

**USO DE ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE
PREÇOS DE ATIVOS NOS MERCADOS DE CAPITAIS DE PAÍSES DO G7**

**USE OF ARTIFICIAL INTELLIGENCE ALGORITHMS FOR ASSET PRICE PREDICTION
IN G7 CAPITAL MARKETS**

**USO DE ALGORITMOS DE INTELIGENCIA ARTIFICIAL PARA LA PREDICCIÓN DE
PRECIOS DE ACTIVOS EN LOS MERCADOS DE CAPITALES DEL G7**



10.56238/sevened2026.001-073

Beatriz Mitsuyo Fuzikawa Bicalho Cotta

Instituição: Universidade Federal de Minas Gerais (UFMG)

E-mail: beatriz.bcotta@hotmail.com

Ewerton Alex Avelar

Instituição: Universidade Federal de Minas Gerais (UFMG)

E-mail: ewertonalexavelar@gmail.com

Terence Machado Boina

Instituição: Universidade Federal de Minas Gerais (UFMG)

E-mail: tmboina@gmail.com

Octávio Valente Campos

Instituição: Universidade Federal de Minas Gerais (UFMG)

E-mail: octaviovc@yahoo.com.br

Daniele Oliveira Xavier

Instituição: Fundação João Pinheiro (FJP)

E-mail: danieloliveiraxavier@gmail.com

RESUMO

Este artigo apresenta os resultados de um estudo quantitativo e descritivo, que objetivou realizar uma análise comparativa do desempenho de algoritmos de inteligência artificial (IA) aplicados à previsão do comportamento de ativos financeiros. Os dados analisados foram coletados em mercados de capitais que compõem índices dos países desenvolvidos que compõem o Grupo dos Sete (G7) entre os anos de 2001 a 2023. Para gerar os modelos na pesquisa, foram empregados os seguintes algoritmos de IA: Random Forest (RF), Naive Bayes (NB) e K-Nearest Neighbors (KNN). A análise dos resultados do estudo se fundamentou em estatísticas descritivas e testes de Shapiro-Wilk, t de Student e Mann-Whitney. Os resultados indicaram a robustez e a consistência do modelo RF para prever o comportamento dos índices. Além disso, o trabalho confirma os indicadores técnicos como inputs relevantes para modelos de IA prever preços de ativos financeiros no mercado de capitais. Dentre as principais contribuições teóricas do estudo, destaca-se a indicação de que a Hipótese de Mercados Eficientes (HME) pode ser contingente ao horizonte temporal e ao tipo de dado analisado. Em termos

empíricos, este trabalho evidencia que modelos baseados em IA podem apresentar desempenho acima da média esperada com base na forma fraca da HME

Palavras-chave: Algoritmos de Inteligência Artificial. Hipótese de Mercados Eficientes (HME). Mercados de Capitais. Países do G7.

ABSTRACT

This article presents the results of a quantitative and descriptive study that aimed to perform a comparative analysis of the performance of artificial intelligence (AI) algorithms applied to predicting the behavior of financial assets. The data analyzed were collected from capital markets that make up indices of developed countries that comprise the Group of Seven (G7) between the years 2001 and 2023. To generate the models in the research, the following AI algorithms were used: Random Forest (RF), Naive Bayes (NB), and K-Nearest Neighbors (KNN). The analysis of the study results was based on descriptive statistics and Shapiro-Wilk, Student's t-test, and Mann-Whitney tests. The results indicated the robustness and consistency of the RF model in predicting the behavior of the indices. Furthermore, the work confirms technical indicators as relevant inputs for AI models to predict the prices of financial assets in the capital market. Among the main theoretical contributions of this study, the indication that the Efficient Market Hypothesis (EMH) can be contingent on the time horizon and the type of data analyzed stands out. In empirical terms, this work shows that AI-based models can perform above the expected average based on the weak form of the EMH.

Keywords: Artificial Intelligence Algorithms. Efficient Market Hypothesis (EMH). Capital Markets. G7 Countries.

RESUMEN

Este artículo presenta los resultados de un estudio cuantitativo y descriptivo cuyo objetivo fue realizar un análisis comparativo del desempeño de algoritmos de inteligencia artificial (IA) aplicados a la predicción del comportamiento de activos financieros. Los datos analizados se recopilaron de los mercados de capitales que conforman los índices de los países desarrollados del Grupo de los Siete (G7) entre los años 2001 y 2023. Para generar los modelos de la investigación, se utilizaron los siguientes algoritmos de IA: Bosque Aleatorio (RF), Naive Bayes (NB) y K-Vecinos Más Cercanos (KNN). El análisis de los resultados del estudio se basó en estadística descriptiva y en las pruebas de Shapiro-Wilk, t de Student y Mann-Whitney. Los resultados indicaron la robustez y consistencia del modelo RF en la predicción del comportamiento de los índices. Además, el trabajo confirma que los indicadores técnicos son entradas relevantes para que los modelos de IA predigan los precios de los activos financieros en el mercado de capitales. Entre las principales contribuciones teóricas de este estudio, destaca la indicación de que la Hipótesis del Mercado Eficiente (HME) puede depender del horizonte temporal y del tipo de datos analizados. En términos empíricos, este trabajo demuestra que los modelos basados en IA pueden obtener resultados superiores al promedio esperado según la formulación débil de la HME.

Palabras clave: Algoritmos de Inteligencia Artificial. Hipótesis del Mercado Eficiente (HME). Mercados de Capitales. Países del G7.

1 INTRODUÇÃO

A crescente disponibilidade de dados econômico-financeiros e os avanços em poder computacional têm impulsionado o desenvolvimento e a aplicação de modelos baseados em inteligência artificial (IA) no contexto da previsão de comportamentos de mercado (Rundo et al., 2019). Tais modelos se mostram particularmente promissores para lidar com a complexidade, não linearidade e alta variabilidade das séries temporais financeiras, superando, em muitos casos, as limitações dos métodos estatísticos clássicos, como ARIMA ou GARCH (Kemalbay & Korkmazoglu, 2023; Saeed et al., 2022). Em função disso, modelos baseados em algoritmos como *Random Forest* (RF), *Naive Bayes* (NB) e *K-Nearest Neighbors* (KNN) têm sido amplamente empregados em tarefas de classificação associadas a movimentos de preços de ativos, especialmente quando combinados a indicadores técnicos derivados do próprio histórico do ativo (Ampomah et al., 2021; Mndawe et al., 2022; Sagaceta-Mejía et al., 2024).

