

**Uma jornada épica onde GARCH é Gandalf, LSTM é Legolas e o Precioso é a  
Previsão da Volatilidade**

**FLAVIO LUIZ DE MORAES BARBOZA**  
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

**JOSE AUGUSTO FIORUCCI**

**JEAN CARLOS DOMINGOS**  
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

## Introdução

O mercado de capitais é inerentemente volátil, sendo essa característica central para sua dinâmica e atratividade. A volatilidade, embora crucial para avaliação de riscos e precificação de ativos, apresenta desafios significativos em sua mensuração e previsão. Este estudo compara abordagens tradicionais (GARCH) e modernas (machine learning) para prever volatilidade, com foco em mercados desenvolvidos e emergentes.

## Problema de Pesquisa e Objetivo

Embora modelos GARCH sejam amplamente utilizados, sua capacidade de capturar padrões complexos em mercados voláteis é limitada. Simultaneamente, técnicas de machine learning vêm ganhando destaque, mas sua eficácia comparativa em diferentes contextos de mercado ainda não está consolidada. O objetivo é avaliar o desempenho preditivo de oito modelos (GARCH, LSTM, CNN, XGBoost, entre outros) em 6 índices (S&P 500, Euro Stoxx 100, Hang Seng, ASX All Ordinaries, IBOVESPA e JSE Top 40), que abrangem mercados desenvolvidos e emergentes e os 5 continentes.

## Fundamentação Teórica

A volatilidade é uma métrica de risco fundamental, porém latente, exigindo métodos robustos para sua estimação. Modelos GARCH são eficazes em capturar heterocedasticidade condicional, enquanto técnicas de ML (como LSTM e XGBoost) destacam-se ao modelar não linearidades e dependências temporais complexas. Estudos recentes sugerem que modelos híbridos e baseados em deep learning frequentemente superam abordagens tradicionais.

## Metodologia

O estudo emprega uma abordagem comparativa, avaliando modelos GARCH, LSTM, GRU, CNN, XGBoost e CatBoost em seis índices globais. Utilizam-se duas medidas de volatilidade (teórica e de mercado) para treinamento dos modelos e métricas de erro consolidadas (RMSE, MAE e MAPE). Os dados são referentes simulações usadas para ter o valor exato da volatilidade como valor de referência, as quais surgem de distribuições baseadas em índices de diferentes mercados, incluindo ainda períodos de crise e estabilidade. Para garantir a comparação apropriada, aplicou-se o teste de Diebold-Mariano.

## Análise dos Resultados

Os resultados indicam que modelos de deep learning (LSTM, CNN) superam GARCH em mercados desenvolvidos, com melhores métricas de precisão. Em emergentes, contudo, essa superioridade é menos consistente, sugerindo que a maior imprevisibilidade desses mercados exige adaptações metodológicas. Modelos baseados em árvores (XGBoost) também apresentam desempenho competitivo. Os testes mostram que estes resultados são estatisticamente significativos, validando assim as constatações percebidas.

## Conclusão

Conclui-se que, embora técnicas de ML ofereçam vantagens preditivas em muitos cenários, a escolha do modelo ideal depende do contexto de mercado. Em mercados maduros, LSTM e CNN são preferíveis, enquanto em emergentes, combinações de métodos tradicionais e ML podem ser mais robustas. A interpretabilidade dos modelos também deve ser considerada em aplicações práticas.

## Contribuição / Impacto

Academicamente, o estudo unifica análises fragmentadas, comparando múltiplos modelos em diversos mercados. Na prática, auxilia investidores e gestores na seleção de técnicas adequadas a cada contexto. Adicionalmente, a análise de mercados emergentes traz insights valiosos, frequentemente negligenciados na literatura. Os resultados reforçam a importância de adaptar estratégias de modelagem às particularidades de cada ambiente econômico.

## Referências Bibliográficas

- Bollerslev, T., Patton, A. J., and Quaedvlieg, R. (2016). Exploiting the errors: A simple approach for improved volatility forecasting. *Journal of Econometrics*, 192(1):1-18.
- Christensen, K., Siggaard, M., and Veliyev, B. (2023). A machine learning approach to volatility forecasting. *Journal of Financial Econometrics*, 21(5):1680-1727.
- Engle, R. F. and Patton, A. J. (2001). What good is a volatility model? *Quantitative Finance*, 1(2):237-245.