



Doi: <https://doi.org/10.70577/ASCE/622.642/2025>

Recibido: 2025-05-20

Aceptado: 2025-06-20

Publicado: 2025-07-21

Modelos de Aprendizaje Automático Híbridos para Pronóstico Macroeconómico con Series Temporales de Alta Frecuencia

Hybrid Machine Learning Models for Macroeconomic Forecasting with High-Frequency Time Series

Autor:

Gabriela Cecilia Quirola Quizhpi

gabriela.quirola@esPOCH.edu.ec

<https://orcid.org/0000-0001-9767-5730>

Escuela Superior Politécnica de Chimborazo (ESPOCH)

Riobamba-Ecuador

Cristian Luis Inca Balseca

cristianl.inca@esPOCH.edu.ec

<https://orcid.org/0000-0002-4795-8297>

Escuela Superior Politécnica de Chimborazo (ESPOCH)

Riobamba-Ecuador

Cómo citar

Quirola Quizhpi, G. C., & Inca Balseca, C. L. (2025). Modelos de Aprendizaje Automático Híbridos para Pronóstico Macroeconómico con Series Temporales de Alta Frecuencia . *ASCE*, 4(3), 622–642.



Resumen

Este estudio explora el uso de modelos híbridos de aprendizaje automático y econometría tradicional para mejorar el pronóstico de indicadores macroeconómicos a partir de series temporales de alta frecuencia. Los modelos híbridos, como la combinación de ARIMA con LSTM o SVM, buscan capitalizar las fortalezas de ambos enfoques: la captura de patrones lineales con modelos clásicos y la detección de relaciones no lineales y complejas con algoritmos de machine learning. La literatura reciente respalda que estos enfoques pueden, bajo ciertas condiciones, superar la precisión de los métodos tradicionales al anticipar variables como el PIB, la inflación y el desempleo, especialmente en contextos financieros volátiles. Sin embargo, el éxito de tales modelos depende en gran medida de la calidad y cantidad de los datos disponibles, así como de una configuración óptima de los algoritmos. El trabajo señala también importantes desafíos: riesgos de sobreajuste, demandas computacionales elevadas y la sensibilidad a sesgos y errores en los datos de entrenamiento. Además, se enfatiza la importancia de validaciones rigurosas y el riesgo inherente de transferir mejoras modelísticas a la práctica macroeconómica real, dado el entorno altamente complejo y multifactorial. En suma, aunque el potencial de estos modelos es significativo, su adopción debe ir acompañada de cautela y evaluaciones robustas, considerando tanto sus posibilidades como sus límites.

Palabras clave: Pronóstico Macroeconómico, Aprendizaje Automático, Modelos Híbridos, Series Temporales, ARIMA-LSTM, Alta Frecuencia.



Abstract

This study explores the use of hybrid machine learning models and traditional econometrics to improve the forecasting of macroeconomic indicators from high-frequency time series. Hybrid models, such as the combination of ARIMA with LSTM or SVM, seek to capitalize on the strengths of both approaches: capturing linear patterns with classical models and detecting nonlinear and complex relationships with machine learning algorithms. Recent literature supports that these approaches can, under certain conditions, outperform the accuracy of traditional methods in anticipating variables such as GDP, inflation, and unemployment, especially in volatile financial contexts. However, the success of such models depends largely on the quality and quantity of available data, as well as optimal algorithm configuration. The paper also highlights significant challenges: risks of overfitting, high computational demands, and sensitivity to biases and errors in the training data. Furthermore, it emphasizes the importance of rigorous validations and the inherent risk of transferring model improvements to real-world macroeconomic practice, given the highly complex and multifactorial environment. In short, although the potential of these models is significant, their adoption must be accompanied by caution and robust evaluations, considering both their possibilities and their limitations.

Keywords: macroeconomic forecasting, machine learning, hybrid models, time series, ARIMA-LSTM, high frequency.

