



Recuadro I: *Machine Learning* vs Series de Tiempo para Pronósticos de Inflación

1. Introducción

Realizar pronósticos precisos generalmente no es una tarea fácil, ya que requiere un enfoque complejo como para identificar variables relevantes y excluir aquellas sin importancia. Los métodos tradicionales de proyección tienen ciertas limitaciones, por lo que constantemente se buscan desarrollar nuevos modelos que puedan manejar conjuntos de datos más complejos y que sean suficientemente flexibles para adaptarse a condiciones cambiantes. En esta línea es que, en los últimos años, el uso de modelos de *Machine Learning* (ML) se ha vuelto popular y accesible debido a una mejora sustancial en la capacidad computacional.

Por tanto, el presente recuadro tiene como objetivo comparar el desempeño de modelos de ML con modelos econométricos tradicionales, de manera a determinar, si mediante su uso, es posible mejorar la predicción de variables macroeconómicas. En este caso, analizamos la inflación, medida por la variación mensual del Índice de Precios al Consumidor sin Alimentos y Energía (IPC SAE).

2. Modelos de Machine Learning

Los modelos de ML pueden dividirse en tres metodologías: aprendizaje supervisado, no supervisado y aprendizaje reforzado. En los modelos supervisados, los datos utilizados para el entrenamiento contienen resultados pasados conocidos, denominados "outputs, variables dependientes u objetivo". Estas son las variables que el modelo busca predecir. Así también, estos modelos pueden aprender de variables adicionales, conocidas como "inputs, variables independientes o predictoras".

Existen dos tipos de procedimientos supervisados: clasificación y regresión. En la clasificación, el objetivo es predecir a qué clase (o etiqueta) pertenece una observación particular. Entre los ejemplos más comunes se encuentra el de los correos no deseados. En este caso, el usuario provee al algoritmo una gran cantidad de correos electrónicos (inputs), indicando cuales de ellos son spam (output). Dado un nuevo correo electrónico, el algoritmo lo clasificará como spam o no¹. Entre los algoritmos de clasificación más populares se encuentran los modelos de *Random Forest* (RF), *K-Nearest Neighbors* (KNN) y *Support Vector Machines* (SVM), entre otros (Theobald, 2017).

En cuanto al análisis de regresión, este busca establecer un modelo para la relación entre un cierto número de características y una variable continua objetivo (o *target*). El propósito en este tipo de modelos es obtener una respuesta cuantitativa, por ejemplo, cómo el precio de un inmueble depende de sus características (ubicación, número de ambientes, terminaciones, etc.). Como en el caso de la econometría tradicional, aquí también es posible estimar una regresión lineal simple con una variable independiente y una variable objetivo, o una regresión múltiple con más de una variable independiente

¹ La clasificación no es necesariamente binaria; e.g., el buzón del correo electrónico puede estar clasificado en bandeja "principal", "promociones", "foros", "spam", entre otras, y el algoritmo clasificará los correos dentro de las posibles categorías.



y una variable objetivo. Algunos algoritmos de regresión lineal populares incluyen la regresión Ridge, Lasso y Elastic Net (Müller & Guido, 2017).

3. Metodología

3.1. Modelos utilizados para pronóstico

Para el pronóstico de la inflación se exploraron diferentes metodologías de aprendizaje supervisado (Tabla 1). La práctica estándar en la literatura, al comparar el rendimiento de los modelos de ML, es utilizar como referencia modelos univariados como el *Random Walk* (RW) y/o el ARIMA. En este recuadro, se opta por la comparación con este último modelo.

