

Métodos de aprendizaje automático (*machine learning*) para proyectar la INFLACIÓN EN EL PERÚ

JAIRO FLORES* Y RODRIGO GRANDEZ**

Este artículo analiza el uso de métodos de *machine learning* para pronosticar la inflación en Perú, comparándolos con modelos estadísticos tradicionales bajo varias medidas de precisión. Los resultados muestran que estos métodos, como *random forest* y *support vector regressor*, mejoran la precisión de los pronósticos en el corto y mediano plazo, aprovechando su capacidad para manejar grandes volúmenes de datos y capturar relaciones no lineales. Además, observamos que, para algunos horizontes de predicción, la combinación de pronósticos ofrece mejoras en la precisión de los pronósticos.



* Especialista en investigación económica, Departamento de Economía Mundial del BCRP
jairo.flores@bcrp.gob.pe



** Especialista sénior, Departamento de Estadísticas de Precios del BCRP
rodrigo.grandez@bcrp.gob.pe

La trayectoria futura de la tasa de inflación es uno de los factores determinantes en las decisiones de política monetaria de los bancos centrales y resulta fundamental para las decisiones de inversión de los agentes económicos; por ello, la elaboración de pronósticos precisos adquiere gran importancia. En los últimos años, la aplicación de métodos de aprendizaje automático (*machine learning*, ML) para predecir variables macroeconómicas ha aumentado significativamente, ya que estos métodos permiten utilizar más información que los modelos clásicos de series de tiempo. Además, estos métodos han demostrado tener un desempeño predictivo igual o superior al de los métodos tradicionales en varios contextos, en parte gracias a su flexibilidad que permite capturar relaciones no lineales.

En este artículo se resume la investigación realizada por Flores y Grandez (2024), en la cual se analiza la capacidad predictiva de varios métodos de ML utilizando un amplio conjunto de predictores para pronosticar la inflación en Perú. Para ello, se compara la eficacia predictiva de estos modelos con modelos estadísticos tradicionales en un período de prueba de 24 meses, para 12 horizontes de predicción diferentes y bajo distintas métricas de precisión. Los resultados muestran que los métodos de ML mejoran la predicción de la inflación de Perú en comparación con los métodos estadísticos tradicionales. En particular, entre las técnicas de ML, *random forest* y *support vector regressor* resultan preferibles tanto a muy corto plazo como para un horizonte de predicción de un año.

USO DE MÉTODOS DE APRENDIZAJE AUTOMÁTICO PARA PRONOSTICAR LA INFLACIÓN

Varios estudios han explorado las capacidades predictivas de los métodos de ML para proyectar la inflación en economías avanzadas (Medeiros y Mendes, 2016; Chakraborty y Joseph, 2017; Cheng et al., 2021; Medeiros et al., 2016; entre otros). Para las economías emergentes, se han realizado investigaciones en paí-

ses como Rusia (Baybuza, 2018) e India (Pratap y Sengupta, 2019). A nivel global, Medeiros et al. (2022) analizaron la proyección de la inflación de un amplio panel de países, donde resaltó la superioridad del modelo *random forest* y las redes neuronales. Por otro lado, en Latinoamérica, se han realizado investigaciones similares en Brasil (Medeiros et al., 2016; García et al., 2017; Araujo y Gaglianone, 2023), Chile (Leal et al., 2020), México (Heeren et al., 2021) y Colombia (Cárdenas-Cárdenas et al., 2023; Martínez-Rivera et al., 2023). Estos estudios generalmente concluyen que los métodos de ML, como LASSO (*least absolute shrinkage and selection operator*) y *random forest*, presentan un buen desempeño en la proyección de la inflación.


La combinación de pronósticos también ha demostrado ser una herramienta eficaz para mejorar la precisión de las proyecciones (Elliott y Timmermann, 2008). Entre sus ventajas están la compensación de sesgos y la eficiencia derivada de la correlación entre ellos. Este método se ha aplicado en diversas regiones, como la Eurozona (Hubrich y Skudelny, 2017), el Reino Unido (Kapetanios et al., 2008), Estados Unidos (Zhang, 2019), India (Pratap y Sengupta, 2019) y Noruega (Bjørnland et al., 2012). La combinación de pronósticos también se ha utilizado en países de América Latina. Por ejemplo, García et al. (2017) emplearon el *model confidence set* (MCS) para seleccionar los mejores modelos para predecir la inflación en Brasil, y lograron mejores resultados a corto plazo, especialmente cuando utilizaron gran cantidad de información.