Introducción

Modelos Híbridos de Aprendizaje Automático para la Predicción Macroeconómica con Series Temporales de Alta Frecuencia se refiere a la integración innovadora de métodos econométricos tradicionales con técnicas modernas de aprendizaje automático (ML) destinadas a mejorar la precisión de las predicciones macroeconómicas. A medida que los entornos económicos se vuelven cada vez más dinámicos, la necesidad de modelos de pronóstico precisos es primordial, especialmente a la luz de las complejidades introducidas por los datos de series temporales de alta frecuencia, que ofrecen información detallada pero también presentan desafíos analíticos significativos. La importancia de los modelos híbridos radica en su capacidad para aprovechar las fortalezas tanto de los métodos estadísticos tradicionales como de los algoritmos avanzados, facilitando pronósticos más robustos de indicadores económicos clave como el PIB, la inflación y las tasas de empleo (Lee, 2025) (Yang et al, 2024).

La incorporación del aprendizaje automático en la previsión macroeconómica marca una evolución crucial en el campo, ya que estos algoritmos destacan en el procesamiento de grandes conjuntos de datos e identifican relaciones no lineales que los modelos tradicionales pueden pasar por alto. Los estudios han demostrado que los modelos híbridos, como aquellos que combinan Promedio Móvil Integrado Autorregresivo (ARIMA) con Máquinas de Vectores de Soporte (SVM) o redes de Memoria a Largo y Corto Plazo (LSTM), superan consistentemente a los métodos independientes en términos de precisión predictiva y capacidad de respuesta del mercado (Lee, 2025) (Stempien, 2025).

Esta capacidad es particularmente valiosa en un panorama económico en rápida evolución, donde las predicciones oportunas y precisas pueden influir significativamente en las decisiones de política e inversión (Yang et al, 2024) (Desai, 2023).

A pesar de sus ventajas, los modelos híbridos de aprendizaje automático no están exentos de controversias y desafíos. Problemas como el sobreajuste del modelo, la necesidad de datos de entrenamiento extensos y de alta calidad, y las demandas de recursos computacionales pueden complicar su implementación y efectividad (Carriero et al, 2025) (Kristianpoller, 2024).



Además, las preocupaciones éticas relacionadas con el sesgo en las predicciones de aprendizaje automático requieren una consideración cuidadosa en la aplicación de estos modelos, particularmente en contextos donde las decisiones económicas tienen profundos impactos sociales (Carriero et al, 2025).

A medida que la investigación continúa explorando y refinando estas metodologías híbridas, están destinadas a desempeñar un papel cada vez más crítico en la configuración de las prácticas de previsión económica y en la información de los marcos de políticas en una era marcada por la abundancia y complejidad de datos (Lee, 2025) (Rafor et al, 2025) (Yang et al, 2024).

La previsión macroeconómica ha evolucionado significativamente a lo largo de los años, integrando diversas metodologías para mejorar la precisión de las predicciones. Tradicionalmente, los economistas se basaban en modelos econométricos, que incorporan teorías económicas y técnicas estadísticas para predecir tendencias futuras. Los modelos econométricos comunes incluyen modelos de Autorregresión Vectorial (VAR) y modelos de Datos de Frecuencia Mixta (MIDAS), que aprovechan relaciones dinámicas complejas y datos de alta frecuencia para mejorar la precisión de las previsiones de indicadores macroeconómicos como el PIB, la inflación y las tasas de desempleo (Yang et al, 2024).

En los últimos años, la aplicación de técnicas de aprendizaje automático (ML) ha surgido como un complemento poderoso a los métodos tradicionales. En los últimos años, la aplicación de técnicas de aprendizaje automático (ML) ha surgido como un poderoso complemento a los métodos tradicionales. Los algoritmos de aprendizaje automático sobresalen en el manejo de grandes conjuntos de datos e identifican patrones intrincados dentro de los datos, lo cual puede ser particularmente beneficioso para pronosticar series temporales de alta frecuencia (Desai, 2023) (Lee, 2025).

La importancia del aprendizaje automático en este contexto se destaca por la creciente frecuencia de términos como "máquina" y "aprendizaje" en las discusiones académicas y la literatura relacionada con la previsión macroeconómica.

