_liquid	0,88
apr	0,86
prom_var_if	0,75
roa	0,48
dpr	0,48
t_prom_c	0,37
pas_sin_costo	0,24
cob_prev	0,15
prom_var_gf	0,10

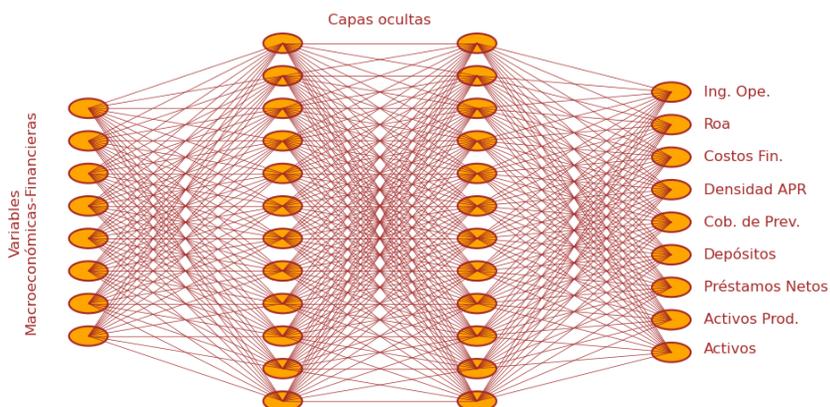
	precisión	recall	f1-score	support
0	0,26	0,59	0,36	17
1	0,95	0,81	0,87	152
ACCURACY			0,96	169
MACRO AVG	0,60	0,70	0,61	169
WEIGHTED AVG	0,88	0,79	0,82	169

Los resultados sugieren que, para la construcción de la prueba de estrés, contamos con variables que pueden capturar la transmisión de los riesgos de crédito, liquidez y mercado.

IV.3. Diseño y construcción del modelo *deep learning*

La estructura de un modelo de aprendizaje profundo incluye varias capas ocultas. En ese sentido, para la construcción de un modelo de prueba de estrés mediante el método *deep learning*, se formula la siguiente red neuronal: una capa de entrada que incluye 38 variables macroeconómicas y financieras; dos capas ocultas; y una capa de salida que incluye 9 variables objetivo: activos, activos productivos, préstamos netos, depósitos, provisiones, densidad de activo ponderado por riesgo, y costos financieros.

Gráfico 1: ESTRUCTURA DE UNA RED NEURONAL PROFUNDA



Fuente: Elaboración propia

Además, para el diseño del modelo *deep learning* se hace uso de la biblioteca *TensorFlow* que es una infraestructura flexible y escalable para el aprendizaje automático profundo y redes neuronales, lo cual nos permite trabajar con una cantidad de información granular.

Siguiendo los pasos del diseño del modelo, se divide los datos en dos partes: entrenamiento y pseudo predicción. Para el periodo de entrenamiento comprende los años 2005 – 2022 y para el periodo de pseudo predicción comprende el año 2023.

IV.4. Evaluación del modelo

Siguiendo la literatura para estimar las variables objetivo se presentan métricas de validación mediante los estadísticos del Error Cuadrático Medio (RMSE, por su sigla en inglés), el Error Absoluto Medio (MAE) y El Error del Porcentaje Absoluto Medio (MAPE, por su sigla en inglés). El modelo apropiado para la predicción tendrá los menores valores de los estadísticos. En este sentido, considerando cinco enfoques de modelación –Modelo de Hoja de Balance Constante, Modelo Satélite, Modelo *Deep Learning*, *Deep Learning* (Bayesian ReLU⁶) y *Deep Learning* (Bayesian LWTA⁷)– para una muestra de entrenamiento 2005 – 2022. Se puede apreciar que los valores de los estadísticos de validación señalan que el poder predictivo reside sobre el modelo *deep learning* con valores menores al resto de los enfoques de modelación. En cambio, para el periodo de entrenamiento 2023, los modelos con menor valor de validación estadística corresponden a los modelos de aprendizaje simple o con métodos bayesianos (ver Cuadro 5).

- 6 ReLU (*Rectified Linear Unit*) es una función de activación clave en deep learning debido a su simplicidad, eficiencia y capacidad para mitigar el desvanecimiento del gradiente. Se define como:

$$f(x) = \max(0, x)$$

$$\begin{aligned} \text{Si: } x > 0, f(x) &= x \\ x < 0, f(x) &= 0 \end{aligned}$$

La Bayesian ReLU es una extensión de la ReLU diseñada para integrar principios de inferencia bayesiana en redes neuronales. Combina la simplicidad y eficiencia computacional de la ReLU tradicional con un enfoque probabilístico, lo que la hace adecuada para modelar incertidumbre en problemas donde esta es crítica, como en tareas de toma de decisiones bajo riesgo o en aplicaciones de pruebas de estrés financiero.

$$f(x) = \max(0, x) + \varepsilon$$

donde. $\varepsilon \sim \mathcal{N}(0, \sigma^2)$ en un término de ruido gaussiano que introduce incertidumbre en el modelo. Los pesos y los sesgos se tratan como distribuciones típicamente gaussianas con priors definidas.

- 7 **LWTA** (*Localized Winner-Take-All*) es un mecanismo de activación y selección utilizado en redes neuronales que fomenta y mejora la robustez del modelo al seleccionar las unidades más relevantes dentro de un grupo para contribuir al aprendizaje. Este enfoque se utiliza en escenarios donde se busca priorizar características importantes, reducir el ruido en los datos y mejorar la capacidad de generalización del modelo. Solo la neurona con la mayor activación en su grupo contribuye a la salida, mientras que las demás son “apagadas”.