MÉTRICAS PARA EVALUAR LAS PROYECCIONES

La precisión de los pronósticos es una medida de la certeza de los valores pronosticados y los resultados observados. Lograr una alta precisión en los pronósticos es esencial para una planificación efectiva y una toma de decisiones eficaz. En el Cuadro 1 se presentan algunos indicadores clave de precisión en los pronósticos.

CUADRO 1 ■ Indicadores clave de precisión en pronósticos		
Medida	Definición	Puntos claves
Error cuadrático medio (ECM)	Promedio de los cuadrados de la diferencia entre el valor proyectado y el valor observado.	Sensible a <i>outliers</i> .
Raíz del error cuadrático medio (RECM)	La raíz cuadrada del ECM.	Útil para comparar las proyecciones de los diferentes modelos ML.
Correlación (CORR)	Correlación entre el cambio de valores proyectados y el cambio de los valores observados.	Útil para medir la relación entre variables.
Precisión positiva (PP)	Número de veces en que los cambios positivos de los valores proyectados coinciden con los cambios positivos de los valores observados.	Útil para evaluar la capacidad predictiva en la detección de tendencias alcistas.
Precisión negativa (PN)	Número de veces en que los cambios negativos de los valores proyectados coinciden con los cambios negativos de los valores observados.	Útil para evaluar la capacidad predictiva en la detección de tendencias bajistas.

GRÁFICO 1 ■ División de la muestra



FUENTE: FLORES Y GRANDEZ (2024).

METODOLOGÍA

La metodología consiste, en primer lugar, en estimar los parámetros de cada método de ML utilizando la muestra de entrenamiento y calibrando los hiperparámetros¹ óptimos en la muestra de validación. Luego, se evalúa el desempeño de pronóstico del modelo en la muestra de prueba (Gráfico 1).

Una estrategia de validación cruzada² para identificar el modelo con mejor desempeño es el método *walk forward cross-validation*. En el Gráfico 2 se presenta una descripción visual de esta técnica. Para una ventana de entrenamiento-validación dada, se crearon 12 divisiones de entrenamiento-prueba en las cuales los datos de la muestra de entrenamiento consisten en observaciones previas a las de la muestra de prueba. Los 12 conjuntos de prueba se seleccionan para corresponder a las 12 observaciones en la muestra de validación. De esta forma, el hiperparámetro óptimo


se define como aquel que logra la mayor precisión en el pronóstico, es decir, el que genera el menor error cuadrático medio calculado a través de los 12 conjuntos de prueba.

En segundo lugar, se evalúa el poder de predicción de los modelos en función de la raíz cuadrada del error cuadrático medio (RECM) en la muestra de prueba. Para ampliar el análisis de desempeño de los modelos, también se evalúan otras métricas descritas en la sección anterior.

Dada una proyección $\hat{\pi}_{t+h|t}^m$ para cada modelo (m), se calcula el RECM para el horizonte h como:

$$RECM_h^m = \sqrt{\left(\frac{1}{24} \sum_{t=T-24-h}^{T-h} (\pi_{t+h} - \hat{\pi}_{t+h|t}^m)^2 \right)}$$

GRÁFICO 2 ■ Walk forward cross-validation



FUENTE: MEDEIROS ET AL. (2022).

- 1 Los hiperparámetros en métodos de ML son parámetros de configuración que se establecen antes de iniciar el proceso de entrenamiento del modelo. A diferencia de los parámetros que el modelo aprende automáticamente a partir de los datos (como los coeficientes en LASSO), los hiperparámetros controlan aspectos clave del proceso de aprendizaje, por lo que su ajuste correcto es crucial para optimizar el desempeño del modelo.
- 2 La validación cruzada es una técnica que consiste en dividir los datos varias veces en diferentes subconjuntos. En cada iteración, una parte de los datos (conjunto de entrenamiento) se utiliza para entrenar el modelo, mientras que la parte restante (conjunto de validación) se emplea para evaluar su rendimiento. Este proceso se repite múltiples veces, cambiando cada vez los datos asignados a entrenamiento y validación, con el fin de obtener una evaluación más confiable y generalizable del modelo.