Tabla I. Modelos para pronosticar la inflación

1	Random Forest	Consiste en una agrupación de varios árboles de decisión individuales. Cada uno de estos árboles se entrena con una muestra ligeramente distinta de datos de entrenamiento, generada mediante <i>bootstrapping</i> . Para hacer predicciones sobre nuevas observaciones, se combinan las predicciones de todos los árboles que componen el modelo.
2	Prophet	Es un procedimiento desarrollado por Meta (Facebook) para pronosticar datos de series temporales, basado en un modelo aditivo donde las tendencias no lineales se ajustan a la estacionalidad anual, semanal y diaria, además de los efectos de días feriados.
3	Prophet Boost	Es una extensión del algoritmo original que incorpora técnicas de <i>extreme gradient boosting</i> para mejorar la precisión de los modelos. El " <i>boosting</i> " básicamente busca mejorar un modelo débil de forma individual combinándolo con otros modelos débiles, con el propósito de generar un modelo colectivo mejorado. A este tipo de modelo también se le pueden agregar tendencias lineales o logísticas para mejorar su precisión.
4	Neural Network	Son modelos que intentan imitar la forma en la que los humanos aprenden cuando reciben información. Su estructura permite capturar relaciones complejas entre los predictores y la variable a predecir sin que sea necesario especificar la forma correcta de dicha relación, ya que la propia red neuronal trata de identificar relaciones a partir de los datos disponibles para su entrenamiento.
5	XGBoost	Es una técnica de aprendizaje supervisado que consiste en un ensamblado secuencial de árboles de decisión. Los árboles se agregan secuencialmente a fin de aprender del resultado de los árboles previos y corregir el error producido por los mismos, hasta que no sea posible reducir dicho error (esto se conoce como "gradiente descendente").
6	ARIMA	El componente autorregresivo (AR) utiliza las observaciones pasadas para predecir el valor actual. La parte del promedio móvil (MA) indica que el error de proyección es una combinación lineal de los errores de predicción pasados. La I (de "integración") se refiere a la diferenciación necesaria para lograr que la serie sea estacionaria.
7	ARIMA Boost	Combina el enfoque ARIMA para modelar series temporales con el <i>boosting</i> para mejorar la precisión de los modelos de predicción.
8	MARS	El <i>Multiplicative Adaptive Regression Splines</i> , o MARS, es un método de modelación no paramétrico que extiende el modelo lineal incorporando no linealidades e interacciones de variables.
9	Exponential Smoothing	Es una técnica estadística que utiliza observaciones pasadas de una serie de tiempo para pronosticar valores futuros. Se llama "exponencial" porque asigna ponderaciones exponencialmente decrecientes a observaciones pasadas. Es decir, las observaciones más recientes tienen ponderaciones más altas que las antiguas.
10	Elastic Net	Es un algoritmo de regularización que combina las características de las regresiones Ridge y Lasso. Es utilizado para abordar problemas de multicolinealidad y <i>overfitting</i> . Este algoritmo funciona agregando términos de penalización a la función objetivo de Mínimos Cuadrados Ordinarios (MCO).

Fuente: Kelleher et. Al, (2020), Taylor & Letham (2024), Brownlee (2020), Morde (2019), Dhumne (2023), Malkari (2023), Vanegas, J. & Vásquez, F. (2017), Espinosa-Zúñiga, J. (2020).