Estos algoritmos no solo tienen como objetivo predecir resultados futuros basándose en datos históricos, sino que también se adaptan y aprenden de nueva información, lo que los hace valiosos para entornos económicos dinámicos. La interacción entre el aprendizaje automático y los modelos econométricos es fundamental, ya que ambos dominios se centran en comprender las estructuras de datos secuenciales. Aunque los objetivos fundamentales pueden diferir—predecir la siguiente palabra en modelos de lenguaje versus pronosticar valores futuros en series temporales—estas tareas están inherentemente entrelazadas, lo que permite a los investigadores construir modelos híbridos que capitalizan las fortalezas de ambos enfoques (Yang et al, 2024) (Zhang et al, 2025).

Esta hibridación permite pronósticos más robustos, particularmente en un panorama caracterizado por cambios económicos rápidos y disponibilidad de datos. A medida que el campo continúa avanzando, la integración del aprendizaje automático en la previsión macroeconómica promete mejorar las herramientas analíticas disponibles para economistas, formuladores de políticas y analistas financieros. La evolución de estas técnicas de pronóstico subraya el papel crítico que desempeñan en la configuración de la política económica y los procesos de toma de decisiones (Desai, 2023) (Slater et al, 2023).

Material y métodos

Modelos Híbridos

Los modelos híbridos en la previsión macroeconómica aprovechan las fortalezas tanto de los métodos econométricos tradicionales como de las técnicas avanzadas de aprendizaje automático. Estos modelos combinan múltiples métodos de pronóstico independientes, con el objetivo de mejorar la precisión al integrar sus predicciones. Esta sección discute varias metodologías de hibridación, el rendimiento de modelos híbridos específicos y sus implicaciones para la previsión financiera.

Metodología de Hibridación

La integración de diferentes técnicas de pronóstico permite a los investigadores capturar tanto patrones lineales como no lineales dentro de los datos de series temporales financieras. Un ejemplo destacado es el modelo de Promedio Móvil Integrado Autorregresivo (ARIMA), que sirve como

un enfoque econométrico fundamental. El modelo ARIMA se basa en la suposición de que las observaciones actuales están influenciadas por valores y errores pasados, confiando así en la autocorrelación de los datos (Desai, 2023) (Stempien et al, 2025).

Para implementar ARIMA de manera efectiva, la serie temporal debe ser estacionaria, una condición asegurada mediante operaciones de diferenciación que estabilizan la media, la varianza y la covarianza a lo largo del tiempo (Lee, 2025).

Basándose en ARIMA, los enfoques híbridos a menudo incorporan métodos de aprendizaje automático, como Máquinas de Vectores de Soporte (SVM) y redes de Memoria a Largo y Corto Plazo (LSTM). Estos modelos pueden identificar relaciones complejas dentro de los datos que los modelos econométricos tradicionales pueden pasar por alto. Por ejemplo, combinaciones como SVM-ARIMA y LSTM-ARIMA han mostrado una mayor precisión predictiva en comparación con sus componentes independientes en varios escenarios de pronóstico (Lee, 2025).

Rendimiento de los Modelos Híbridos

El rendimiento de los modelos híbridos puede variar significativamente dependiendo de la combinación de métodos utilizados. En estudios que analizan el índice S&P 500 y los datos de Bitcoin, varios modelos híbridos demostraron capacidades de pronóstico superiores. Notablemente, los modelos SVM-ARIMA y LSTM-ARIMA superaron a sus componentes individuales en términos de precisión predictiva (Lee, 2025).

Sin embargo, es esencial señalar que no todos los enfoques híbridos producen mejores resultados; por ejemplo, se ha encontrado que los modelos híbridos basados en XGBoost tienen un rendimiento inferior en comparación con sus contrapartes más simples (Lee, 2025) (Stempien et al, 2025).

Los resultados de las pruebas retrospectivas indican que los modelos híbridos pueden proporcionar señales de trading valiosas, con métricas como el Índice de Información (IR) y el Índice de Sharpe (SR) reflejando su efectividad. El híbrido LSTM-ARIMA, por ejemplo, logró un IR de 0.50 y un SR de 1.06 durante los procedimientos de backtesting (Lee, 2025).