CUADRO 2 ■ Modelos para predecir la inflación

Modelos Shrinkage

LASSO
Ridge
Elastic Net

Modelos No Lineales

Random Forest (RF)
Support Vector Regressor (SVR)
Decision Tree (DT)

Modelos Ensemble

AdaBoost (AB)
Gradient Boost (GB)
Extreme Gradient Boost (XGB)

Modelos Híbridos

LASSO-RF
LASSO-SVR
LASSO-DT
LASSO-AB
LASSO-GB
LASSO-XGB
RF-DT
RF-AB
RF-GB
RF-XGB

Métodos Clásicos

ARIMA
Regression Random walk (RW)

Modelos Combinación

Promedio Simple
Promedio Pesos-RECM*
Promedio Mejores 3
Promedio Mejores 4
Promedio Mejores 5

* RAÍZ DE ERROR CUADRÁTICO MEDIO.

En tercer lugar, se estima el promedio de los modelos mediante dos enfoques: un promedio ponderado con pesos iguales y otra con pesos variables, definidos de forma inversamente proporcional al RECM obtenido en la muestra de validación.

Finalmente, se repiten los pasos anteriores con una muestra de variables ajustada mediante la selección de variables bajo los métodos LASSO y *random forest*. De esta manera, se construyen 10 modelos híbridos (Cuadro 2), en el que el primer nombre representa el método de selección de variables y el segundo se refiere al enfoque de estimación. Se emplean algunos modelos de ML implementados con éxito en ejercicios

de pronósticos, así como modelos ARIMA en calidad de modelo estadístico clásico y el modelo *random walk* como comparación base.

El horizonte de predicción, denotado como h , varía desde 1 hasta los 12 meses. El período de la muestra cubre 21 años, desde enero 2003 hasta diciembre 2023 ($T = 252$ observaciones). Debido a la persistencia habitual en la serie de inflación, se han considerado 12 rezagos de la variable dependiente, así como variables de expectativas de inflación, producción y variables financieras. Además, se utiliza un amplio conjunto de predictores (82 variables), en su mayoría provenientes de las cuentas nacionales y de las tablas estadísticas

CUADRO 3 ■ Indicador: RECM (Período de prueba: 2022-2023)