3.2. Datos

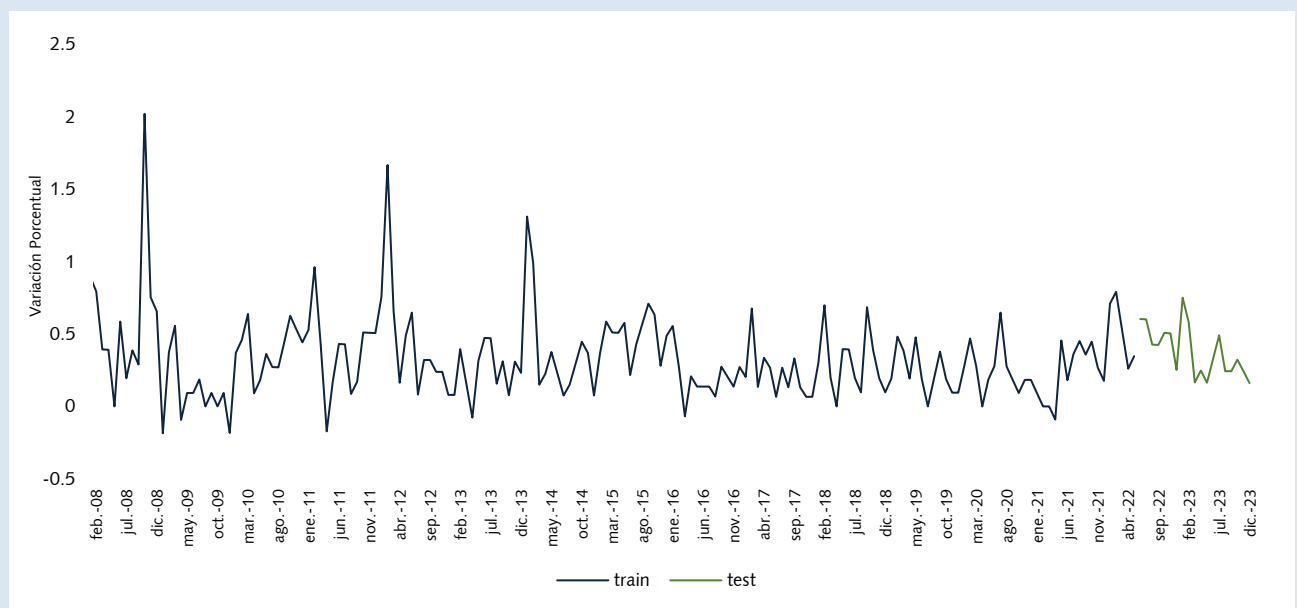
A los efectos de este recuadro, la inflación se define como: $\text{infl}_t = ((P_t) / (P_{t-1})) \times 100 - 100$, donde infl_t es la variación mensual en el mes t del índice considerado y P_t es el IPC SAE calculado por el Banco Central del Paraguay (BCP).

Los procedimientos de predicción con modelos de ML se basan en dividir el conjunto de datos en dos submuestras: una de entrenamiento (*train*), en la que, dados los hiperparámetros, se estiman los parámetros, y la submuestra de prueba (*test*), en la que se evalúan las predicciones. Tanto las estimaciones de los parámetros como los hiperparámetros son variables. Pueden tomar diferentes valores ya sea porque aprenden de los datos (en el caso de los estimadores de los parámetros) o porque fueron establecidos manualmente con anterioridad a la propia estimación (en el caso de los hiperparámetros) (Pramoditha, 2022).

De esta manera, para estimar y evaluar los distintos modelos, la muestra se divide en dos partes. La primera va desde enero de 2008 hasta abril de 2022 (172 observaciones) y es utilizada como insumo para entrenar y estimar los modelos. La segunda muestra va desde mayo de 2022 a diciembre de 2023 (20 observaciones). Esta es utilizada como un conjunto independiente de observaciones con el que se contrasta y se evalúan las predicciones de los diferentes métodos.

Gráfico I. Muestra de entrenamiento (train) y de prueba (test)

Inflación Mensual – IPC SAE



Fuente: Elaboración propia con datos del Banco Central del Paraguay.

Utilizando los modelos ajustados, se procede a generar predicciones sobre la partición de evaluación para, posteriormente, compararlas con los valores observados. Esto permite obtener métricas de evaluación de los modelos.

3.3. Ingeniería de características

Otro aspecto importante que considerar, al momento de utilizar modelos de ML, es la ingeniería de características (o *feature engineering*). Este procedimiento consiste en transformar los datos creando nuevas características, llamadas recetas (*recipes*), que son utilizadas como información para los



modelos. La Tabla II resume las *recipies* utilizadas en este caso con los diferentes modelos (Bartolomé & Zambrano, 2021).