A avaliação do desempenho desses modelos é usualmente feita com base em métricas consolidadas no campo do aprendizado de máquina supervisionado, como acurácia, *precision*, *recall* e F1-score. Cada métrica fornece uma perspectiva para interpretar os acertos e erros do modelo, variando em função de tipos de desequilíbrio entre as classes e erros de classificação (Lantz, 2019; Mohanty et al., 2021; Nabipour et al., 2020). Ainda assim, a literatura carece de investigações mais robustas que analisem, de forma sistemática, se a superioridade de desempenho de um modelo apontada por determinadas métricas é consistente entre algoritmos e quais variações significativas influenciam os resultados desses modelos.

Além disso, embora o foco deste estudo não se relacione ao retorno econômico-financeiro diretamente associado à aplicação desses modelos, é importante considerar que, em muitos trabalhos da literatura (Avelar & Jordão, 2024), há uma associação implícita entre alto desempenho preditivo e potencial geração de retornos anormais, o que remete a debates relevantes da Teoria de Finanças. Em particular, a Hipótese de Mercados Eficientes (HME), pilar da teoria financeira moderna, especialmente em sua forma fraca, sustenta que os preços dos ativos incorporam todas as informações históricas disponíveis, tornando inviável a obtenção de retornos sistemáticos por meio da análise técnica (Fama, 1970; Timmermann & Granger, 2004). De forma mais específica, a HME sustenta que: (i) recursos financeiros fluem para as empresas e projetos com as melhores perspectivas de retorno ajustado ao risco; (ii) como o preço de mercado é a melhor estimativa disponível do valor de um ativo, nenhum agente econômico possui consistentemente informações superiores que permitam lucros anormais sustentáveis; e (iii) anomalias de mercado tendem a ser raras, transitórias ou compensadas, uma vez que qualquer desvio de preço em relação ao valor normal do ativo seria momentaneamente explorado, mas o preço voltaria ao equilíbrio de forma célere.

Tendo em vista essas características da HME e considerando que, na prática, os mercados

apresentam imperfeições e os agentes enfrentam incertezas complexas, modelos preditivos ainda são considerados fundamentais no mercado financeiro (de capitais) para, por exemplo: (a) identificar momentaneamente ativos sub ou supervalorizados (desafiando a HME) ou explorar fatores de risco (valor, momento, qualidade) que possam gerar retornos persistentes, (b) quantificar e controlar a exposição ao risco de portfólio, (c) prever retornos e correlações futuras entre diferentes classes de ativos (ações, títulos, *commodities*) para otimizar a distribuição do capital e (d) identificar padrões de curto prazo, executar ordens automaticamente e explorar ineficiências momentâneas. Diante disso, diversos estudos vêm documentando desempenhos superiores de modelos de IA em relação à aleatoriedade, mesmo se baseando exclusivamente em dados históricos (Shynkevich *et al.*, 2017; Cao *et al.*, 2019; Hung *et al.*, 2024; Shaban *et al.*, 2024), o que tensiona os pressupostos da HME e motiva análises empíricas adicionais — ainda que dissociadas do retorno propriamente dito.

Nesse contexto, o presente artigo apresenta os resultados de um estudo que objetivou realizar uma análise comparativa do desempenho de algoritmos de IA aplicados à previsão do comportamento de ativos financeiros, com base em indicadores técnicos amplamente utilizados na literatura, e avaliados sob múltiplas métricas preditivas. Na pesquisa, incluiu-se a Regressão Logística (RL), de forma a estabelecer um referencial clássico estatístico que possibilite comparar a contribuição dos algoritmos de IA na tarefa de classificação binária em séries temporais financeiras. A análise visou contribuir para o avanço do debate sobre o papel da IA na modelagem de dados econômico-financeiros e sobre os critérios mais adequados para a sua avaliação, especialmente diante da diversidade de métricas disponíveis e da sensibilidade dos modelos aos diferentes vieses que essas métricas podem introduzir.

Dentre as principais contribuições teóricas do estudo, destaca-se a indicação de que a HME pode ser contingente ao horizonte temporal e ao tipo de dado analisado. Em termos empíricos, este trabalho evidencia que modelos baseados em IA podem apresentar desempenho acima da média esperada com base na forma fraca da HME, o que desafia a teoria do passeio aleatório (*random walk* – RW), na qual nenhum modelo preditivo deveria obter mais de 50% de acerto. Nesse diapasão, apresenta a robustez e consistência do modelo RF com dados de índices de mercado de capitais, especialmente ao considerar conjuntamente acurácia, *precision* e *recall*, mas também reforçou a RL como um referencial clássico estatístico satisfatório. Além disso, o trabalho confirma os indicadores técnicos como *inputs* relevantes para modelos de IA prever preços de ativos financeiros no mercado de capitais.

2 FUNDAMENTAÇÃO TEÓRICA E DESENVOLVIMENTO DE HIPÓTESES

Na literatura de finanças, a lógica do passeio aleatório (RW) delineada por Bachelier (1900) e consolidada por Fama (1970) continua sendo o ponto de partida para discutir eficiência de mercado.

Contudo, tendo em vista Pagliaro (2025), a relação entre a HME e a previsibilidade de preços precisa ser reavaliada à luz do *big data* e da IA: modelos preditivos baseados nesta tecnologia reabrem o debate ao demonstrar ganho estatístico — ainda que nem sempre econômico — em diferentes regimes de mercado.

Para além da discussão teórica, a adoção de algoritmos de IA tem avançado justamente por capturar estruturas não lineares ausentes nas abordagens econométricas clássicas. Balasubramanian et al. (2024) mostraram, em uma meta-análise de mais de 100 estudos, que classificadores supervisionados como KNN, RF e NB aparecem entre os mais investigados quando se utilizam métricas de avaliação como *recall*, *precision*, acurácia e F1-score — exatamente o conjunto de métricas adotado nesta pesquisa. Evidências empíricas corroboram esse movimento, tais como Khan et al. (2023), Hung et al. (2024), Shaban et al. (2024), Yang (2024). De forma geral, a literatura pós-2010 passa a sugerir que algoritmos como KNN, RF e NB — avaliados via *recall*, *precision*, acurácia e F1 — representam alternativas robustas para investigar anomalias de mercado, sem necessariamente invalidar a HME, mas refinando as condições sob as quais ela se sustenta.