Modelos	h=1	h=2	h=3	h=4	h=5	h=6	h=7	h=8	h=9	h=10	h=11	h=12
LASSO	0,371	0,432	0,448	0,464	0,464	0,471	0,568	0,463	0,488	0,500	0,420	0,429
Ridge	0,401	0,586	0,879	0,801	0,987	1,090	0,892	0,897	1,060	0,862	1,101	0,787
ElasticNet	0,363	0,449	0,446	0,474	0,441	0,467	0,462	0,447	0,478	0,478	0,422	0,417
AdaBoost (AB)	0,396	0,407	0,432	0,434	0,464	0,455	0,433	0,473	0,456	0,426	0,419	0,423
Gboost (GB)	0,409	0,413	0,521	0,476	0,507	0,595	0,422	0,541	0,499	0,455	0,421	0,446
Xgboost (XGB)	0,355	0,410	0,436	0,423	0,457	0,441	0,433	0,439	0,431	0,407	0,394	0,410
Random Forest (RF)	0,365	0,402	0,448	0,425	0,444	0,444	0,442	0,475	0,438	0,417	0,401	0,430
Support Vector Regressor (SVR)	0,338	0,405	0,426	0,388	0,456	0,463	0,432	0,426	0,447	0,428	0,450	0,420
Decision Tree (DT)	0,457	0,520	0,623	0,494	0,620	0,525	0,499	0,642	0,493	0,564	0,490	0,490
Promedio Simple	0,352	0,401	0,468	0,408	0,462	0,453	0,398	0,467	0,442	0,438	0,413	0,397
Promedio RECM	0,356	0,411	0,470	0,435	0,464	0,440	0,415	0,474	0,452	0,446	0,411	0,411
Promedio Top3	0,369	0,422	0,493	0,458	0,475	0,453	0,437	0,505	0,456	0,454	0,425	0,422
Promedio Top4	0,356	0,409	0,485	0,458	0,469	0,441	0,430	0,487	0,448	0,441	0,421	0,405
Promedio Top5	0,353	0,408	0,471	0,456	0,467	0,441	0,436	0,475	0,449	0,436	0,432	0,416
LASSO-AB	0,379	0,445	0,456	0,440	0,472	0,456	0,469	0,518	0,477	0,446	0,383	0,450
LASSO-GB	0,379	0,525	0,452	0,447	0,488	0,446	0,429	0,526	0,556	0,443	0,388	0,448
LASSO-XGB	0,363	0,438	0,435	0,459	0,477	0,410	0,456	0,462	0,487	0,389	0,359	0,410
LASSO-RF	0,388	0,534	0,493	0,550	0,578	0,450	0,442	0,592	0,514	0,504	0,415	0,438
LASSO-SVR	0,353	0,436	0,466	0,484	0,576	0,578	0,477	0,448	0,508	0,504	0,445	0,454
LASSO-DT	0,453	0,546	0,546	0,539	0,546	0,503	0,461	0,541	0,539	0,507	0,401	0,505
RF-AB	0,410	0,430	0,509	0,425	0,497	0,488	0,460	0,455	0,439	0,436	0,412	0,435
RF-GB	0,401	0,425	0,621	0,534	0,509	0,544	0,481	0,521	0,542	0,451	0,497	0,483
RF-XGB	0,393	0,405	0,470	0,407	0,466	0,487	0,490	0,435	0,452	0,418	0,461	0,427
RF-SVR	0,414	0,449	0,512	0,404	0,567	0,454	0,437	0,517	0,525	0,480	0,603	0,487
RF-DT	0,465	0,515	0,675	0,559	0,504	0,631	0,564	0,662	0,492	0,526	0,456	0,453
ARIMA	0,388	0,487	0,570	0,454	0,447	0,504	0,544	0,461	0,465	0,506	0,559	0,490
RW	0,543	0,460	0,459	0,452	0,679	0,696	0,448	0,491	0,730	0,577	0,746	0,521

ELABORACIÓN PROPIA.

CUADRO 4 ■ Indicador: precisión positiva
(Período de prueba: 2022-2023)