Esto ilustra cómo los modelos híbridos bien estructurados pueden mejorar las estrategias de trading y facilitar una toma de decisiones más informada en los mercados financieros. Esto ilustra cómo los modelos híbridos bien estructurados pueden mejorar las estrategias de trading y facilitar una toma de decisiones más informada en los mercados financieros.

Datos de Series Temporales de Alta Frecuencia

Los datos de series temporales de alta frecuencia, caracterizados por su granularidad y frecuencia, presentan desafíos y oportunidades únicos en el ámbito de la previsión macroeconómica. Estos conjuntos de datos suelen consistir en miles de características que están altamente correlacionadas, lo que a menudo conduce a problemas como datos faltantes y no estacionariedad (Haponik, 2024).

La naturaleza intrincada de estos conjuntos de datos requiere metodologías sofisticadas para capturar eficazmente los patrones subyacentes.

Desafíos en el Análisis de Series Temporales de Alta Frecuencia

Uno de los principales desafíos asociados con los datos de series temporales de alta frecuencia es la baja relación señal-ruido, lo que complica la tarea de pronóstico (Lee, 2025).

Las series temporales financieras, en particular, son a menudo caóticas y pueden exhibir tanto estructuras de dependencia lineales como no lineales que pueden cambiar con el tiempo. En consecuencia, los modelos econométricos tradicionales, como ARIMA o ARFIMA, pueden ser insuficientes para modelar con precisión las complejidades inherentes a dichos datos (Lee, 2025).

Además, la presencia de datos asincrónicos y la estacionalidad intradía complican aún más el análisis[1].

Técnicas de Aumento de Datos

Para abordar la escasez y variabilidad de los conjuntos de datos de series temporales de alta frecuencia, se emplean técnicas de aumento de datos. Estas técnicas pueden generar datos de entrenamiento más diversos creando combinaciones convexas de secuencias existentes,



incorporando patrones estacionales y utilizando tendencias y funciones escalonadas (Zhang et al, 2025).

Tales estrategias de aumento son vitales para entrenar modelos híbridos de aprendizaje automático que requieren conjuntos de datos extensos y variados para una predicción efectiva.

El papel de los modelos híbridos

Los modelos híbridos, que combinan diversas técnicas de pronóstico, han surgido como una respuesta a los desafíos planteados por los datos de alta frecuencia (Lee, 2025).

Al integrar diversos modelos individuales, las metodologías híbridas pueden capturar las complejidades de las series temporales financieras con mayor precisión que los enfoques de un solo modelo. Este enfoque se basa en la suposición de que diferentes modelos pueden complementar las fortalezas de los demás, lo que lleva a un mejor rendimiento predictivo y a estrategias de inversión más robustas (Lee, 2025).

A medida que el análisis de datos de series temporales de alta frecuencia continúa evolucionando, estos modelos híbridos están posicionados para desempeñar un papel crítico en la mejora de la precisión y la fiabilidad de las previsiones macroeconómicas.

Modelos Estadísticos

Los modelos empleados en este análisis representan lo más avanzado en técnicas de pronóstico para series temporales macroeconómicas. A continuación, se presenta una descripción profesional y accesible de cada uno, destacando sus características y fortalezas.

Modelos Estadísticos y de Aprendizaje Automático

ARIMA (AutoRegressive Integrated Moving Average)

El modelo ARIMA es una herramienta clásica para el análisis de series temporales univariantes. Se distingue por su capacidad para identificar y modelar patrones temporales recurrentes y la estacionalidad inherente a datos económicos o financieros. Su principal fortaleza radica en la

precisión que ofrece al pronosticar la evolución futura de una sola variable, basándose únicamente en la información pasada de esa serie.

VAR (Vector Autoregression)

El modelo VAR extiende el enfoque anterior para trabajar con múltiples series temporales de manera simultánea. Este esquema multivariante permite analizar no solo la evolución propia de cada variable, sino también las interrelaciones dinámicas entre diferentes indicadores. Por ello, el VAR resulta especialmente valioso al estudiar sistemas macroeconómicos interconectados, donde los cambios en una variable influyen directamente sobre las demás.