Cuadro 5: MEDIDAS DE VALIDACIÓN EN MUESTRA

Entrenamiento			
Modelos	RMSE	MAE	MAPE
Constant Balance Sheet	0,436703	0,328389	0,999348794
Satellite Modelling	0,436703	0,328389	0,999348794
Deep Learning	0,051177	0,021446	5,92967E+11
Deep Learning (Bayesian ReLU)	0,055955	0,021938	6,31552E+11
Deep Learning (Bayesian LWTA)	0,045585	0,022305	7,65014E+11
Prueba			
Modelos	RMSE	MAE	MAPE
Constant Balance Sheet	0,524811	0,448539	1,000000
Satellite Modelling	0,524811	0,448539	1,000000
Deep Learning	0,078167	0,047764	0,279895
Deep Learning (Bayesian ReLU)	0,076717	0,047702	0,329416
Deep Learning (Bayesian LWTA)	0,075109	0,048497	0,278770

Fuente: Elaboración propia

Nota: Los modelos con aprendizaje profundo sea ha estimado mediante LSTM (Long Short Term Memory). La periodicidad de entrenamiento comprende desde el año 2005 hasta el 2022 y el periodo de prueba dentro de muestra se considera el año 2023. La definición de cada uno de los modelos se encuentra en el Anexo

V. Prueba de tensión

V.1. Diseño de prueba de tensión

Una parte importante para analizar la resistencia del sistema financiero son el diseño de escenario de estrés. Un escenario de estrés en el sector financiero es una simulación o análisis que evalúa como responderían las entidades financieras como los bancos ante condiciones macroeconómicas adversas extremas. Estos escenarios se diseñan para medir la resistencia de las entidades frente a eventos de crisis que podrían afectar la liquidez, solvencia y estabilidad. Los escenarios de estrés son esenciales para identificar posibles vulnerabilidades en el sistema financiero y para planificar respuestas efectivas para mitigar riesgos.

En la literatura sobre pruebas de estrés hay características de escenarios de estrés, pero, en su mayoría, suele basarse en suposiciones de eventos económicos severos que podrían impactar sobre las variables importantes

de la economía. Por ejemplo, los choques macroeconómicos implican recesiones profundas, alta inflación, desempleo elevado o caídas significativas.

Con base en los estadísticos históricos de las variables macroeconómicas, se definen dos escenarios para el periodo 2024: el escenario base, que utiliza el valor promedio histórico de cada variable para representar condiciones macroeconómicas normales, y el escenario de estrés, que considera valores cercanos al percentil 10 de la distribución histórica para evaluar las condiciones más desfavorables registradas en el pasado. Este último afecta a variables como el Producto Interno Bruto (PIB), el gasto público como porcentaje del PIB (*g_pib*) y las exportaciones como proporción del PIB (*exp*). En el caso de la inflación (*inf*) y el desempleo (*unem*), se emplea el percentil 90 para identificar los niveles más altos de inflación y las tasas de desempleo más elevadas. La inclusión de este escenario permite evaluar la capacidad de resistencia del sistema financiero ante situaciones de mayor tensión macroeconómica. A continuación, el Cuadro 6, presenta el diseño de escenarios de las variables macroeconómicas⁸:

Cuadro 6: DISEÑO DE ESCENARIOS

Escenarios	PIB	g_PIB	exp_PIB	inf	unem
Base	3,95	16,13	2,79	4,47	4,34
Estresado	1,33	1,26	-11,58	10,42	5,87

Fuente: Elaboración propia

V.2. Transmisión de escenarios de estrés en la hoja de balance

Petropoulos *et al.* (2019) proponen un modelo con técnicas de aprendizaje profundo para las pruebas de estrés en balances financieros. El modelo integra datos financieros históricos y variables macroeconómicas en un modelo de aprendizaje profundo para simular de forma dinámica el impacto de choques económicos sobre el balance bancario. A diferencia de los modelos convencionales que requieren suposiciones rígidas, *deep-*

8 El diseño de escenarios de estrés comprende tres escenarios: base, moderado, estresado. En el escenario base, se calcula la media de cada una de las variables macroeconómicas para el periodo 2005 – 2023. Para el escenario moderado se calcula el percentil 90 para cada una de las variables macro, y para el escenario estresado se calcula el percentil 10 de las variables macro.

stress emplea un enfoque dinámico y adaptativo que se ajusta a nuevas informaciones y cambios en el mercado. Este enfoque permite a los bancos y a los reguladores evaluar con mayor precisión la solvencia y liquidez bajo distintos escenarios de estrés.

Para el cálculo de los resultados de la prueba de estrés en la hoja de balance, los autores utilizan la siguiente ecuación:

$$\text{Capital}_t = \text{Ganancias de los activos}_t - \text{Previsiones de cartera}_t \\ + \text{Ingresos operativos netos}_t - \text{Gastos Financieros}_t + \text{Capital}_{t-1}$$

Según los autores, se tiene la siguiente relación de las variables objetivo con el cálculo de las variables de la ecuación.

- Ganancias de los activos (GA), es el resultado de multiplicar activos por el ROA.
- Las provisiones de cartera (PREV), que representan los cargos por incobrabilidad de cartera, en este caso determinadas a partir de la contabilización de las provisiones relacionadas con la calificación de cartera.
- Ingresos operativos netos (IO), donde se consideran los otros ingresos netos del balance financiero.
- Los gastos financieros (GF) aproximados a partir de los costos financieros.
- El Capital, para nuestro caso, será considerado como el patrimonio neto (PN), con el objeto de realizar el cálculo del CAP.

En este sentido la ecuación se transformaría en:

$$\text{Capital}_t = \text{GA}_t - \text{PREV} + \text{IO}_t - \text{GF}_t + \text{PN}_{t-1} \quad (13)$$

Si bien la cartera neta y los activos totales no son considerados en la ecuación, se debe considerar que ambas variables afectan el cálculo del patrimonio neto ya que afectan la calidad del balance y el patrimonio contable de las EIF.

Por su parte, la densidad de los activos ponderados por riesgos, es importante para el cálculo de los Activos Ponderados por Riesgos (APR) y el cálculo del Coeficiente de Adecuación Patrimonial (CAP).