Tabla II. Ingeniería de Características (*featuring engineering*)

<i>recipe_base</i>	<i>recipe_base</i> , que representa la especificación de preprocesamiento base, donde la fórmula es $target = f(date)$. Aquí solo se especifica que la variable objetivo se modela como función de la variable predictiva <i>date</i> .
<i>recipe_date_features</i>	<i>recipe_base</i> + algunas características adicionales generadas a partir de la columna <i>date</i> del <i>dataframe</i> : "mes ² ", "año".
<i>recipe_date_extrafeatures</i>	<i>recipe_date_features</i> + más funciones adicionales generadas a partir de la columna <i>date</i> : "trimestre", "semestre".
<i>recipe_date_extrafeatures_lag</i>	<i>recipe_date_extrafeatures</i> + 6 columnas que incluyen valores rezagados. Los valores NA para las primeras observaciones, donde no se pueden calcular valores rezagados, se imputan con un método de series temporales.
<i>recipe_date_extrafeatures_fourier</i>	transformación de Fourier ³ aplicada a la característica <i>date</i> .

4. Resultados

En total, se han evaluado 46 especificaciones correspondientes a los modelos expuestos en la Tabla I (con sus respectivas variantes), los cuales, considerando los criterios *Root Mean Squared Error* (RMSE)⁴, *Mean Absolute Error* (MAE)⁵ y *Mean Absolute Scaled Error* (MASE)⁶, parecen efectivos para pronosticar la inflación sin alimentos y energía. La Tabla II muestra los resultados de los primeros 15 métodos para el pronóstico de la inflación mensual, ordenados por su desempeño con base en el criterio RMSE.

Tabla II. Evaluación del Conjunto de Modelos para Pronosticar la Inflación

Num	Recipie	Modelo	rmse	mae	mase
1	<i>extrafeatures_lag</i>	<i>random forest</i>	0.146324	0.118741	0.794328
2	<i>extrafeatures_lag</i>	<i>XGBoost</i>	0.151399	0.117497	0.786006
3	<i>extrafeatures</i>	<i>random forest</i>	0.153041	0.121583	0.813336
4	<i>extrafeatures_fourier</i>	<i>random forest</i>	0.158320	0.128035	0.856500
5	<i>features</i>	<i>random forest</i>	0.164683	0.139606	0.933903
6	<i>features</i>	<i>arima</i>	0.168502	0.132860	0.888775
7	<i>base</i>	<i>exponential smoothing</i>	0.172474	0.137533	0.920034
8	<i>extrafeatures</i>	<i>prophet_xgboost</i>	0.180569	0.153025	1.023672
9	<i>extrafeatures_lag</i>	<i>elastic net</i>	0.180687	0.133444	0.892683
10	<i>extrafeatures_lag</i>	<i>prophet_xgboost</i>	0.182823	0.138940	0.929445
11	<i>extrafeatures_fourier</i>	<i>prophet_xgboost_log</i>	0.183435	0.156783	1.048808
12	<i>extrafeatures_lag</i>	<i>prophet_xgboost_log</i>	0.186193	0.150031	1.003641
13	<i>extrafeatures</i>	<i>prophet_xgboost_log</i>	0.187308	0.159334	1.065877
14	<i>base</i>	<i>arima</i>	0.188815	0.144764	0.968405
15	<i>base</i>	<i>arima_boost</i>	0.192951	0.147633	0.987602

Fuente: Elaboración propia.

En el periodo de evaluación, se pueden observar más claramente cuáles son los pronósticos que se ajustan mejor a los datos que los modelos no han visto para el entrenamiento. De esta manera, en el

² En este caso particular, el *feature* "mes" va a contener solo los valores correspondientes a los meses. Este tipo de *feature* puede ser útil cuando hay un componente estacional en los datos y el modelo necesita tener en cuenta las variaciones entre meses diferentes. Esta explicación aplica también para los demás *features*: año, semestre y trimestre.