XGBoost (Extreme Gradient Boosting)

XGBoost es un modelo de machine learning ampliamente reconocido por su eficiencia y capacidad para procesar grandes volúmenes de datos. Basado en un enjambre de árboles de decisión, XGBoost sobresale en la detección de relaciones no lineales complejas entre variables. Su diseño le permite considerar de manera simultánea todas las variables predictoras, lo cual resulta en pronósticos robustos incluso en contextos de alta dimensionalidad.

LSTM (Long Short-Term Memory)

Las redes neuronales LSTM están concebidas específicamente para abordar problemas de series temporales que requieren entender dependencias a largo plazo dentro de los datos. Estas redes aprovechan secuencias de valores previos, aprendiendo patrones y tendencias que otros modelos podrían pasar por alto, lo que las convierte en una opción destacada para procesos donde la memoria histórica resulta esencial para una predicción fiable.

Modelo Híbrido ARIMA-LSTM

El enfoque híbrido ARIMA-LSTM combina lo mejor de ambos mundos: la capacidad de ARIMA para capturar los comportamientos lineales en una serie, y la potencia de LSTM para identificar patrones no lineales y dependencias complejas. Este modelo es especialmente útil cuando la dinámica temporal incluye tanto componentes sistemáticos tradicionales como relaciones más sofisticadas y difíciles de modelar. Como resultado, suele conseguir mejoras sustanciales en la precisión de los pronósticos.

Procedimientos y Evaluaciones Aplicadas

Todos los modelos se someten a un riguroso proceso de validación, que incluye:

Pruebas de estacionariedad: Utilizando metodologías como ADF y KPSS, garantizando que los supuestos estadísticos se cumplen en las series analizadas.

Normalización de datos: Para asegurar la correcta comparabilidad y mejorar el desempeño de los algoritmos de aprendizaje automático.

Análisis de residuos: Permitiendo identificar posibles patrones no capturados por los modelos y mejorar la robustez de las predicciones.

Evaluación por métricas estándar: Como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el coeficiente de determinación (R^2), proporcionando una comparación objetiva y transparente de los distintos enfoques.

Visualizaciones: Generación de gráficos intuitivos para ilustrar los resultados y facilitar la interpretación tanto para expertos como para audiencias técnicas y no técnicas.

Esta integración de modelos avanzados y procedimientos estadísticos rigurosos asegura la solidez y credibilidad de los pronósticos entregados.

Datos utilizados

La generación de datos para este estudio se realiza de manera sintética utilizando la clase DataSimulator, garantizando así un entorno controlado y reproducible. Estos datos se organizan en dos grandes categorías según su naturaleza y frecuencia de actualización.

Por un lado, se incluyen las variables macroeconómicas de baja frecuencia, donde destacan:

- Crecimiento del PIB (gdp_growth), modelado con frecuencia trimestral,
- Índice de Precios al Consumidor (cpi_inflation), de medición mensual,

- Tasa de desempleo (unemployment_rate), también reportada mensualmente.

En el otro extremo, se genera un conjunto amplio de variables financieras y de alta frecuencia, entre las que se encuentran:

- El índice S&P 500 (sp500), con datos diarios,
- El índice de volatilidad (vix),
- El rendimiento de los bonos del Tesoro a 10 años (bond10y_yield),
- El tipo de cambio Euro/Dólar (eurusd),
- El precio del petróleo WTI (oil),
- El consumo de electricidad (electric),
- El índice Baltic Dry (baltic),
- Las solicitudes de desempleo (claims),
- El volumen de transacciones con tarjeta de crédito (cc_tx),
- Y el índice de Incertidumbre Político-Económica (epu).

Estos datos cubren el periodo comprendido desde el 1 de enero de 2020 y abarcan aproximadamente cuatro años de observaciones, totalizando 1,500 registros. La frecuencia de muestreo varía según la variable: diaria para las financieras y semanal, mensual o trimestral para las macroeconómicas.