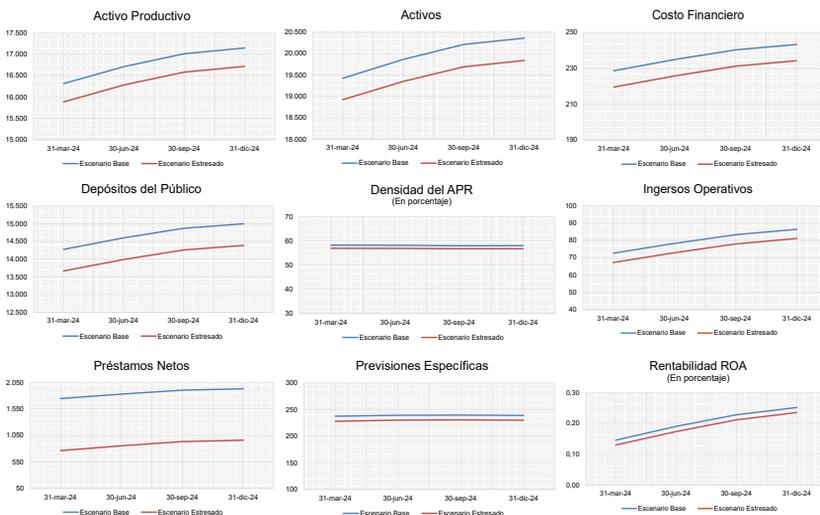
Así:

$$CAP_{t+1} = \frac{\text{Patrimonio Neto}_{t+1}}{APR_{t+1}} \quad (14)$$

VI. Resultados

En el Gráfico 2, se presentan los resultados para las nueve variables objetivo, calculado mediante el modelo de aprendizaje profundo. Las variables presentan un comportamiento adecuado sin cambios atípicos, tanto para el escenario base, así como para el escenario estresado. En este sentido, ante un posible deterioro de las variables macroeconómicas, las variables objetivo presenta menores niveles que en el escenario base.

**Gráfico 2: RESULTADO DE LA VARIABLES OBJETIVOS
(En millones de Bs)**



Fuente: Elaboración propia

Nota: Previo a la predicción fuera del periodo muestral, se ha realizado una evaluación mediante una pseudo predicción para cada una de las variables objetivo para evaluar el ajuste sobre el valor observado

Para evaluar el impacto sobre el CAP, en primera instancia, se calcula el capital en función de las variables objetivo (determinantes) para obtener el valor en el periodo de predicción, tanto para el escenario base como para el escenario estresado. En cambio, el Activo Ponderado por Riesgo se

obtiene a partir de una predicción mediante el modelo simple de *deep learning*. En el Cuadro 7 se presenta los resultados de los componentes del CAP.

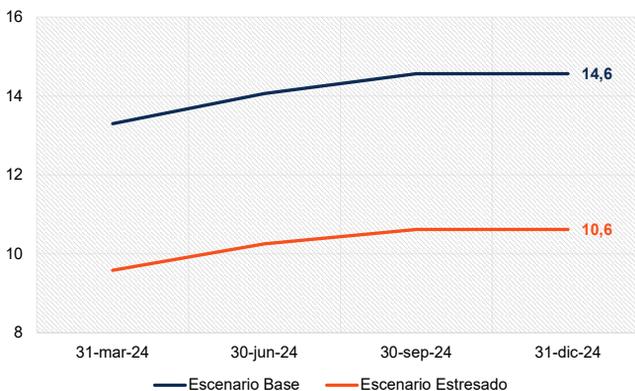
Cuadro 7: RESULTADO DE LA VARIABLES OBJETIVOS

Fecha	APR	CAPITAL	
		Escenario Base	Escenario Estresado
31-mar-24	12.038	1.646	1.173
30-jun-24	11.895	1.729	1.251
30-sep-24	11.577	1.753	1.273
31-dic-24	11.661	1.766	1.287

Fuente: Elaboración propia

Una vez realizada la proyección de las variables objetivo y haber agregado dichas variables para evaluar el impacto de las variables macroeconómicas estresadas por escenarios, se obtuvieron los siguientes resultados en el CAP proyectado.

Gráfico 3: RESULTADOS DE LOS ESCENARIOS DEL CAP⁹



Fuente: Elaboración propia

Nota: CAP promedio de las entidades bancarias

En este sentido, los resultados reflejan la capacidad de resiliencia del sistema bancario ante escenarios macroeconómicos adversos, proyectados en un horizonte de 12 meses. Los resultados muestran que,

9 En el Apéndice B se presenta los resultados por EIF.

bajo un escenario estresado, el CAP podría disminuir del 14,0% actual al 10,6%, manteniéndose por encima del requisito regulatorio mínimo del 10%.

Aunque el CAP proyectado permanecería dentro del margen legal, se recomienda fortalecer el patrimonio neto para garantizar el cumplimiento de los requisitos regulatorios, especialmente en escenarios estresados. Además, resulta crucial establecer un monitoreo continuo de las variables relacionadas con los riesgos financieros para anticipar posibles vulnerabilidades y mitigar su impacto.

Mapa de calor del indicador de solvencia por bancos

El siguiente gráfico evalúa el impacto que tendría la materialización del deterioro de las variables macroeconómicas sobre la solvencia de los bancos. Considerando los dos escenarios, los resultados muestran que la mayoría de los bancos cuentan con niveles adecuados de solvencia. Sin embargo, seis bancos presentarían problemas de solvencia para la gestión 2024, situándose por debajo del umbral establecido en la Ley 393 de Servicios Financieros¹⁰ (Gráfico 4).

¹⁰ En la Ley No 393 de Servicios Financieros, se establece un umbral de 10% para el indicador de solvencia de Coeficiente de Adecuación Patrimonial.