Modelos	h=1	h=2	h=3	h=4	h=5	h=6	h=7	h=8	h=9	h=10	h=11	h=12
LASSO	50,0	50,0	60,0	50,0	50,0	40,0	50,0	80,0	50,0	50,0	50,0	50,0
Ridge	90,0	40,0	50,0	50,0	40,0	50,0	70,0	70,0	40,0	50,0	40,0	50,0
ElasticNet	60,0	30,0	60,0	50,0	40,0	50,0	50,0	80,0	50,0	40,0	50,0	50,0
AdaBoost (AB)	60,0	70,0	60,0	50,0	50,0	50,0	60,0	50,0	40,0	60,0	70,0	70,0
Gboost (GB)	60,0	60,0	30,0	60,0	60,0	40,0	70,0	40,0	60,0	40,0	60,0	60,0
Xgboost (XGB)	50,0	70,0	50,0	50,0	50,0	60,0	50,0	50,0	50,0	60,0	50,0	20,0
Random Forest (RF)	30,0	60,0	20,0	70,0	50,0	50,0	70,0	60,0	50,0	60,0	60,0	50,0
Support Vector Regressor (SVR)	70,0	30,0	60,0	40,0	60,0	30,0	60,0	70,0	50,0	60,0	60,0	50,0
Decision Tree (DT)	50,0	60,0	50,0	60,0	50,0	60,0	80,0	50,0	60,0	60,0	70,0	60,0
Promedio Simple	50,0	60,0	40,0	60,0	40,0	50,0	70,0	60,0	50,0	50,0	60,0	50,0
Promedio RECM	50,0	50,0	30,0	70,0	50,0	50,0	80,0	60,0	50,0	50,0	50,0	50,0
Promedio Top3	50,0	40,0	40,0	60,0	50,0	50,0	70,0	70,0	60,0	40,0	60,0	60,0
Promedio Top4	50,0	50,0	40,0	70,0	50,0	60,0	90,0	60,0	60,0	50,0	60,0	50,0
Promedio Top5	50,0	50,0	40,0	60,0	50,0	60,0	80,0	60,0	50,0	50,0	50,0	50,0
LASSO-AB	60,0	60,0	50,0	70,0	40,0	60,0	50,0	60,0	40,0	60,0	60,0	50,0
LASSO-GB	40,0	40,0	60,0	60,0	50,0	80,0	70,0	60,0	50,0	50,0	50,0	50,0
LASSO-XGB	40,0	60,0	70,0	30,0	50,0	50,0	50,0	60,0	40,0	50,0	60,0	40,0
LASSO-RF	50,0	20,0	50,0	40,0	40,0	80,0	50,0	80,0	30,0	50,0	70,0	60,0
LASSO-SVR	70,0	40,0	70,0	50,0	60,0	40,0	50,0	70,0	30,0	70,0	50,0	60,0
LASSO-DT	40,0	20,0	50,0	50,0	40,0	70,0	80,0	60,0	40,0	60,0	90,0	70,0
RF-AB	40,0	50,0	40,0	70,0	50,0	50,0	70,0	50,0	60,0	40,0	60,0	50,0
RF-GB	50,0	70,0	30,0	60,0	40,0	60,0	60,0	60,0	50,0	50,0	60,0	50,0
RF-XGB	40,0	60,0	40,0	50,0	60,0	40,0	60,0	70,0	50,0	50,0	50,0	50,0
RF-SVR	40,0	50,0	40,0	60,0	40,0	50,0	60,0	50,0	30,0	50,0	50,0	60,0
RF-DT	60,0	60,0	50,0	70,0	50,0	70,0	80,0	50,0	70,0	50,0	70,0	50,0

ELABORACIÓN PROPIA.

CUADRO 5 ■ Indicador: precisión negativa
(Período de prueba: 2022-2023)