El diseño estadístico busca reflejar la complejidad y dinamismo del entorno económico real. Para ello, se emplean modelos AR(1) en aquellas variables sujetas a tendencias, distribuciones normales en crecimiento y consumo, lognormales para índices y precios, y Poisson para capturar la dinámica de las solicitudes de desempleo. Además, se incorporan efectos estacionales, correlaciones plausibles entre distintos indicadores, así como componentes de ruido y variabilidad, con el fin de mantener el realismo estadístico de los datos simulados.

Resultados

El análisis detallado de los resultados pone de manifiesto los retos inherentes al pronóstico de series temporales macroeconómicas. Al evaluar el desempeño de los distintos modelos implementados,

se observa que todos presentan un rendimiento limitado, lo cual es coherente con la complejidad y los múltiples factores que inciden en la dinámica de estas series.

Figura 1. Matriz de correlación




Fuente: Autores

En términos de capacidad explicativa, medida a través del coeficiente de determinación (R^2), el mejor resultado lo proporciona el modelo XGBoost, aunque su valor es apenas positivo (0,016), lo que indica una capacidad predictiva marginal.

Por su parte, los modelos ARIMA y LSTM ofrecen desempeños similares y negativos, reflejo de las limitaciones de los enfoques puramente univariantes o basados solo en patrones secuenciales en este contexto.

Figura 2. ARIMA y LSTM




Fuente: Autores

Cabe destacar que el modelo híbrido ARIMA-LSTM, lejos de mejorar los resultados, obtiene el peor desempeño de todos. Esto sugiere que, en este escenario específico, la combinación de patrones lineales y no lineales no alcanza a captar la complejidad de las relaciones subyacentes.

La exploración de las relaciones entre variables, a través de la matriz de correlación, muestra asociaciones moderadas entre los principales indicadores macroeconómicos como el crecimiento del PIB, la inflación y la tasa de desempleo, algo habitual en economías avanzadas.

Entre las variables financieras de alta frecuencia se identifican patrones de correlación más complejos, donde instrumentos como el índice S&P 500 muestran vínculos significativos con otros indicadores financieros, tales como el VIX y el rendimiento de los bonos del Tesoro, revelando la alta interconectividad de los mercados.


Figura 3. Modelos actuales vs predictivo



Fuente: Autores

En cuanto a las predicciones, los gráficos generados permiten observar que los modelos analizados tienden a subestimar los movimientos bruscos en el crecimiento del PIB y, en general, ofrecen estimaciones conservadoras, a menudo alineadas con la tendencia de fondo más que con las variaciones abruptas. El modelo ARIMA-LSTM, en particular, refleja una mayor volatilidad en sus pronósticos, lo que sugiere dificultades para estabilizar la combinación de ambos enfoques.

Figura 4. Modelo ARIMA-LSTM



Fuente: Autores

En conjunto, estos resultados confirman la dificultad de anticipar la evolución de indicadores macroeconómicos con precisión mediante modelos estándar y avanzados por igual. Esto se debe, en buena medida, a la influencia de factores exógenos no capturados en los datos disponibles y a la complejidad estructural de los sistemas macroeconómicos, lo que limita la capacidad predictiva de los modelos y pone de relieve la necesidad de enfoques cada vez más sofisticados y flexibles para este tipo de aplicaciones.

Discusión

Estos hallazgos sintonizan parcialmente con la literatura reciente sobre modelos híbridos y aprendizaje automático en macroeconomía y finanzas.

Diversos estudios han reportado mejoras moderadas al combinar modelos clásicos y machine learning, especialmente en contextos financieros o en la predicción de volatilidad (Dong & Zhou,



2024) (Kristianpoller, 2024), donde la dinámica es menos estructurada y más sensible a patrones estadísticos.

Sin embargo, trabajos han destacado la dificultad de trasladar estos avances al ámbito macroeconómico, en parte por la naturaleza no estacionaria y multifactorial de estas series (Atif, 2025) (Kabir et al, 2025).

En contraste, algunos autores muestran que los enfoques híbridos pueden superar claramente a los modelos tradicionales, pero generalmente bajo condiciones de simulación o con series financieras de alta frecuencia más predecibles (Behera et al, 2024) (Garai et al, 2024).