Gráfico 4: MAPA DE CALOR DE SOLVENCIA POR BANCOS (En porcentaje)

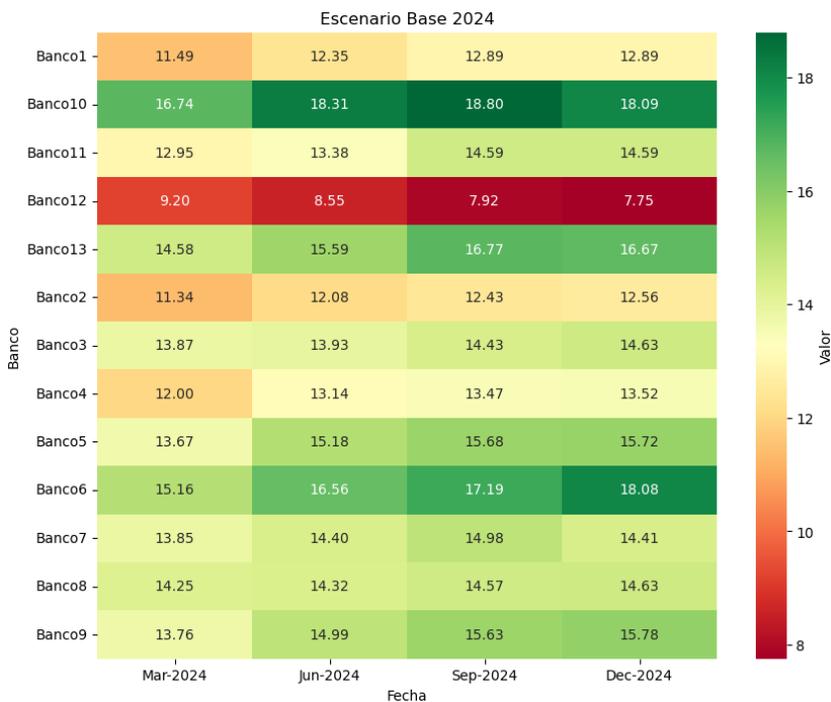
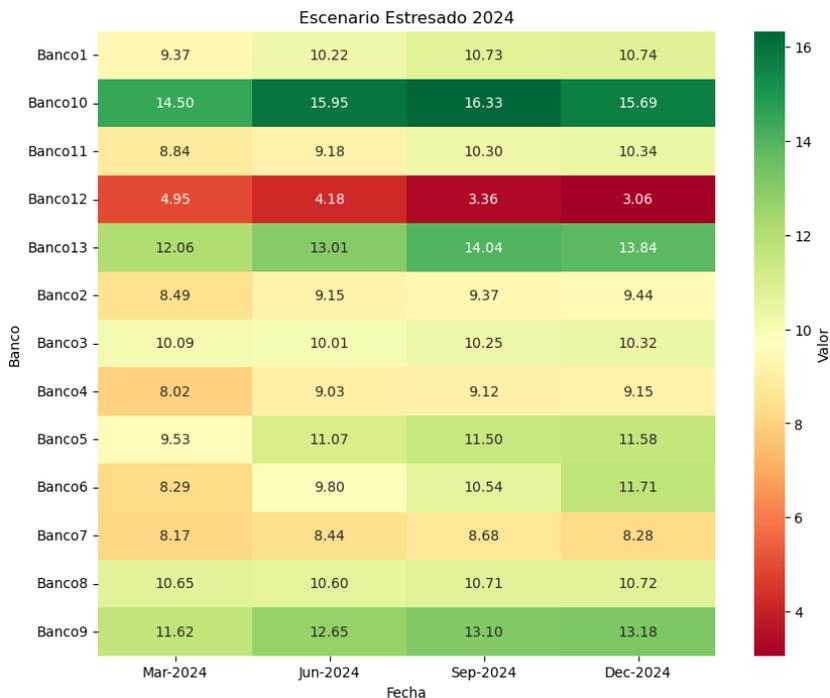


Gráfico 4: MAPA DE CALOR DE SOLVENCIA POR BANCOS (Cont.)
(En porcentaje)



Fuente: Elaboración propia

Nota: El mapa de calor se distribuye en tres colores: el color verde representa elevados niveles de solvencia; amarillo, representa un nivel moderado de solvencia y rojo representa aquellos bancos con bajo nivel de solvencia

VII. Conclusión

- Los modelos basados en aprendizaje profundo (*deep learning*) ofrecen una capacidad superior para capturar relaciones no lineales complejas entre variables macroeconómicas y financieras en pruebas de estrés. Comparados con métodos econométricos tradicionales, como los modelos ARIMA o DSGE, el enfoque propuesto evidencia mayor precisión en la proyección de escenarios adversos, especialmente en términos de solvencia. En particular, el modelo logró predecir con éxito el Coeficiente de Adecuación Patrimonial, mostrando una

disminución en escenarios estresados, pero manteniéndose dentro de los márgenes regulatorios.

- El uso de redes neuronales profundas permite a los reguladores evaluar con mayor precisión la resiliencia del sistema bancario. Este enfoque facilitaría el diseño de políticas macroprudenciales más efectivas y oportunas. Asimismo, los resultados sugieren fortalecer el patrimonio neto de los bancos y mantener un monitoreo constante de las variables clave de riesgo financiero.
- Los resultados de la prueba de tensión integral establecen que, considerando los supuestos el escenario estresado, el CAP, en promedio, se mantiene por encima del 10%, por encima del establecido por la Ley. Determinando que el sistema financiero bancario cuenta con una elevada solvencia.
- Aunque el modelo de aprendizaje profundo muestra un alto rendimiento predictivo, su implementación requiere grandes volúmenes de datos de alta calidad. Las limitaciones en la disponibilidad y consistencia de los datos podrían afectar la precisión del modelo.
- Para investigaciones futuras, se recomienda explorar más este tipo de modelos para potenciar aún más las capacidades predictivas y operativas en la gestión de riesgos financieros desde una visión macroprudencial y mejorar los resultados presentados en este documento.