Destaca-se que, em muitos desses estudos são empregados algoritmos de aprendizado supervisionado que usam indicadores técnicos como *inputs* dos modelos (Chacon et al., 2020; Henrique et al., 2018; Kulagic & Ustundag, 2021; Staffini, 2022). Os preços de abertura, fechamento, máximo e mínimo são aplicados a uma fórmula que calcula tais indicadores técnicos (Dhafer et al., 2022; Jia et al., 2024; Sivapurapu, 2020). Na pesquisa ora apresentada, foram considerados os seguintes indicadores com base nos estudos de Samal e Dash (2023) e Sivapurapu (2020): *Simple Moving Average* (SMA), *Weighted Moving Average* (WMA), *Moving Average Convergence/Divergence* (MACD), *Momentum Stochastic K%* (STCK), *Momentum Stochastic D%* (STCD), *Relative Strength Index* (RSI) e *William's Percent R* (WPR). Com base nessas pesquisas, a Hipótese 1 (H1) do estudo foi formulada:

H₁: Modelos baseados em IA apresentam desempenho acima da média esperada com base na forma fraca da HME.

Estudos passados destacam o uso de modelos estatísticos tradicionais para analisar o fenômeno como *benchmarking* para os algoritmos de IA, tais como Das et al. (2022) e Jia et al. (2024). Alguns estudos, ainda, evidenciaram que o desempenho de alguns algoritmos de IA usados foi parecido com o desempenho de técnicas tradicionais de estatística, quando aplicados para a previsão de preços de ativos (Vuong et al., 2022; Kemalbay & Korkmazoglu, 2023). Entretanto, de maneira geral, o desempenho dos algoritmos de IA, quando aplicados à previsão de movimentos nos preços de ativos no mercado financeiro, apresentou resultados satisfatórios. Segundo autores como Chernavin (2019), Mahtab et al. (2022) e Farahani et al. (2023), o modelo RL é bastante utilizado para resolver problemas

de classificação binária, sendo base de referência para comparação com o desempenho de modelos baseados em algoritmos de IA. Com isso, a Hipótese 2 (H2) foi formulada:

H₂: Modelos baseados em IA apresentam desempenho estatisticamente superior às técnicas estatísticas tradicionais.

Tal como destacado, diferentes algoritmos de IA são empregados para previsão de preços de ativos no mercado de capital, sendo alguns deles NB, KNN e RF (Khan *et al.*, 2023; Metawa *et al.*, 2023; Moon *et al.*, 2018; Muthuselvi *et al.*, 2019; Polamouri *et al.*, 2021; Shastri *et al.*, 2019). O KNN é um algoritmo não paramétrico, que escolhe o rótulo de classe do novo ponto de dados o comparando com seus “k vizinhos mais próximos”, ou seja, de acordo com padrões, tais como o de precificação de ativos (Khan *et al.*, 2023). Esse método é simples e direto de ser implementado, mas é sensível à estrutura local dos dados e ao número de amostras no conjunto de treinamento para classificar novas amostras (Moon *et al.*, 2018).

O NB, por seu turno, se baseia no fato de os dados anteriores serem independentes, podendo ser utilizado para classificar informações e, posteriormente, atuar na previsão do crescimento ou decréscimo de preços de ativos (Shastri *et al.*, 2019). Por fim, o RF é uma coleção de preditores de árvore de modo que cada árvore depende dos valores de vetores aleatórios amostrados individualmente (Muthuselvi *et al.*, 2019). o RF usa um método de conjunto para criar muitas árvores de decisão com base nos dados de treinamento, fazendo com que essas árvores de decisão sejam então calculadas em média e uma otimização desses valores é usada para decidir qual árvore usar. Assim, como cada um desses algoritmos emprega formas distintas de aprendizado, com suas características peculiares, a Hipótese 3 (H3) foi formulada:

H₃: Modelos baseados em diferentes algoritmos de IA têm desempenhos estatisticamente diferentes entre si.

3 METODOLOGIA

De acordo com Cooper e Schindler (2006), o estudo apresentado neste artigo teve caráter descritivo e quantitativo. Os dados financeiros analisados foram coletados em mercados de capitais que compõem índices dos países desenvolvidos que compõe o Grupo dos Sete (G7). Trata-se de um fórum informal que reúne Itália, Canadá, França, Alemanha, Japão, Reino Unido e Estados Unidos da América (G7, 2025).

Os ticker (códigos) dos principais índices das bolsas de valores de cada país foram coletados no site Yahoo! Finance, essencial para coleta de dados referentes às cotações diárias de cada índice a partir da linguagem de programação R e das funções do pacote Quantitative Financial Modelling Framework (quantmod). De acordo com Ryan *et al.* (2024), esse pacote objetiva auxiliar agentes de mercado a testar e desenvolver modelos de negociação no mercado de capitais. Com base nesses

critérios, foram selecionados 7 índices – que compreendem a amostra final: Estados Unidos (^GSPC), Reino Unido (^FTSE), Japão (^N225), Itália (FTSEMIB.MI), Alemanha (^GDAXI), França (^FCHI) e Canadá (^GSPTSE).

Os dados dos índices foram usados para calcular os indicadores técnicos mencionados na Tabela 1, que foram normalizados para possibilitar o emprego de algoritmos que demandam variáveis contínuas, como sugerem Ampomah et al. (2021) e Mohanty et al. (2021). Além disso, foram estimados modelos de RL para que seus resultados fossem comparados com os resultados dos algoritmos de IA, conforme verificado em Chernavin (2019) e Farahani et al. (2023). Os indicadores técnicos foram empregados para prever o retorno do índice no dia seguinte, ou seja, aumento ou redução do seu preço em relação ao dia anterior, segundo modelo apresentado na Equação 1, no qual a variável dependente RA representa o retorno do ativo em relação ao dia anterior (1 se positivo, 0 se negativo), t representa o dia e ε representa o erro.

$$RA_t = \beta_0 + \beta_1 SMA_{t-1} + \beta_2 WMA_{t-1} + \beta_3 MACD_{t-1} + \beta_4 STCK_{t-1} + \beta_5 STCD_{t-1} + \beta_6 RSI_{t-1} + \beta_7 WPR_{t-1} + \varepsilon$$

Os modelos gerados por algoritmos de IA analisados na pesquisa (KNN, NB e RF) foram empregados para fins de classificação, com o propósito de prever o retorno futuro dos índices, usando os indicadores técnicos listados na Equação 1 como variáveis independentes. Para fins de treinamento do modelo, foram empregados 80% dos dados e os 20% remanescentes dos dados foram utilizados na etapa de teste. Tal proporção de dados de treinamento em relação aos dados de teste (4:1) se assemelha com estudos anteriores para previsão no mercado financeiro, por exemplo: Mndawe et al. (2022) e Shaban et al. (2024).