Modelos	h=1	h=2	h=3	h=4	h=5	h=6	h=7	h=8	h=9	h=10	h=11	h=12
LASSO	61,5	23,1	53,8	53,8	53,8	61,5	61,5	61,5	53,8	53,8	69,2	53,8
Ridge	61,5	46,2	46,2	53,8	46,2	61,5	61,5	46,2	61,5	53,8	46,2	38,5
ElasticNet	69,2	46,2	53,8	53,8	61,5	61,5	61,5	69,2	53,8	53,8	61,5	53,8
AdaBoost (AB)	53,8	69,2	61,5	76,9	53,8	38,5	46,2	69,2	53,8	53,8	61,5	61,5
Gboost (GB)	53,8	61,5	61,5	61,5	53,8	53,8	76,9	38,5	69,2	61,5	69,2	61,5
Xgboost (XGB)	61,5	61,5	61,5	61,5	53,8	46,2	53,8	53,8	53,8	69,2	53,8	61,5
Random Forest (RF)	61,5	61,5	53,8	53,8	61,5	61,5	69,2	53,8	61,5	53,8	46,2	61,5
Support Vector Regressor (SVR)	76,9	30,8	61,5	61,5	61,5	38,5	61,5	69,2	38,5	53,8	69,2	76,9
Decision Tree (DT)	61,5	53,8	46,2	53,8	53,8	53,8	69,2	53,8	53,8	69,2	53,8	61,5
Promedio Simple	53,8	61,5	61,5	61,5	61,5	53,8	76,9	53,8	61,5	61,5	61,5	61,5
Promedio RECM	53,8	53,8	61,5	46,2	61,5	53,8	61,5	61,5	69,2	53,8	69,2	61,5
Promedio Top3	61,5	61,5	53,8	46,2	53,8	53,8	53,8	61,5	61,5	61,5	61,5	61,5
Promedio Top4	61,5	61,5	53,8	53,8	53,8	53,8	53,8	61,5	61,5	61,5	69,2	69,2
Promedio Top5	61,5	61,5	53,8	53,8	53,8	53,8	53,8	61,5	61,5	61,5	69,2	61,5
LASSO-AB	46,2	61,5	61,5	61,5	53,8	53,8	61,5	61,5	53,8	38,5	76,9	46,2
LASSO-GB	61,5	53,8	38,5	53,8	46,2	61,5	69,2	53,8	46,2	69,2	61,5	69,2
LASSO-XGB	61,5	38,5	53,8	61,5	46,2	46,2	61,5	46,2	30,8	53,8	53,8	61,5
LASSO-RF	53,8	38,5	46,2	38,5	46,2	53,8	53,8	53,8	38,5	53,8	76,9	69,2
LASSO-SVR	76,9	38,5	53,8	61,5	46,2	53,8	61,5	61,5	53,8	46,2	53,8	61,5
LASSO-DT	61,5	23,1	38,5	46,2	46,2	61,5	61,5	53,8	46,2	46,2	76,9	61,5
RF-AB	38,5	61,5	53,8	69,2	53,8	53,8	69,2	53,8	53,8	61,5	61,5	61,5
RF-GB	61,5	69,2	46,2	53,8	38,5	53,8	76,9	46,2	53,8	46,2	53,8	61,5
RF-XGB	46,2	61,5	61,5	61,5	61,5	61,5	61,5	61,5	69,2	53,8	53,8	69,2
RF-SVR	46,2	38,5	53,8	53,8	38,5	53,8	69,2	61,5	38,5	61,5	46,2	61,5
RF-DT	38,5	69,2	38,5	38,5	53,8	46,2	53,8	53,8	53,8	61,5	61,5	61,5

ELABORACIÓN PROPIA.

del BCRP y el Ministerio de Desarrollo Agrario y Riego (Midagri). También se incorporan variables relacionadas con las condiciones climatológicas recopiladas por el National Weather Service y el Servicio Nacional de Meteorología e Hidrología del Perú (Senamhi), que podrían ayudar a pronosticar la inflación.

Para evaluar el desempeño de los modelos relativo al modelo *random walk* antes y después del COVID-19, se realizaron dos ejercicios de predicción fuera de la muestra: el primero (después del COVID-19) con una

muestra de prueba que abarca desde enero 2022 hasta diciembre 2023, y el segundo (antes del COVID-19) desde enero de 2018 hasta diciembre de 2019³.

RESULTADOS Y CONCLUSIONES

Los resultados para el período pos-COVID-19 muestran que, en el muy corto plazo, los métodos de ML reportan menores errores de predicción en comparación con el modelo de referencia *random walk*. Además, para *h=1*, los métodos de ML muestran ganancias de

3 Los resultados para el caso antes de COVID-19 se presentan en Flores y Grandez (2024).

precisión entre 14 y 35 por ciento respecto al modelo de referencia. Para horizontes entre $h=3$ y $h=4$, el modelo *adaptive boosting* muestra un mejor desempeño respecto a la combinación de pronósticos; sin embargo, para horizontes mayores, la combinación mejora en su capacidad de pronóstico. Destaca el desempeño de los modelos *random forest* y *support vector regressor* debido a su superioridad en la mayoría de los periodos de predicción.

Respecto a la medida de precisión positiva, se observa que el modelo *ridge* registra un 90 por ciento de precisión en el muy corto plazo ($h=1$). Además, los resultados muestran que 9 de los 24 modelos estimados superan el 60 por ciento de precisión. Así, en promedio, las predicciones generadas por los modelos de ML están alineadas con los cambios positivos de la inflación.

Respecto al análisis de cambio negativo de la inflación, se observa que el modelo *support vector regressor* y el modelo híbrido *LASSO-support vector regressor* resultan tener la mayor precisión en el muy corto plazo ($h=1$) y en el horizonte a 1 año ($h=12$). La combinación de pronósticos y el modelo *random forest* muestran un buen desempeño en los horizontes intermedios.