Referencias bibliográficas

BASHEER, I. and HAJMEER, M., 2000. Artificial Neural Networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43 (1), pp. 3 - 31. ISSN en línea 1872-8359. Disponible en: [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)

BERLANGA, Vanesa, RUBIO, María y VILÀ, Ruth, 2013. Cómo aplicar árboles de decisión en SPSS. *Revista d'Innovació i Recerca en Educació*, 6 (1), pp. 65 - 79. ISSN: 1886-1946. Disponible en: <https://doi.org/10.1344/reire2013.6.1615>

BORIO, Claudio, DREHMANN, Matias and TSATSARONIS, Kostas, 2014. Stress-testing macro stress testing: Does it live up to expectations? *Journal of Financial Stability*, 12, pp.3 - 15. ISSN en línea: 1878-0962. Disponible en: <https://doi.org/10.1016/j.jfs.2013.06.001>

BREIMAN, Leo, FRIEDMAN, Jerome, OLSHEN, Richard and STONE, Charles, 1984. *Classification and Regression Trees*. Boca Raton, Florida: Chapman & Hall/CRC. ISBN 978-0-412-04841-8

CHAFIK, Omar, MIKOU, Mohammed, MOTL, Tomas and SLAOUI, Yassine, 2022. A DSGE model for macroprudential policy in Morocco. Bank Al-Maghrib, Working paper, December. Disponible en: <https://www.bkam.ma/content/download/776339/8675179/version/1/file/DSGE+for+macroprudential+policy.pdf>

CHRONOPOULOS, Ilias, CHRYSIKOU, Katerina, KAPETANIOS, George, MITCHELL, James and RAFTAPOSTOLOS, Aristeidis, 2023. Deep Neural Network Estimation in Panel Data Models. Federal Reserve Bank of Cleveland, Working paper No. 23-15, July. Disponible en: <https://www.clevelandfed.org/-/media/project/clevelandfedtenant/clevelandfedsite/publications/working-papers/2023/wp2315.pdf>

ČIHÁK, Martin, 2004. Stress Testing: A Review of key Concepts. Czech National Bank, Internal Research and Policy Note, 2, April. Disponible en: https://www.cnb.cz/export/sites/cnb/en/economic-research/.galleries/research_publications/irpn/download/irpn_2_2004.pdf

DANIELSSON, Jon, SHIN, Hyun and ZIGRAND, Jean-Pierre, 2001. Asset Price Dynamics with Value-at-Risk Constrained Traders. Financial Markets Group, London School of Economics, Discussion Paper No.367. En: *29th EFA Annual Meeting*. Berlin, Germany: EFA, August. Disponible en: <https://dx.doi.org/10.2139/ssrn.302307>

ELHOSENY, Mohamed, METAWA, Noura, SZTANO, Gabor and EL-HASNONY, Ibrahim, 2022. Deep Learning-Based Model for Financial Distress Prediction. *Annals of Operations Research*, 345, pp. 885 – 907. ISSN en línea: 1572-9338. Disponible en: <https://doi.org/10.1007/s10479-022-04766-5>

GAI, Prasanna and KAPADIA, Sujit, 2010. Contagion in financial networks. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466 (2120), pp. 2401–2423. ISSN en línea: 1471-2946. Disponible en: <https://doi.org/10.1098/rspa.2009.0410>

HUANG, Jian, CHAI, Junyi and CHO, Stella, 2020. Deep learning in finance and banking: A literature review and classification. *Frontiers of Business Research in China*, 14 (2). ISSN en línea: 1673-7431. Disponible en: <https://doi.org/10.1186/s11782-020-00082-6>

JURADO, Llorent, HIRALDO, Melgar y SANZ, Ordaz, 2011. Una aproximación a las técnicas cuantitativas en las pruebas de estrés a la banca. En: *XIX Jornadas ASEPUMA – VII Encuentro Internacional*. Valencia: Universidad Pablo de Olavide. Disponible en: <https://investiga.upo.es/documentos/5eb2892329995203e240fe88>

LECUN, Yann, BENGIO, Yoshua and HINTON, Geoffrey, 2015. Deep learning. *Nature*, 521 (7553), pp. 436 – 444. ISSN en línea: 1476-4687. Disponible en: <https://doi.org/10.1038/nature14539>

LOH, Wei-Yin, 2011. Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1 (1), pp. 14 - 23. ISSN en línea: 1942-4795. Disponible en: <https://doi.org/10.1002/widm.8>

ONG, Li, ed., 2014. *A Guide to IMF Stress Testing. Methods and models*. Washington D.C.: International Monetary Fund. ISBN 978-1-47555-129-7.

Disponible en: <https://www.elibrary.imf.org/display/book/9781484368589/9781484368589.pdf>

OURA, Hiroko and SCHUMACHER, Liliana, 2012. Macrofinancial Stress Testing—Principles and Practices. International Monetary Fund, Monetary and Capital Markets Department, Working paper, August. Disponible en: <https://www.imf.org/external/np/pp/eng/2012/082212.pdf>

PÉREZ, Daniel y TRUCHARTE, Carlos, 2011. Los ejercicios de estrés test: Experiencia reciente y reflexiones sobre su futuro. Banco de España, *Estabilidad Financiera*, 21, pp. 63 – 82. Disponible en: <https://www.bde.es/f/webbde/Secciones/Publicaciones/InformesBoletinesRevistas/RevistaEstabilidadFinanciera/11/ref0421.pdf>

PETROPOULOS, Anastasios, SIAKOULIS Vasilis, VLACHOGIANNAKIS, Nikolaos and STAVROULAKIS, Evaggelos, 2019. Deep-Stress: A deep learning approach for dynamic balance sheet stress testing. En: *ICAIF '22: Proceedings of the Third ACM International Conference on AI in Finance*. New York: ICAIF, pp. 53 – 61. Disponible en: <https://doi.org/10.1145/3533271.3561656>

QUINLAN, J. Ross, 1993. *C4.5: Programs for Machine Learning*. London: Morgan Kaufmann Publishers. ISBN 1-55860-238-0

TSARYK, Krystyna, 2020. Artificial Neural Networks and Deep Learning for stress testing a banking system. Università Ca'Foscari Venezia. Master's Degree in Economics and Finance Final Thesis. Disponible en: <https://unitesi.unive.it/bitstream/20.500.14247/16922/1/856865-1247126.pdf>

URIBE, Jorge, MORALES, Miguel y PIÑEROS, José, 2008. Análisis de estrés sobre el sistema bancario colombiano: un escenario conjunto de riesgos. Banco de la República – Colombia, Reporte de Estabilidad Financiera, septiembre. Disponible en: <https://www.banrep.gov.co/sites/default/files/publicaciones/archivos/analisis.pdf>