Para otimizar os parâmetros dos modelos e estimar seus desempenhos, optou-se pela métrica de acurácia (Equação 2), empregada em estudos dessa natureza envolvendo modelos de IA, de acordo com Ampomah et al. (2021), Mndawe et al. (2022) e Farahani et al. (2023). Segundo Chernavin (2019), a acurácia mensura a proporção de previsões corretas realizadas pelo modelo, proporcionando uma visão geral da capacidade de o modelo acertar as previsões realizadas.

$$Acurácia = \frac{VP+VN}{VP+FP+VN+FN}$$

‘VP’ equivale a “verdadeiros positivos”;

‘VN’ equivale a “verdadeiros negativos”;

‘FP’ equivale a “falsos positivos”; e

‘FN’ equivale a “falsos negativos”.

Os seguintes parâmetros foram usados para determinados algoritmos: (a) KNN –variação entre 1 (um) e 50 (cinquenta) para o parâmetro “k”, de forma que o algoritmo selecionasse o melhor “k-vizinhos mais próximos” para cada índice; e (b) RF – variação entre 3 (três) e 30 (trinta) árvores estimadas, a fim de que o algoritmo selecionasse a quantidade que otimizaria o desempenho para cada índice, no sentido de Qian e Rasheed (2007). Ressalta-se a forma de treinamento e teste dos modelos de IA foi com base no fluxograma básico de Ferreira et al. (2021) para previsão de preços de ativos no mercado de capitais: (1) Coleta dos dados de entrada – dados dos preços históricos (abertura, máximo, mínimo e fechamento) dos principais índices de bolsas de valores selecionadas; (2) Transformação e seleção dos dados – cálculo dos retornos diários dos índices e dos respectivos indicadores técnicos; (3) Treinamento do modelo – uso de 80% dos dados por ano; (4) Otimização de parâmetros – variação da janela de cálculo dos indicadores técnicos entre 3 e 30 dias, assim como de parâmetros específicos de cada algoritmo; e (5) Avaliação do desempenho do modelo – cálculo da acurácia para os 20% dos dados remanescentes por ano

Ressalta-se que os indicadores técnicos foram calculados para o período entre 3 (três) e 30 (dias), conforme Khoa e Huynh (2021), para que cada algoritmo selecionasse o intervalo com melhor desempenho para previsão de cada índice. Não obstante, diferentemente dos referidos autores, que segregaram períodos específicos para os algoritmos escolherem, neste estudo, os algoritmos tiveram autonomia para escolher um dos 28 dias disponíveis para cálculo dos indicadores.

A análise dos resultados do estudo se fundamentou em estatísticas descritivas (descrição dos resultados essenciais dos modelos estimados), teste de Shapiro-Wilk (análise da normalidade da distribuição), teste t de Student, teste de Mann-Whitney (verificação da existência de diferenças estatisticamente significantes entre os desempenhos dos algoritmos de IA e entre estes desempenhos e o desempenho do mercado de capitais), semelhantemente a Mndawe et al. (2022) e Farahani et al. (2023). Salienta-se que, segundo Suárez-Cetrulo et al. (2019) e Hung et al. (2024), o desempenho do mercado de capitais se assemelha ao movimento aleatório de preços, isto é, 50% de acerto e de erro, consistente com a HME em sua forma fraca.

O nível de significância empregado nos testes foi de 5%. Todos os dados foram tratados e analisados a partir do R, utilizando os seguintes pacotes: Discrete Goodness-of-Fit Tests (dgof); quantmod; Functions for Classification (class); Breiman and Cutler's Random Forests for Classification and Regression (randomForest); Misc Functions of the Department of Statistics, Probability Theory Group (e1071); A Grammar of Data Manipulation (dplyr); e eXtensible Time Series (xts).

4 RESULTADOS

A comparação entre os modelos preditivos com base nas principais métricas de desempenho — acurácia, F1-score, *precision* e *recall* — permite uma análise mais refinada do comportamento de cada algoritmo. Conforme os *boxplots* apresentados (Figuras 1 a 4), observam-se diferenças relevantes entre os algoritmos RF, NB, KNN e RL.