³ La Transformada de Fourier puede ayudar a extraer características relevantes de datos de series temporales mediante el análisis de sus componentes de frecuencia. Esto es crucial para tareas como la detección de anomalías, el análisis de tendencias y las proyecciones.

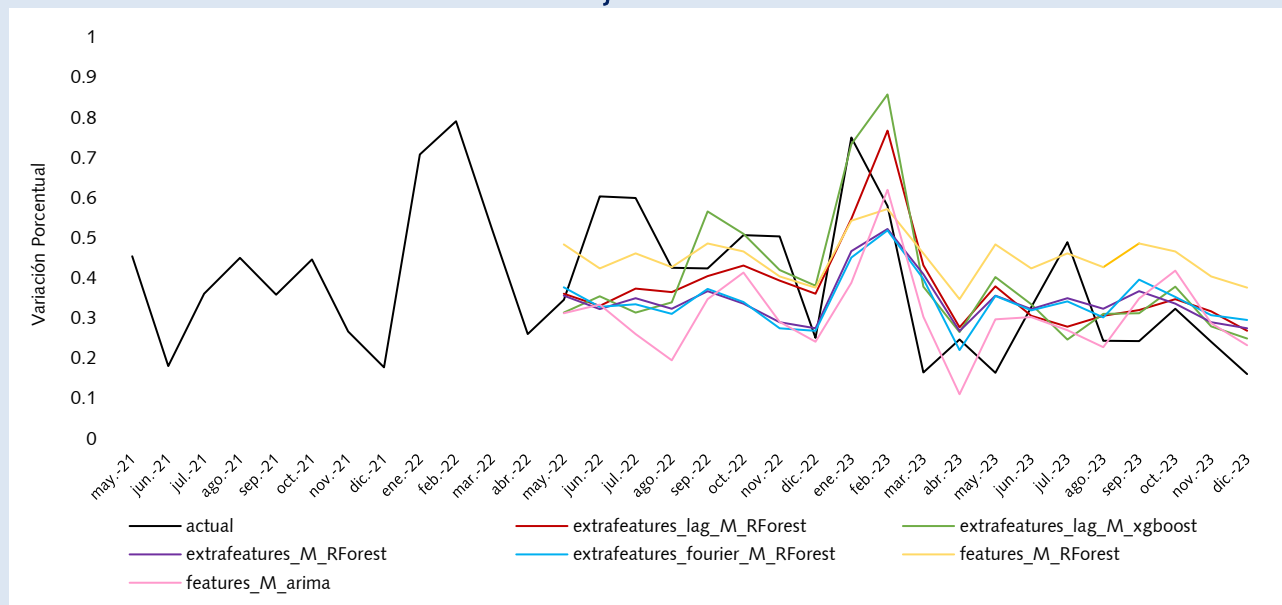
⁴ El RMSE es la raíz cuadrada de las diferencias entre los valores predichos y los observados elevadas al cuadrado. Cuanto menor sea el valor de esta métrica, mejor será el modelo.

⁵ El MAE, a diferencia del RMSE, toma el promedio de la diferencia absoluta entre los valores predichos y los observados.

⁶ El MASE es igual al MAE "original" dividido por el MAE de un modelo "naive" o de referencia. Este modelo naive se basa en la idea de que el comportamiento de una serie temporal tiende a repetirse en intervalos regulares. Por tanto, para predecir el siguiente valor en una serie temporal, toma el último valor observado del mismo periodo estacional.

Grafico II se pueden apreciar los pronósticos para la inflación de los 6 mejores modelos para la muestra de evaluación.

Gráfico II. Pronósticos de inflación con los 6 mejores modelos entrenados



Fuente: Elaboración propia.