VARIAN, Hal, 2014. Big Data: New Tricks for Econometrics. *Journal of Economic Perspectives*, 28 (2), pp. 3 – 28. ISSN en línea: 1944-7965. Disponible en: <https://doi.org/10.1257/jep.28.2.3>

APÉNDICES

Apéndice A

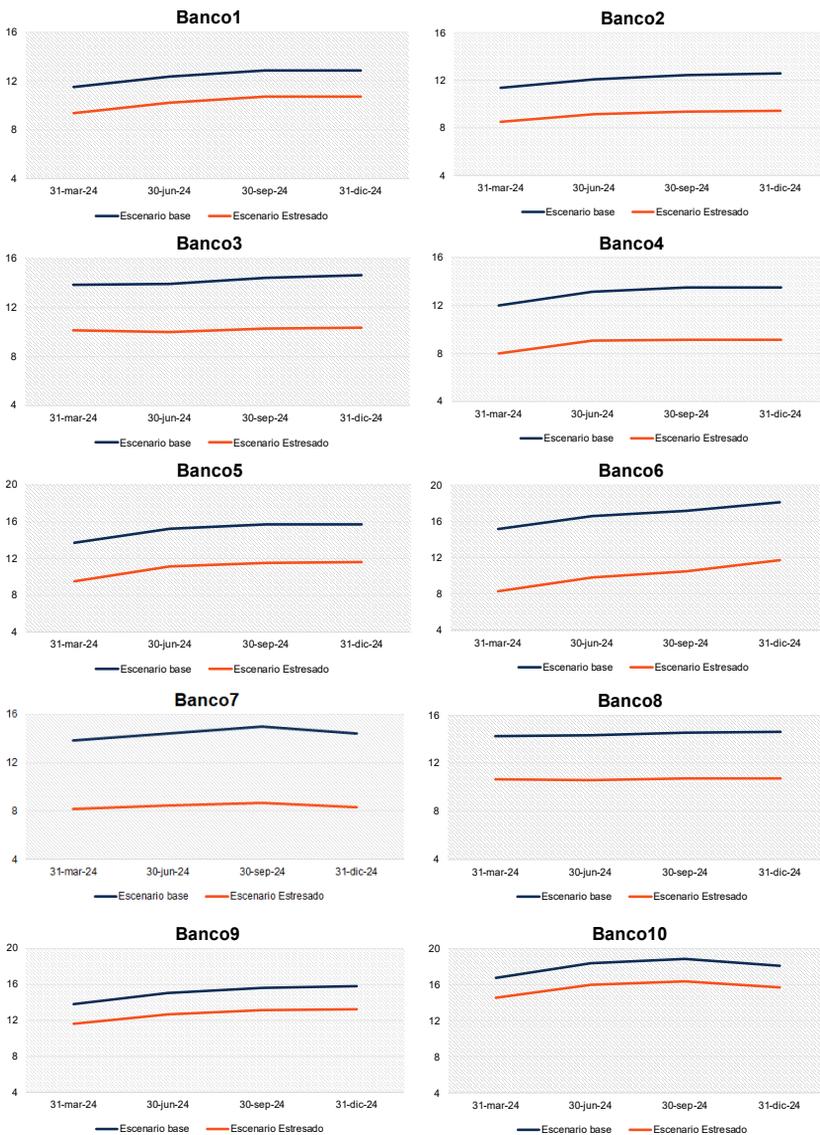
DESCRIPCIÓN DE LAS VARIABLES DEL MODELO

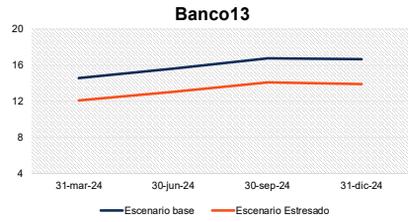
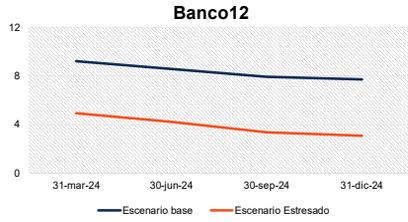
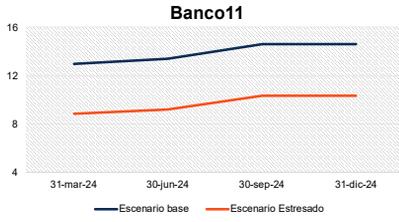
Variables	Descripción	Simbolos	Fuente
Variables macroeconómicas			
Crecimiento del Producto Interno Bruto	Es la tasa de crecimiento del PIB trimestral, es la variación a similar periodo.	pi_b	Instituto Nacional de Estadística (INE)
Participación del gasto público	Es la relación de la actividad de gasto público sobre la actividad económica	g_pi_b	
Participación de las exportaciones	Compara la proporción de las exportaciones respecto al PIB	exp	
Inflación	Es la variación del Índice de Precio al Consumidor a similar periodo	inf	
Desempleo	Mide la proporción de la población desocupada en las zonas urbanas.	unem	
Variables financieras			
Activos	Son activos que mantiene la entidad de intermediación financiera	activos	Autoridad de Supervisión del Sistema Financiero (ASFJ)
Activo Productivo	Activo generado de ingresos	act_pro	
Activo Improductivo	Activo que no generan ingresos	act_impro	
Cartera bruta	Principal activo de riesgos	cartera_bruta	
Cartera en mora	Saldo de la cartera con incumplimiento de pagos	mora	
Solvencia	Coefficiente de Adecuación Patrimonial, es la relación entre el capital regulatorio sobre el activo ponderado por riesgos.	cap	
Índice de morosidad	Porcentaje de la cartera que se encuentra con incumplimiento del pago	im	
Previsiones específicas	Importe constituido para cubrir el riesgo de pérdida por incobrabilidad de préstamos como consecuencia de la evaluación y calificación individual de los deudores.	prev_esp	
Depósitos del Público	Fondos recibidos en depósito y otros tipos de obligaciones con el público en general.	dep_pub	
Activos Líquidos	Activo de fácil conversión a efectivo, tales como disponibilidades e inversiones financieras negociables en el mercado.	act_liquid	
Pasivos de Corto Plazo	Obligaciones que deben pagarse en un plazo de 90 días	pasivos_cp	
Pasivos sin Costo	Pasivos que surgen de la propia actividad de la EIF	pas_sin_costo	
Pasivos con costo operativo	Obligaciones que tienen un costo financiero implícito de captación	pas_costo_ope	
Patrimonio	Participación en la propiedad de los activos de una EIF después de deducir los pasivos. Refleja el valor que pertenece a los accionistas	patrimonio	
Patrimonio Eficiente	Gestión óptima del patrimonio contable y el mantenimiento de un Coeficiente de Adecuación Patrimonial adecuado (Asset and Liability Management)	patrimonio_eficiente	
Gestión de Activos y Pasivos	Administración de los riesgos financieros que surgen debido a descalces entre los activos y pasivos, especialmente en términos de plazos y tasas de interés.	alm	
Utilidades	Ganancias netas que una empresa obtiene después de deducir todos los costos y gastos asociados a su operación, incluyendo impuestos y otros compromisos financieros.	utilidades	
Rentabilidad sobre Patrimonio	Ratio de rentabilidad, que relaciona la utilidad neta con el patrimonio promedio de una EIF	roe	
Rentabilidad sobre activos	Ratio que relaciona la utilidad neta con el promedio de los activos totales de una EIF. Muestra cuál es la capacidad de los activos para generar utilidades.	roa	
Brecha de cartera y depósitos	Indicador financiero que refleja la diferencia entre el total de depósitos recibidos por las entidades financieras y el total de créditos otorgados	brecha	
Densidad de activos ponderados por riesgo	Proporción de los activos de una institución financiera que han sido ajustados según su nivel de riesgo, en relación con el total de activos.	dpr	
Liquidez sobre total activos	Proporción de los activos líquidos sobre el total de activos	liquidez_tot_act	
Disponibilidades sobre Obligaciones de Corto Plazo	Capacidad de una EIF para cumplir con sus compromisos financieros inmediatos utilizando sus activos más líquidos.	disp_oblig_cp	
Ingresos Financieros	Ingresos del período provenientes de la actividad de intermediación entre la oferta y la demanda de recursos financieros.	if	