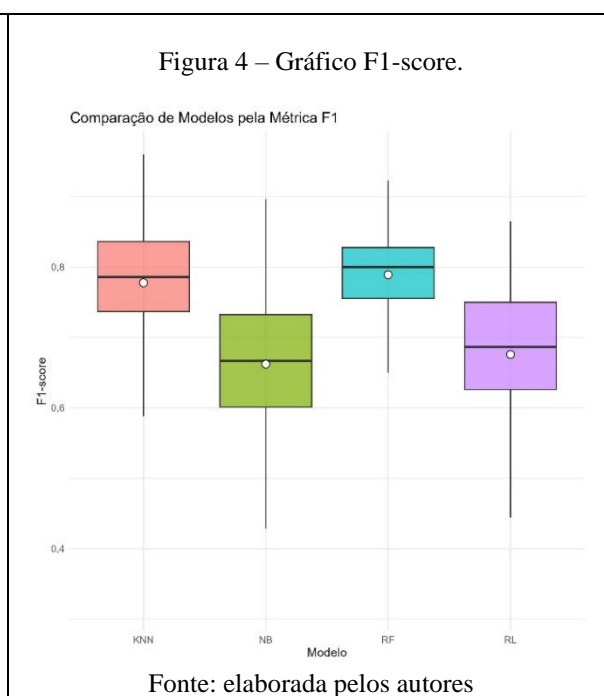
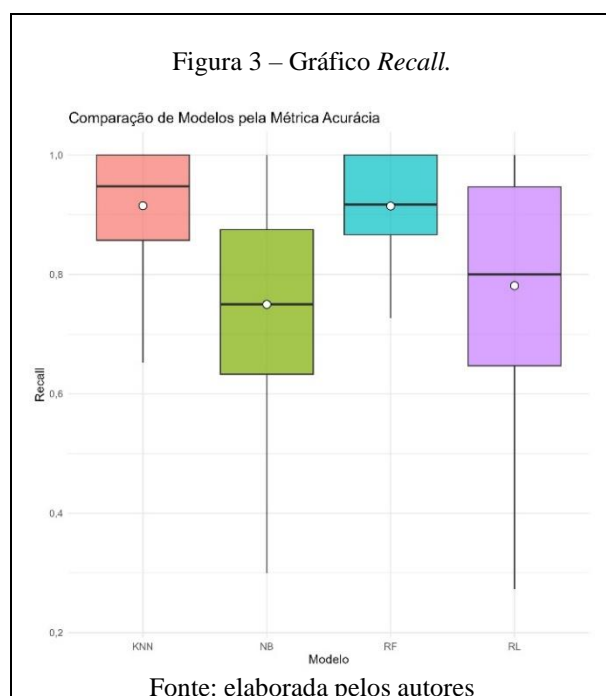
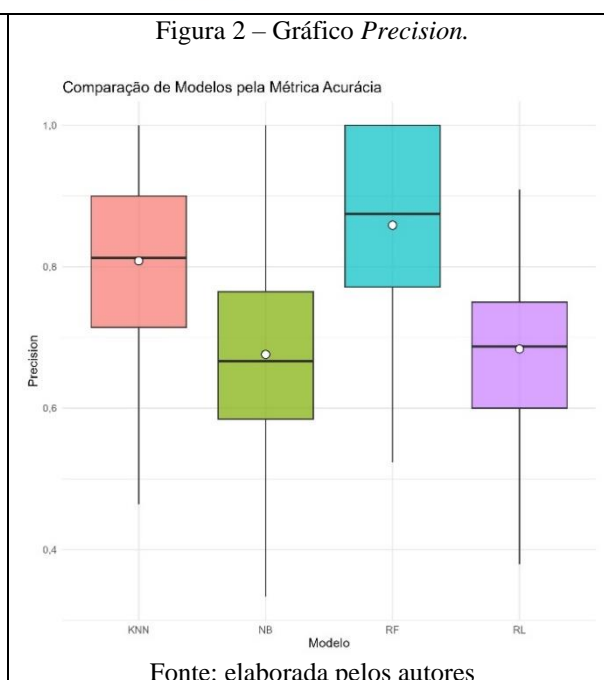
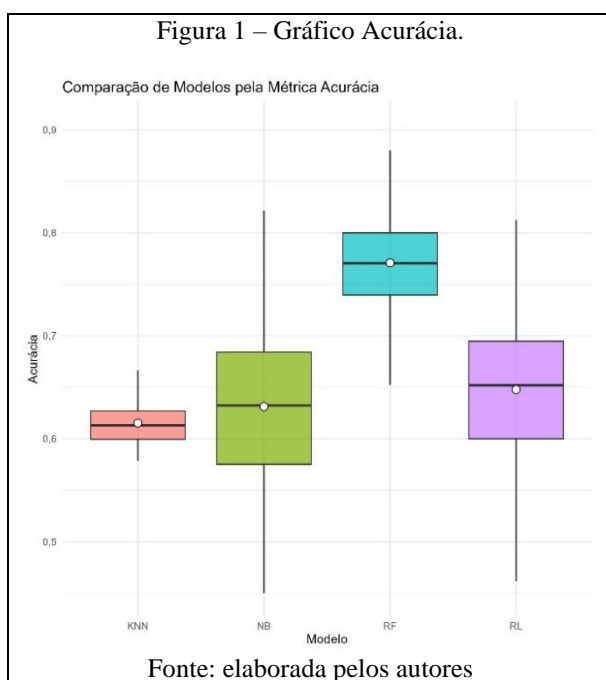
O primeiro gráfico (Figura 1), que apresenta os resultados segundo a métrica de acurácia, evidencia que o algoritmo RF possui a mediana mais elevada, com desempenho mais consistente, refletido em menor dispersão e valores superiores à RL, ao NB e ao KNN. Apesar disso, os modelos de RL também apresentaram desempenho satisfatório, com mediana próxima a 0,70. O NB, por outro lado, apresentou maior variabilidade, enquanto o KNN manteve-se com acurácia inferior, com mediana próxima de 0,62.

A métrica F1-score (Figura 4) revela um comportamento distinto: os modelos baseados em KNN e RF apresentaram as maiores medianas, próximas de 0,80, com o KNN levemente superior ao RF nesse aspecto. O NB novamente demonstrou menor desempenho, com maior dispersão e mediana inferior, enquanto a RL posicionou-se de forma intermediária, reforçando sua estabilidade.

Quanto à métrica *precision* (Figura 2), RF novamente lidera com valores máximos próximos a 1,0 e mediana elevada, seguido por KNN. O NB e a RL apresentaram performances inferiores nesse aspecto, com destaque para a maior variabilidade no NB. Esses resultados indicam que o RF possui maior capacidade de evitar falsos positivos — aspecto crucial para aplicações em que a penalização de classificações incorretas pode impactar decisões financeiras.

Já na métrica *recall* (Figura 3), embora todos os modelos tenham obtido valores elevados, indicando boa capacidade de identificar corretamente a classe positiva, as diferenças entre eles foram menos expressivas. Ainda assim, RF e RL destacaram-se com medianas próximas a 0,90, sugerindo bom desempenho na recuperação de casos positivos, enquanto NB e KNN apresentaram maior variância, especialmente o primeiro.