Los resultados aquí obtenidos parecen confirmar los reparos de quienes advierten sobre la sobrestimación de la aplicabilidad de modelos de machine learning para el nowcasting macroeconómico (Desai, 2023) (Yang et al, 2024), y coinciden con otro autor en que la integración de datos de alta frecuencia no garantiza mejoras automáticas de desempeño (Ozdemir et al, 2024).

Este trabajo contribuye a la literatura al ofrecer evidencia empírica actualizada sobre los alcances y límites de modelos híbridos, llenando un vacío identificado con respecto a la necesidad de evaluaciones realistas sobre predicciones macroeconómicas complejas (Stempien et al, 2025).

Conclusiones

En síntesis, este estudio muestra que, aunque los modelos híbridos de aprendizaje automático representan un avance metodológico prometedor, su capacidad para anticipar con precisión indicadores macroeconómicos clave sigue siendo limitada dada la complejidad inherente del fenómeno económico. Estos hallazgos aportan evidencia relevante para académicos y profesionales, invitando a seguir innovando en el diseño de modelos más integradores y realistas, a la vez que destacan la importancia de una interpretación cautelosa y contextualizada de los avances tecnológicos en la predicción macroeconómica.

Implicaciones del Estudio

Implicaciones Teóricas

Este estudio reafirma que los sistemas macroeconómicos poseen una complejidad estructural y una dependencia de shocks no observables que desafían los límites de la modelización estadística tradicional y avanzada. Los hallazgos sugieren que, si bien los modelos híbridos permiten cierta flexibilidad y adaptación, su potencial disruptivo es aún incipiente en el nowcasting macroeconómico. Esto invita a revisitar y complementar los marcos teóricos convencionales introduciendo enfoques interdisciplinarios, integración de variables textuales o fuentes alternativas de datos, y modelos de naturaleza generativa o basada en agentes.

Implicaciones Prácticas

Para decisores públicos, analistas e instituciones financieras, los resultados sugieren prudencia en la adopción de modelos automáticos como herramienta de pronóstico macroeconómico. Si bien incorporar indicadores de alta frecuencia y metodologías avanzadas puede contribuir a enriquecer la interpretación y el monitoreo de tendencias, las expectativas sobre la capacidad predictiva a corto plazo deben ser moderadas. La utilidad de estos modelos reside más en su capacidad de detección temprana de cambios de tendencia o identificación de anomalías, que en la precisión absoluta del pronóstico puntual.

Limitaciones del Estudio

Primero, la calidad del resultado depende de la representación realista de las dinámicas de los datos sintéticos y de la selección de variables incluidas.

Segundo, las arquitecturas y parámetros empleados para los modelos pueden no haber alcanzado su configuración óptima, dado el alto costo computacional y la complejidad del proceso de ajuste.

Tercero, la ausencia de factores exógenos imprevistos, eventos extremos o cambios estructurales limita la generalización de los hallazgos a contextos reales. Adicionalmente, el tamaño muestral y el horizonte observado pueden influir en la robustez y validez externa de los resultados obtenidos.