Variación de Ingresos Financieros	Variación a 12 meses de los ingresos financieros	var_ing_fin
Promedio de la variación de Ingresos financieros	Variación promedio de los Ingresos financieros a 12 meses	prom_var_df
Cartera promedio	Cartera bruta promedio a 12 meses	c_prom
Gastos Financieros	Gastos del período provenientes de la actividad de intermediación financiera. Comprende los cargos por obligaciones con el público.	gf
Variación de gastos financieros	Variación promedio de los gastos financieros a 12 meses	var_gf
Promedio de la variación de gastos financieros	Variación promedio de los Gastos financieros a 12 meses	prom_var_gf
Depósitos del Público promedio	Depósitos del público promedio a 12 meses	d_prom
Tasa promedio de cartera		t_prom_c
Tasa promedio de depósitos		t_prom_d
Spread	Diferencia entre t_prom_c y t_prom_d	spread
Cobertura de provisiones	Indicador financiero que mide la capacidad de una EFP para absorber los créditos en mora, mediante las provisiones específicas	cob_prev
Activo Ponderado por Riesgo	Valor del activo multiplicado por el ponderador de riesgos	apr
Cobertura de pasivos de corto plazo	Proporción de activos líquidos que cubren pasivos de corto plazo	cp.
Cartera Neta	Cartera neta de garantías reales	net_loan

Apéndice B

RESULTADOS POR BANCOS





RESEÑA LITERARIA

Reseña del libro *Slow burn: The hidden costs of a warming world*

Autor: Kenneth Rogoff

Editorial: Yale University Press

Año: 2025

Número de páginas: 360

Desde la posguerra hasta la era de las criptomonedas, el dólar estadounidense ha ejercido una influencia decisiva en la configuración del orden financiero internacional. En *Our Dollar, Your Problem*, Kenneth Rogoff, reconocido economista de Harvard y ex economista jefe del Fondo Monetario Internacional (FMI), ofrece un análisis personal, histórico y económico sobre el rol del dólar como moneda de reserva global, sus implicancias geopolíticas y los riesgos crecientes que enfrenta su hegemonía.

El título hace alusión a la frase célebre pronunciada por John Connally, entonces Secretario del Tesoro estadounidense, en 1971 "It's our dollar, but it's your problem". Esta afirmación, que sintetiza la tensión entre la soberanía monetaria de Estados Unidos y su rol internacional, sirve como punto de partida para un libro que combina la memoria institucional del autor con un diagnóstico preciso sobre los desafíos del sistema monetario global.

Uno de los ejes fundamentales del libro es la evolución histórica del dólar en siete décadas de turbulencia financiera. Se repasan eventos como el colapso del sistema de Bretton Woods, las crisis de deuda en América

Latina, la consolidación del mercado global de capitales, la Gran Recesión de 2008 y el surgimiento de los activos digitales. En cada episodio, el autor entrelaza su experiencia personal, con un análisis técnico que permite entender cómo y por qué el dólar ha mantenido su supremacía a lo largo del tiempo.

Rogoff sostiene que la posición privilegiada del dólar no es producto exclusivo de la economía estadounidense, sino también de una combinación institucional de liquidez, profundidad de mercado, estabilidad jurídica y poder geopolítico. Sin embargo, advierte que esta supremacía se enfrenta a nuevas amenazas, muchas de ellas generadas dentro del propio Estados Unidos como ser un elevado endeudamiento público, creciente polarización política y la posibilidad de interferencia en la autonomía de la Reserva Federal. Estos factores, según el autor, erosionan gradualmente la confianza internacional en el dólar y podrían dar paso a un proceso de fragmentación financiera global.