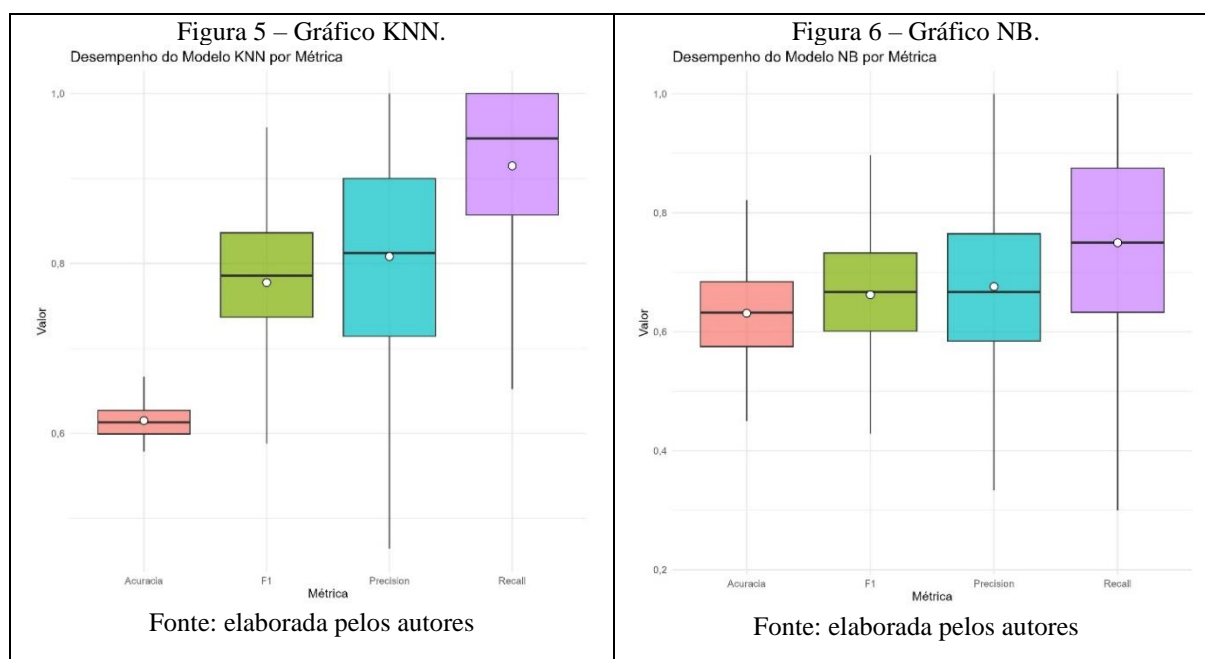
Esses resultados, portanto, sugerem que o modelo RF apresentou o desempenho mais robusto e consistente entre os algoritmos avaliados, particularmente quando consideradas conjuntamente acurácia, *precision* e *recall*. Entretanto, observa-se que modelos estatísticos como a RL mantêm desempenho satisfatório quanto à ausência de superioridade clara e consistente dos modelos de IA sobre abordagens tradicionais em todas as métricas avaliadas.

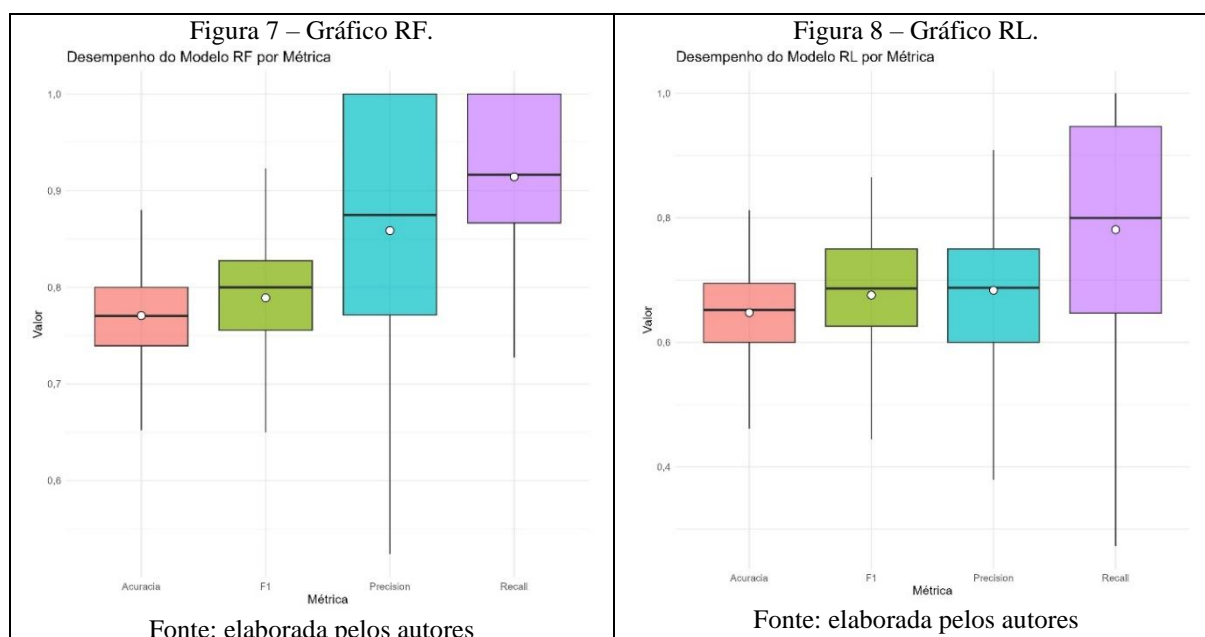


A decomposição do desempenho de cada modelo por métrica permite uma avaliação mais precisa de suas características preditivas e das limitações de cada abordagem. O modelo KNN (Figura 5) apresentou desempenho consistente nas métricas F1-score, *precision* e *recall*, com medianas superiores a 0,75, destacando-se especialmente na métrica de *recall*, onde a mediana se aproxima de 0,95. Esse resultado sugere uma forte capacidade do modelo em identificar corretamente os casos positivos. Por outro lado, a acurácia do KNN foi notadamente inferior às demais métricas, com mediana próxima de 0,62, o que pode indicar sensibilidade ao desbalanceamento das classes.

No caso do modelo NB (Figura 6), observa-se uma maior homogeneidade entre as métricas. As medianas de acurácia, F1-score, *precision* e *recall* situaram-se próximas a 0,65–0,70, porém com ampla variabilidade — revelando um desempenho instável, fortemente influenciado pelas características dos dados. A elevada dispersão dos resultados pode comprometer sua confiabilidade em cenários práticos. O modelo RF (Figura 7) confirmou seu desempenho robusto, pois as quatro métricas analisadas apresentaram medianas elevadas, com destaque para a *precision*, cuja mediana superou 0,90, e para o *recall*, próximo a 0,95. Essa performance reforça a eficácia do RF em minimizar falsos positivos e negativos, tornando-o uma das abordagens mais estáveis e eficientes entre as testadas.

Por fim, o modelo RL (Figura 8) demonstrou um desempenho intermediário. Embora nenhuma métrica tenha se destacado de forma isolada, todas apresentaram medianas razoáveis (entre 0,65 e 0,80). O destaque vai para o *recall*, que apresentou maior mediana e menor variabilidade, o que pode indicar uma capacidade mais robusta na identificação de eventos positivos em comparação com a *precision* mais moderada.





5 CONCLUSÕES

Os resultados empíricos obtidos neste estudo permitem avaliar de forma crítica as hipóteses formuladas acerca do desempenho preditivo de algoritmos de IA aplicados à previsão do comportamento de ativos financeiros. A análise, baseada em métricas clássicas de avaliação – acurácia, *precision*, *recall* e F1-score – e apoiada em comparações visuais por meio de *boxplots*, revelou padrões relevantes que permitem discutir os pressupostos da literatura recente frente à HME em sua forma fraca e à teoria do passeio aleatório.