Referencias bibliográficas

- Atif, D. (2025). Enhancing long-term gdp forecasting with advanced hybrid models: A comparative study of arima-lstm and arima-tcn with dense regression. *Computational Economics*, 65(6), 3447–3473. <https://doi.org/10.1007/s10614-024-10683-5>
- Behera, S., Ramana, A. V., Venkata Pratima, P., Sinha, K., Rao, P. S., & Ayaz Uddin, M. (2024). Evolutionary hybrid neural networks for time series forecasting. 2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI), 1–6. <https://doi.org/10.1109/IATMSI60426.2024.10502740>
- Carriero, A., Pettenuzzo, D., & Shekhar, S. (2025). Macroeconomic forecasting with large language models (No. arXiv:2407.00890). arXiv. <https://doi.org/10.48550/arXiv.2407.00890>
- Coulombe, P. G., Goebel, M., & Klieber, K. (2024). Dual interpretation of machine learning forecasts. arXiv. <https://doi.org/10.48550/ARXIV.2412.13076>
- Desai, A. (2023). Machine learning for economics research: When, what and how. <https://doi.org/10.34989/SAN-2023-16>
- Dong, Z., & Zhou, Y. (2024). A novel hybrid model for financial forecasting based on ceemdan-se and arima-cnn-lstm. *Mathematics*, 12(16), 2434. <https://doi.org/10.3390/math12162434>
- Garai, S., Paul, R. K., Yeasin, M., & Paul, A. K. (2024). Ceemdan-based hybrid machine learning models for time series forecasting using mars algorithm and pso-optimization. *Neural Processing Letters*, 56(2), 92. <https://doi.org/10.1007/s11063-024-11552-w>
- Haponik, A. (2024, October 6). Machine learning and deep learning in economics. Addepto. <https://addepto.com/blog/machine-learning-in-economics-how-is-it-used/>
- Kabir, M. R., Bhadra, D., Ridoy, M., & Milanova, M. (2025). Lstm–transformer-based robust hybrid deep learning model for financial time series forecasting. *Sci*, 7(1), 7. <https://doi.org/10.3390/sci7010007>
- Kristjanpoller, W. (2024). A hybrid econometrics and machine learning based modeling of realized volatility of natural gas. *Financial Innovation*, 10(1), 45. <https://doi.org/10.1186/s40854-023-00577-0>
- Lee, S. (2025). A close look at top forecasting in macroeconomics. Retrieved July 19, 2025, from <https://www.numberanalytics.com/blog/forecasting-top-macroeconomics-guide>



Mou, S., Xue, Q., Zhang, W., Kinkyō, T., Hamori, S., Chen, J., Takiguchi, T., & Ariki, Y. (2024). Integrating textual and financial time series data for enhanced forecasting*. 2024 16th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI), 541–544. <https://doi.org/10.1109/IIAI-AAI63651.2024.00103>

Ozdemir, O., & Yozgatligil, C. (2024). Forecasting performance of machine learning, time series, and hybrid methods for low- and high-frequency time series. *Statistica Neerlandica*, 78(2), 441–474. <https://doi.org/10.1111/stan.12326>

Rafor, B., Gauran, I. I., Ombao, H., Lansangan, J. R., & Barrios, E. (2025). Analysis of experiments with high frequency time series responses and the implications for power and sample size. *Scientific Reports*, 15(1), 16752. <https://doi.org/10.1038/s41598-025-00554-w>

Slater, L. J., Arnal, L., Boucher, M.-A., Chang, A. Y.-Y., Moulds, S., Murphy, C., Nearing, G., Shalev, G., Shen, C., Speight, L., Villarini, G., Wilby, R. L., Wood, A., & Zappa, M. (2023). Hybrid forecasting: Blending climate predictions with AI models. *Hydrology and Earth System Sciences*, 27(9), 1865–1889. <https://doi.org/10.5194/hess-27-1865-2023>

Song, Y., Cai, C., Ma, D., & Li, C. (2024). Modelling and forecasting high-frequency data with jumps based on a hybrid nonparametric regression and LSTM model. *Expert Systems with Applications*, 237, 121527. <https://doi.org/10.1016/j.eswa.2023.121527>

Stempień, D., & Ślepaczuk, R. (2025). Hybrid models for financial forecasting: Combining econometric, machine learning, and deep learning models (No. arXiv:2505.19617). arXiv. <https://doi.org/10.48550/arXiv.2505.19617>

Wang, J. (2024). A hybrid MODWT-PSO-SVM model for time series forecasting. In H. Wu & H. Li (Eds.), *International Conference on Computer Graphics, Artificial Intelligence, and Data Processing (ICCAID 2023)* (p. 131). SPIE. <https://doi.org/10.1117/12.3026620>

Yang, Y., Xu, X., Ge, J., & Xu, Y. (2024). Machine learning for economic forecasting: An application to china's gdp growth (No. arXiv:2407.03595). arXiv. <https://doi.org/10.48550/arXiv.2407.03595>

Zhang, L., & Hua, L. (2025). Major issues in high-frequency financial data analysis: A survey of solutions. *Mathematics*, 13(3), 347. <https://doi.org/10.3390/math13030347>



Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.