En resumen, los resultados señalan que los modelos de ML muestran un desempeño predictivo superior al de los métodos tradicionales de predicción considerados. Además, se observa una mejora en la precisión al combinar pronósticos. Estos hallazgos resaltan los



Los resultados
muestran que los
**métodos de ML
mejoran la predicción
de la inflación de Perú
en comparación con
los métodos estadísticos
tradicionales**



beneficios de utilizar modelos de ML para predecir la inflación en Perú cuando se dispone de un conjunto amplio y diverso de variables.

REFERENCIAS

- Araujo, G., & Gaglianone, W. (2023). Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models. *Latin American Journal of Central Banking*, 4(2), 100087. 9
- Baybuza, I. (2018). Inflation Forecasting Using Machine Learning Methods. *Russian Journal of Money and Finance*, 77(4), 42–59.
- Bjørnland, H., Gerdrup, K., Jore, A., Smith, C., & Thorsrud, L. (2012). Does forecast combination improve Norges Bank inflation forecasts? *Oxford Bulletin of Economics and Statistics*, 74(2), 163–179.
- Chakraborty, C., & Joseph, A. (2017). *Machine learning at central banks*. Staff Working Paper 674. Bank of England.
- Cheng, K., Huang, N., & Shi, Z. (2021). Survey-based forecasting: To average or not to average. En Sriboonchitta, S., Kreinovich, V., & Yamaka, W. (eds.) *Behavioral Predictive Modeling in Economics* (87–104).
- Cárdenas-Cárdenas, J., Cristiano-Botia, D., & Martínez-Cortés, N. (2023). Colombian inflation forecast using Long Short-Term Memory approach. Borradores de Economía No. 1241. Banco de la República.
- Elliott, G., & Timmermann, A. (2008). Economic forecasting. *Journal of Economic Literature*, 46(1), 3–56.
- Flores, J., & Grandez, R. (2024). Forecasting Peruvian Inflation Rate with Machine Learning Methods. (Unpublished manuscript).
- García, M., Medeiros, M., & Vasconcelos, G. (2017). Real-time inflation forecasting with high-dimensional models: The case of Brazil. *International Journal of Forecasting*, 33(3), 679–693.
- Heeren, S., O'Neill, E., & Naghi, A. (2021). *Forecasting Inflation using Machine Learning for an Emerging Economy*. Erasmus School of Economics.
- Hubrich, K., & Skudelny, F. (2017). Forecast combination for euro area inflation: a cure in times of crisis? *Journal of Forecasting*, 36(5), 515–540.
- Kapetanios, G., Labhard, V., & Price, S. (2008). Forecast combination and the Bank of England's suite of statistical forecasting models. *Economic Modelling*, 25(4), 772–792.
- Leal, F., Molina, C., & Zilberman, E. (2020). *Proyección de la Inflación en Chile con Métodos de Machine Learning*. Documentos de Trabajo 860. Banco Central de Chile.
- Martínez-Rivera, W., González-Molano, E., & Caicedo-García, E. (2023). Forecasting Inflation from Disaggregated Data: The Colombian case. Borradores de Economía No. 1251. Banco de la República.
- Medeiros, M., Schutte, E., & Soussi, T. (2022). Global inflation forecasting: Benefits from machine learning methods. Available at SSRN 4145665.
- Medeiros, M., Vasconcelos, G., & Freitas, E. (2016). Forecasting Brazilian inflation with high-dimensional models. *Brazilian Review of Econometrics*, 36(2), 223–254.
- Medeiros, M., & Mendes, E. (2016). L1-regularization of high-dimensional time-series models with non-Gaussian and heteroskedastic errors. *Journal of Econometrics*, 191(1), 255–271.
- Pratap, B., & Sengupta, S. (2019). *Macroeconomic Forecasting in India: Does Machine Learning Hold the Key to Better Forecasts?* RBI Working Paper Series.
- Zhang, B. (2019). Real-time inflation forecast combination for time-varying coefficient models. *Journal of Forecasting*, 38(3), 175–191.