A primeira hipótese, que sugeria que os modelos baseados em IA apresentariam desempenho acima da média esperada com base na HME na forma fraca e considerando o passeio aleatório, encontrou apoio parcial nos resultados. Em praticamente todas as métricas avaliadas, os algoritmos de IA (RF, NB e KNN) apresentaram medianas superiores a 0,6 e, em alguns casos, próximas ou superiores a 0,8, o que supera o desempenho aleatório (próximo a 50%). Contudo, o nível de variação interna de alguns modelos, especialmente o NB, sinaliza que essa superioridade não é uniforme entre os algoritmos e nem sempre é consistente em todas as métricas. Ainda assim, os resultados desafiam empiricamente o postulado da imprevisibilidade do passeio aleatório sustentado pela forma fraca da HME.

A segunda hipótese, que previa desempenho estatisticamente superior dos modelos de IA em relação à técnica estatística tradicional (RL), não foi plenamente confirmada. Embora modelos como o RF tenham demonstrado desempenho superior em métricas como *precision* e *recall*, a RL apresentou desempenho satisfatório, especialmente em *recall* e acurácia, com baixa dispersão e estabilidade notável. Em alguns casos, o desempenho da RL se mostrou equivalente ou mesmo superior ao de algoritmos como NB, o que sugere que a substituição de métodos estatísticos por técnicas de IA deve ser analisada com cautela, especialmente quando se considera o custo computacional envolvido.

A terceira hipótese, que propôs desempenhos estatisticamente distintos entre os diferentes algoritmos de IA, foi corroborada pelos gráficos analisados. Verificaram-se diferenças substanciais entre os algoritmos em magnitude e em dispersão dos escores de desempenho. O RF destacou-se pela robustez e constância em múltiplas métricas, enquanto o NB apresentou maior variação e sensibilidade às métricas utilizadas. O KNN, por sua vez, oscilou entre desempenho moderado e elevado, dependendo da métrica analisada. Esses achados reforçam a importância da escolha criteriosa do algoritmo conforme o objetivo da previsão, os custos associados a erros de classificação específicos (falsos positivos ou negativos) e o contexto de sua utilização.

Em síntese, os resultados obtidos demonstram que os modelos baseados em IA, embora promissores, não são uniformemente superiores às técnicas estatísticas tradicionais, e seu desempenho pode variar significativamente conforme o algoritmo e a métrica empregada. Isso ressalta a importância de análises multifacetadas, capazes de capturar as nuances do desempenho preditivo e de sustentar decisões metodológicas bem fundamentadas, especialmente em aplicações sensíveis como o mercado financeiro.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio na realização da pesquisa.

REFERÊNCIAS

AGUIRRE, A. A.; MEDINA, R. A.; MÉNDEZ, N. D. Machine learning applied in the stock market through the Moving Average Convergence Divergence (MACD) indicator. **Investment Management and Financial Innovations**, v. 17, n. 4, p. 44–60, 2020.

AMPOMAH, E. K.; QIN, Z.; NYAME, G.; BOTCHEY, F. E. Stock market decision support modeling with tree-based AdaBoost ensemble machine learning models. **Informatica**, v. 44, n. 4, 2021.

AVELAR, E.; JORDÃO, R. V. D. The role of artificial intelligence in the decision-making process: a study on the financial analysis and movement forecasting of the world's largest stock exchanges. **Management Decision**, 2024.

BACHELIER, L. **Théorie de la spéculation**. Annales scientifiques de l'École Normale Supérieure, 3^a série, v. 17, p. 21–86, 1900.

BALASUBRAMANIAN, P.; CHINTHAN, P. C.; BADARUDEEN, S.; SRIRAMAN, H.; et al. **A systematic literature survey on recent trends in stock market prediction**. PeerJ Computer Science, v. 10, e1700, 2024.

BENACHENHOU, A. **Países emergentes**. Brasília: FUNAG, 2013.

CAO, H. et al. Stock price pattern prediction based on complex network and machine learning. **Complexity**, v. 2019, 2019.

CHACÓN, H. D.; KESICI, E.; NAJAFIRAD, P. **Improving financial time series prediction accuracy using ensemble empirical mode decomposition and recurrent neural networks**. IEEE Access, v. 8, p. 117133–117143, 2020.

CHERNAVIN, N. P. Application of the committee machine method to analysis of stock market technical indicators. **Бизнес-информатика**, v. 13, 4, 2019, 73-86.

COOPER, D.; SCHINDLER, P. **Business research methods**. McGraw Hill-Irwin, 2006.

DAS, S.; et al. **Applied artificial intelligence and high-performance work systems: mediating role of employee potential development**. Artificial Intelligence Review, 2022.

DHAFFER, A. H.; NOR, F. M.; ALKAWSI, G.; AL-OTHMANI, A. Z.; et al. **Empirical analysis for stock price prediction using NARX model with exogenous technical indicators**. Computational Intelligence and Neuroscience, v. 2022, Article ID 9208640, p. 1–13, 2022.

FAMA, E. F. Efficient capital markets: a review of theory and empirical work. **The Journal of Finance**, v. 25, n. 2, p. 383–417, 1970.

FARAHANI, M.; FARROKHI-ASL, H.; RAHIMIAN, S. Hybrid metaheuristic artificial neural networks for stock price prediction considering efficient market hypothesis. **International journal of research in industrial engineering**, v. 12, 3, 2023, pp. 234-272.