5. Discusión y Conclusiones

En este recuadro, se ilustró cómo los procedimientos de ML pueden ser útiles para la predicción de la inflación de la economía paraguaya. Para ello, se estudió la precisión del pronóstico de la inflación con modelos de ML supervisado y también de econometría tradicional. Para evaluar el poder predictivo de cada método, se utilizaron métricas como el RMSE, MAE y MASE, las cuales indicaron que el desempeño de los métodos de ML puede incluso superar a los modelos tradicionales.

De acuerdo con los resultados presentados en la Tabla II, y para este caso en particular, el rendimiento de modelos de ML, como el RF, se encuentra por encima del de los ARIMA. No obstante, es importante mencionar que los resultados al utilizar ML están condicionados a la correcta determinación de la muestra de entrenamiento y de prueba. Determinar cuántos datos se requieren para entrenar los modelos es una tarea crítica pero necesaria para lograr desarrollar modelos precisos y confiables.

Los resultados de este trabajo pueden ampliarse a modelos en los que se consideren, por ejemplo, variables relacionadas a la producción, los agregados monetarios, las tasas de interés, el tipo de cambio, los precios domésticos y de *commodities*, así como las expectativas. Estos resultados también permiten inferir que los modelos de ML podrían empezar a formar parte de la caja de herramientas que utilizan los pronosticadores de variables macroeconómicas.



6. Referencias Bibliográficas

- Bartolomé, K., & Zambrano, R. (24 de April de 2021). "Workflowsets in Time Series". Rafael Zambrano blog. https://rafael-zambrano-blog-ds.netlify.app/posts/workflowsets_timeseries/
- Brownlee, J. (15 de Agosto de 2020). "Time Series Forecasting as Supervised Learning". Machine Learning Mastery <https://machinelearningmastery.com/time-series-forecasting-supervised-learning/>
- Brownlee, J. (01 de Noviembre de 2020). "Random Forest for Time Series Forecasting". Machine Learning Mastery <https://machinelearningmastery.com/random-forest-for-time-series-forecasting/>
- Dhumne, S. (12 de Marzo de 2023). "Elastic Net Regression detailed guide". Medium <https://medium.com/@shruti.dhumne/elastic-net-regression-detailed-guide-99dce30b8e6e>
- Zúñiga, Javier. (2020). Aplicación de algoritmos *Random Forest* y *XGBoost* en una base de solicitudes de tarjetas de crédito. Ingeniería Investigación y Tecnología. 21. 1-16. 10.22201/fi.25940732e.2020.21.3.022.
- Faust, J., & Wright, J. (2013). *Forecasting Inflation. Handbook of Economic Forecasting*.
- Kelleher, J. D., Mac Namee, B., & D'arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies*. MIT press.
- Malkari, N. (19 de Abril de 2023). *Exponential Smoothing: A Method for Time Series Forecasting*. Medium <https://medium.com/@nikhilmalkari18/exponential-smoothing-a-method-for-time-series-forecasting-7ea35ca2c781>
- Morde, V. (07 de Abril de 2019). *XGBoost Algorithm: Long May She Reign*. Medium <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>
- Müller, A., & Guido, S. (2017). *Introduction to Machine Learning with Python*. O'Reilly.
- Pramoditha, R. (7 de Abril de 2022). *Parameters Vs Hyperparameters: What is the difference?* Medium <https://rb.gy/cxmmsw>
- Taylor, S. J., & Letham, B. (2018). *Forecasting at scale*. *The American Statistician*, 72(1), 37–45
- Theobald, O. (2017). *Machine Learning for Absolute Beginners. Second Edition*.
- Vanegas, J., & Vásquez, F. (2017). *Multivariate Adaptive Regression Splines (MARS), una alternativa para el análisis de series de tiempo*. *ScienceDirect*, 235-237.
- NVIDIA AI (31 de Mayo 2023). "XGBoost". *NVIDIA Data Science Glossary*. <https://www.nvidia.com/en-us/glossary/xgboost/>