En materia de desigualdad financiera global, Rogoff plantea que la centralidad del dólar ha contribuido a concentrar poder económico y a generar vulnerabilidades estructurales en países emergentes. Muchas economías, especialmente en América Latina, África y el sudeste asiático, dependen, en gran medida, de la estabilidad del dólar para financiar sus déficits externos, acumular reservas y estabilizar sus sistemas monetarios. Esta dependencia, si bien aporta estabilidad en ciertos momentos, también expone a estos países a ciclos de entrada y salida de capitales, crisis cambiarias y restricciones a su soberanía económica en temas de política monetaria.

Uno de los aportes más valiosos del libro radica en su exploración de las alternativas al dólar, analiza con profundidad las limitaciones actuales del euro, rublo soviético, del renminbi chino y de las monedas digitales de bancos centrales (CBDC) para reemplazar al dólar como activo de reserva dominante. En todos los casos, identifica obstáculos estructurales como la falta de unión fiscal en Europa, controles financieros en China y una arquitectura institucional incipiente en el caso de los activos digitales. Desde su perspectiva, el reemplazo del dólar no ocurrirá por sustitución directa, sino posiblemente por una diversificación gradual hacia un sistema más multipolar.

El autor también introduce un enfoque normativo. Más allá del diagnóstico, propone un conjunto de reformas orientadas a fortalecer la arquitectura monetaria internacional. Aboga por restaurar la disciplina fiscal en Estados Unidos, garantizar la independencia de la Reserva Federal y promover marcos multilaterales que reduzcan la exposición excesiva de las economías en desarrollo al dólar. Asimismo, plantea la necesidad de revisar el papel del FMI y de los acuerdos de *swaps* entre bancos centrales como mecanismos para contener la volatilidad global.

Un capítulo especialmente relevante es el dedicado a las criptomonedas y las CBDCs. Rogoff, autor de *The Curse of Cash*, ha sido una voz crítica frente al entusiasmo desmedido por las monedas digitales. En este libro, mantiene su postura reconociendo su potencial disruptivo, pero subraya que, sin regulación, respaldo institucional y aceptación generalizada, estos instrumentos difícilmente podrán reemplazar al dólar. Aun así, destaca que podrían acelerar el proceso de debilitamiento de la hegemonía estadounidense si las condiciones internas continúan deteriorándose.

El estilo del libro también contribuye a su impacto. A pesar de tratar un tema técnico, la escritura de Rogoff es clara, atractiva y en muchos pasajes introspectiva. Su capacidad de conectar teoría económica con historias personales y contextos históricos amplía el alcance del texto y lo convierte en una lectura tanto formativa como estimulante.

Our Dollar, Your Problem es una contribución fundamental al debate sobre el futuro del sistema monetario internacional. Su enfoque sobre los riesgos domésticos que enfrenta el dólar llena un vacío en la literatura sobre hegemonía monetaria y proporciona herramientas analíticas útiles para anticipar escenarios futuros. En un contexto global donde las monedas digitales, las tensiones geopolíticas y la inestabilidad fiscal redefinen las reglas del juego, el trabajo de Rogoff resulta en una lectura obligatoria.

Finalmente, como bien advierte el autor, el dólar no está condenado a caer, pero tampoco es invulnerable. Su destino dependerá, en gran medida, de las decisiones que se tomen dentro de Estados Unidos. En este sentido, el libro no solo describe el pasado, sino que lanza una advertencia clara sobre el futuro: el problema del dólar no es solo de los demás, también es, y será, cada vez más un problema para Estados Unidos.

BANCO CENTRAL DE BOLIVIA

Revista de Análisis

Instrucciones de los autores

Objetivo

La *Revista de Análisis* del Banco Central de Bolivia tiene por objetivo contribuir a la difusión y discusión de diferentes tópicos de la economía boliviana, preferentemente en temas relacionados con actividades de banca central y aquellos que tengan relevancia para la conducción de la política económica.

Contribuciones

Los artículos serán seleccionados de trabajos de investigación realizados por funcionarios del Banco Central de Bolivia y por investigadores externos al Banco. Los trabajos recibidos serán evaluados por el Consejo Editorial (CE) con la participación de evaluadores anónimos, garantizándose así la imparcialidad y seriedad del proceso.

Los trabajos de investigación deben remitirse acorde con lo establecido en las convocatorias públicas que emite regularmente el Banco Central de Bolivia. Se invita a investigadores y académicos nacionales y extranjeros a que participen de estas convocatorias, cuyos artículos serán recibidos preferentemente en inglés o español, aunque podrán enviar sus artículos escritos en su lengua nativa.

Se recomienda tomar nota de los siguientes aspectos:

- Los trabajos podrán ser abordados tanto desde una perspectiva teórica como empírica.
- Los trabajos deben enviarse, en formato Word o PDF, a la siguiente dirección de correo electrónico: **revistadeanalisis@bcb.gob.bo**. El mensaje debe incluir los datos del (de los) autor (es) (nombre, teléfono, domicilio y dirección de correo electrónico). Los autores recibirán un mensaje de correo electrónico de confirmación a la recepción del trabajo.
- El contenido del artículo debe ser original y preferentemente inédito.
- La página inicial del documento debe incluir la siguiente información: el título del artículo, nombre (s) del (de los) autores, resumen no mayor a 150 palabras, no más de cinco códigos de clasificación JEL y hasta cinco palabras clave que describan el artículo. Es importante considerar que sólo la página inicial deberá contener información referente al nombre del (de los) autor (es).
- La extensión del trabajo no debe exceder las 40 páginas en fuente Arial 11 e interlineado 1,5 (incluyendo los anexos).
- El artículo debe ser adecuado a la *Guía de Estilo de la Revista de Análisis del BCB*. Este es un requisito imprescindible para la publicación del documento.



Calle Ayacucho esquina Mercado
Teléfono: (591-2) 2409090
Fax: (591-2) 2661590
Línea gratuita: 800-10-2023
bancocentraldebolivia@bcb.gob.bo
www.bcb.gob.bo
La Paz - Bolivia

BancoCentralBO

