

INTRODUCCIÓN

El auge de la inteligencia artificial aumentó el interés por invertir en las empresas de IA generativa. Esto presenta un dilema para los inversionistas: ¿conviene usar modelos de *machine learning* frente a modelos de análisis técnico tradicional para la predicción de retornos diarios?

Lin y Lobo Marques (2024) concluyen que no hay consenso sobre qué modelos ofrecen mayor precisión. Esta idea es respaldada por Bustos et al. (2025) quienes concluyen que los resultados de los modelos varían dependiendo del periodo y mercado. Esta investigación busca comparar empíricamente modelos de regresión puntuales y por cuantiles frente a métodos tradicionales y buscar interpretar las predicciones de los mismos.


METODOLOGÍA

- Se analizan los siguientes métodos y modelos:
- Métodos Tradicionales (5): **Buy & Hold**, **SMA Crossover**, **RSI**, **MACD**, **Mean Reversion**.
 - Modelos de Machine learning puntuales y por cuantiles (8): **Regresión Lineal**, **Random Forest**, **XGBoost**, **LSTM**.

Se extraen datos de *Yahoo Finance* de los años 2011 al 2025 de las acciones NVDA, MSFT y GOOGL y se hace una selección de variables por VIF. Se entrenan los modelos del 2011 al 2016 y se hace un **backtesting** del 2017 al 2025 con un capital inicial de \$10,000 y un **costo de transacción** de 0.1%. Se aplica una **walk-forward validation** con ventana expandible, que reentrena los modelos cada año. Cada predicción se traduce en una decisión con un **umbral** $\theta = 0.002$:

- Retorno predicho $> +\theta \rightarrow$ se compra
- Retorno predicho $< -\theta \rightarrow$ se liquida
- En otro caso $\rightarrow$ se mantiene la posición

En los modelos por cuantiles la decisión se toma con la **mediana**; el intervalo Q10–Q90 solo mide la incertidumbre. Finalmente, se busca interpretar los modelos con un **análisis SHAP** para saber qué variables tienen mayor peso en las predicciones para cada modelo.



RESULTADOS

La métrica principal usada fue el **Sharpe Ratio**, que mide la rentabilidad en relación al riesgo.

Método / Modelo	NVDA	MSFT	GOOGL
Buy & Hold	1.209	1.021	0.921
Mejor método tradicional	0.976	0.704	0.873
Mejor modelo puntual	1.148	0.904	0.909
Mejor modelo por cuantiles	1.194	1.102	1.005

El mejor modelo por cuantiles es la Regresión lineal por cuantiles para NVDA y MSFT y el XGBoost por cuantiles para GOOGL. Los modelos por cuantiles cuentan con mejor Sharpe promedio y superan al Buy & Hold en MSFT y GOOGL. La ventaja del *machine learning* no está en acertar la dirección, sino en **elegir cuándo entrar y salir del mercado**.


Con el **Hit Ratio**, se observa que los modelos predicen correctamente la dirección del mercado entre el 49 y 53%. Esto coincide con la investigación de Bustos et al. (2025) donde obtienen un 51% de precisión en sus modelos de clasificación de retornos. El valor del uso de los modelos de *machine learning* está en **gestionar la exposición al riesgo**, no en adivinar el retorno.

El Sharpe promedio de los modelos cambia dependiendo si es una fase alcista o bajista del mercado.

Método / Modelo	Fase Alcista	Fase Bajista
Buy & Hold	1.15	0.85
Modelos puntuales	0.9	0.72
Modelos por cuantiles	0.89	0.86

En un mercado alcista, conviene la simplicidad del *Buy & Hold* y en el mercado bajista, los modelos por cuantiles **protegen mejor contra las caídas y disminuyen pérdidas**.

En el análisis SHAP se observa que ninguna variable domina en todos los modelos y acciones, la **importancia cambia** según la acción, el modelo y el periodo.



CONCLUSIONES

- Los modelos por cuantiles ofrecen una **mejor rentabilidad en relación al riesgo**, dependiendo del régimen.
- El verdadero valor del uso de los modelos de *machine learning* por cuantiles **es administrar la exposición al mercado**.
- Ningún método tradicional supera al Buy & Hold** en ninguna acción.
- La mediana es un predictor más robusto que el promedio**, esto se debe a que los retornos de acciones de IA tienen mayor volatilidad y esto crea colas pesadas en la distribución.

REFERENCIAS

- Bustos, O., Pomares-Quimbaya, A., & Stellan, R. (2025). Machine learning, stock market forecasting, and market efficiency: A comparative study. *International Journal of Data Science and Analytics*, 20, 6815–6839. <https://doi.org/10.1007/s41060-025-00854-4>
- Lin, C. Y., & Lobo Marques, J. A. (2024). Stock market prediction using artificial intelligence: A systematic review of systematic reviews. *Social Sciences & Humanities Open*, 9, 100864. <https://doi.org/10.1016/j.ssaho.2024.100864>