G7. **About the G7**. 2025. <https://www.g7italy.it/en/about-g7/>

- GUENNIQUI, O.; CHIADMI, D.; AMGHAR, M. **Global stock price forecasting during a period of market stress using LightGBM**. *International Journal of Computing and Digital Systems*, v. 15, n. 1, p. 22–33, 2024.
- HENRIQUE, B. M.; SOBREIRO, V. A.; KIMURA, H. **Stock price prediction using support vector regression on daily and up to the minute prices**. *Journal of Finance and Data Science*, v. 4, p. 183–201, 2018.
- HUNG, M. C.; CHEN, A. P.; YU, W. T. AI-driven intraday trading: applying machine learning and market activity for enhanced decision support in financial markets. *IEEE Access*, v. 12, 2024.
- JIA, Y.; ANAISSI, A.; SULEIMAN, B. **ResNLS: An improved model for stock price forecasting**. *Computational Intelligence*, v. 40, e12608, 2024.
- KEMALBAY, A. F.; KORKMAZOGLU, F. E. Comparative performance analysis of statistical and machine learning models for financial time series prediction. *Expert Systems with Applications*, v. 213, 2023.
- KHAN, A. H.; SHAH, A.; ALI, A.; SHAHID, R.; et al. **A performance comparison of machine learning models for stock market prediction with novel investment strategy**. *PLoS ONE*, v. 18, n. 9, e0286362, 2023.
- KHOA, B. T. & HUYNH, T. T. Is it possible to earn abnormal return in an inefficient market? An approach based on machine learning in stock trading. *Computational Intelligence and Neuroscience*, v. 1, 2021, pp. 2917577.
- KULAGLIC, A.; USTUNDAG, B. B. **Stock price prediction using predictive error compensation wavelet neural networks**. *Computers, Materials & Continua*, v. 68, n. 3, p. 3571–3586, 2021.
- LANTZ, B. **Machine learning with R: expert techniques for predictive modeling**. 3. ed. Birmingham: Packt Publishing, 2019.
- MAHTAB, M. T.; ZAMAN, A. G. M.; MAHIN, M. R.; NAZIM, M. M.; ISLAM, M. T. **Stock price prediction: an incremental learning approach model of multiple linear regression**. *AIUB Journal of Science and Engineering*, v. 21, n. 3, p. 159–166, 2022.
- METAWA, N.; AKOUR, I.; TAREK, Z.; ELHOSENY, M. **Improved optimization model for forecasting stock directions (FSD)**. *Economic Research-Ekonomska Istraživanja*, v. 36, n. 3, p. 1–20, 2023.
- MNDAWE, S. T.; PAUL, B. S.; DOORSAMY, W. Development of a stock price prediction framework for intelligent media and technical analysis. *Applied Sciences*, v. 12, n. 2, 2022.
- MOHANTY, D. K.; PARIDA, A. K.; KHUNTIA, S. S. Financial market prediction under deep learning framework using auto encoder and kernel extreme learning machine. *Applied Soft Computing*, v. 99, 2021.
- MOON, K.; JUN, S.; KIM, H. Speed up of the majority voting ensemble method for the prediction of stock price directions. *Economic Computation & Economic Cybernetics Studies & Research*, v. 5, 21, 2018.

MUTHUSELVI, S.; RENGARAJAN, A.; SCINTIACLARINDA, S.; NITHYA, K. **Stock price prediction using machine learning and sentiment analysis**. *International Journal of Recent Technology and Engineering*, v. 8, n. 2, p. 2847–2851, 2019.

NABIPOUR, M. et al. Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data: a comparative analysis. *IEEE Access*, v. 8, p. 150199–150212, 2020.

PAGLIARO, A. **Forecasting significant stock market price changes using machine learning: Extra Trees classifier leads**. *Electronics*, v. 12, n. 21, p. 4551, 2023.

POLAMURI, S. R.; SRINIVAS, D. K.; KRISHNA MOHAN, D. A. **Multi-model generative adversarial network hybrid prediction algorithm (MMGAN-HPA) for stock market prices prediction**. *Journal of King Saud University – Computer and Information Sciences*, v. 34, n. 7, p. 7433–7444, 2022.

QIAN, B.; RASHEED, K. Stock market prediction with multiple classifiers. *Applied Intelligence*, 26, 2007, pp. 25-33.

RUNDO, F.; TRENTA, F.; DI STALLO, A. L.; BATTIATO, S. Machine learning for quantitative finance applications: A survey. *Applied Sciences*, v. 9, 24, 2019, pp. 5574.

RYAN, J. A. et al. **Package ‘quantmod’**, 2024.

SAEED, S. et al. Performance analysis of financial forecasting using deep learning techniques. *Neural Computing and Applications*, v. 34, p. 15035–15053, 2022.

SAGACETA-MEJÍA, A. R.; SÁNCHEZ-GUTIÉRREZ, M. E.; FRESÁN-FIGUEROA, J. A. An intelligent approach for predicting stock market movements in emerging markets using optimized technical indicators and neural networks. *Economics*, v. 18, n. 1, 2024.

SAMAL, D.; DASH, R. Intelligent stock price prediction using machine learning and deep learning techniques: a comprehensive review. *Journal of King Saud University - Computer and Information Sciences*, v. 35, n. 10, p. 11301–11313, 2023.

SHABAN, W. M.; ASHRAF, E.; SLAMA, A. E. SMP-DL: a novel stock market prediction approach based on deep learning for effective trend forecasting. *Neural Computing and Applications*, v. 36, 4, 2024, pp. 1849-1873.

SHASTRI, M.; ROY, S.; MITTAL, M. **Stock price prediction using artificial neural model: an application of big data**. *EAI Endorsed Transactions on Scalable Information Systems*, v. 6, n. 20, e1, 2019.

SIVAPURAPU, S. A. **Comparative study of time series and deep learning algorithms for stock price prediction**. *International Journal of Advanced Computer Science and Applications*, v. 11, n. 6, p. 460–468, 2020.

STAFFINI, A. **Stock price forecasting by a deep convolutional generative adversarial network**. *Frontiers in Artificial Intelligence*, v. 5, Article 837596, 2022.

SUÁREZ-CETRULO, A. L.; CERVANTES, A.; QUINTANA, D. Incremental market behavior classification in presence of recurring concepts. *Entropy*, v. 21, 1, 2019, pp. 25.

TANG, H. et al. Stock market prediction using multi-feature fusion and stacked LSTM networks. **Procedia Computer Science**, v. 174, p. 393–402, 2020.

TIMMERMANN, A.; GRANGER, C. W. Efficient market hypothesis and forecasting. **International Journal of Forecasting**, v. 20, n. 1, p. 15–27, 2004.

VUONG, P. H.; DAT, T. T.; MAI, T. K.; UYEN, P. H.; BAO, P. T. **Stock-price forecasting based on XGBoost and LSTM**. *Computer Systems Science & Engineering*, v. 44, n. 1, p. 279–292, 2022.

WANG, H.; LU, S.; ZHAO, J. **Aggregating multiple types of complex data in stock market prediction: a model-independent framework**. *Knowledge-Based Systems*, v. 164, p. 193–204, 2019.

YANG, S.; DING, Y.; XIE, B.; GUO, Y.; BAI, X.; QIAN, J.; GAO, Y.; WANG, W.; REN, J. **Advancing financial forecasts: a deep dive into memory attention and long-distance loss in stock price predictions**. *Applied Sciences*, v. 13, n. 22, p. 12160, 2023.