



O USO DA INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE PREÇOS NO MERCADO FINANCEIRO

CARLOS HENRIQUE CARVALHAES DE ARAUJO - ric.pastel@gmail.com
PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS - PUC-GO

JOÃO HENRIQUE SILVA DE MIRANDA - joaohsm13@gmail.com
PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS - PUC-GO

MARCUS VINICIUS SANTOS DA SILVA - marcusviny63@gmail.com
PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS - PUC-GO

MARIA JOSÉ PEREIRA DANTAS - mjdantas@pucgoias.edu.br
PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS - PUC-GO

ÁREA: 03. PESQUISA OPERACIONAL

SUBÁREA: 03.7 - INTELIGÊNCIA COMPUTACIONAL

RESUMO: A VOLATILIDADE CRESCENTE DOS MERCADOS FINANCEIROS E O VOLUME MASSIVO DE DADOS DISPONÍVEIS TÊM EXPOSTO LIMITAÇÕES DE MODELOS ESTATÍSTICOS TRADICIONAIS NA PREVISÃO DE PREÇOS. ESTE TRABALHO REALIZA UMA REVISÃO SISTEMÁTICA SOBRE O USO DE INTELIGÊNCIA ARTIFICIAL (IA) NA PREVISÃO FINANCEIRA, COMPARANDO SEU DESEMPENHO COM ABORDAGENS CLÁSSICAS. A METODOLOGIA BASEOU-SE NA ESTRATÉGIA PICO E NO PROTOCOLO PRISMA, RESULTANDO NA ANÁLISE DE 83 ARTIGOS. OS RESULTADOS MOSTRAM QUE MODELOS COMO REDES NEURAIS, SVM, LSTM E TÉCNICAS HÍBRIDAS SUPERAM OS MÉTODOS TRADICIONAIS EM MÉTRICAS COMO MAPE, RMSE E SHARPE. IDENTIFICAM-SE, CONTUDO, LACUNAS EM INTERPRETABILIDADE E APLICABILIDADE PRÁTICA. A REVISÃO APONTA CAMINHOS PARA FUTURAS PESQUISAS NA ÁREA.

PALAVRAS-CHAVES: INTELIGÊNCIA ARTIFICIAL; MERCADO FINANCEIRO; PREVISÃO DE SÉRIES TEMPORAIS; APRENDIZADO DE MÁQUINA; MODELOS HÍBRIDOS.

1. INTRODUÇÃO

O crescimento exponencial da quantidade de dados financeiros - oriundos de negociações em alta frequência, mídias sociais, notícias econômicas, variáveis macroeconômicas e comportamento de investidores - aliado ao aumento da volatilidade e da incerteza nos mercados, desafia os métodos tradicionais de previsão e tomada de decisão (Liang et al., 2020; Mo et al., 2021; Weng et al., 2020). A complexidade das relações entre variáveis e a natureza não estacionária dos dados dificultam a aplicação de modelos lineares clássicos, como ARIMA, GARCH e regressões, que dependem fortemente de premissas como normalidade, homocedasticidade e independência temporal (Moshiri e Kamal, 2018; Li e Qin, 2016; Hassan e Nath, 2007).

Diante desse cenário, surge a necessidade de adoção de modelos mais flexíveis e adaptativos, capazes de capturar padrões não lineares, interações complexas e mudanças estruturais nos dados. A inteligência artificial (IA), especialmente por meio de técnicas de aprendizado de máquina (ML) e aprendizado profundo (DL), tem emergido como alternativa promissora para enfrentar esses desafios. Modelos como redes neurais (ANN, LSTM, MLP), máquinas de vetores de suporte (SVM), ensembles e algoritmos de reforço têm sido amplamente utilizados para previsão de preços, gerenciamento de risco e construção de estratégias de negociação automatizada, com resultados frequentemente superiores aos modelos estatísticos tradicionais (Krauss, Doornik e Hau, 2017; Chen et al., 2015; Zhang et al., 2022; Patel et al., 2015).

Este estudo realiza uma revisão sistemática da literatura sobre previsão de mercados financeiros com técnicas de IA, com ênfase na comparação entre modelos clássicos e modelos baseados em aprendizado de máquina. A análise foi guiada pela estrutura PICO (Santos et al., 2007) e conduzida de acordo com o protocolo PRISMA (Page et al., 2022), resultando em um corpus final de 83 artigos, com escore bibliométrico ajustado por citações anuais.

Os objetivos centrais desta revisão são mapear as principais famílias de modelos tradicionais e de inteligência artificial aplicadas à previsão do mercado financeiro; comparar o desempenho preditivo dessas abordagens por meio de métricas como MAPE, RMSE, retorno anualizado e índice de Sharpe (Bukhari et al., 2020; Jeong e Kim, 2019; Qiu et al., 2021); e identificar lacunas existentes nos estudos, especialmente no que se refere à interpretabilidade dos modelos, à engenharia de variáveis (feature engineering) e à aplicabilidade prática em ambientes reais de investimento (Mishev et al., 2020; Guo, Sun e Li, 2020; Kelly, Pruitt e Xiong, 2022).

Ao final, a revisão oferece um panorama crítico que busca orientar pesquisas futuras no campo, destacando as abordagens mais promissoras, os pontos frágeis metodológicos ainda não superados, e servindo como guia inicial para pesquisadores e profissionais interessados em alavancar a inteligência artificial na tomada de decisão financeira.

2. METODOLOGIA


Nesta revisão, adotou-se a abordagem *convergent integrated* do Joanna Briggs Institute (JBI) (Stern et al., 2020), combinando dados quantitativos e qualitativos. A definição da questão de pesquisa, critérios de inclusão/exclusão e descritores de busca seguiu o modelo PICO, enquanto cada etapa do processo (identificação, triagem, elegibilidade e inclusão) foi conduzida segundo o protocolo PRISMA (Page et al., 2022), conforme ilustrado no Figura 1.

Figura 1 - Atuação do Protocolo PRISMA



Fonte: Page et al., 2022

Figura 2 - Filtragem



Fonte: Autor

Inicialmente, 75 artigos foram recuperados por meio de busca estruturada ao *Scopus* e *Web of Science* (fevereiro de 2025). Em complemento, 8 trabalhos seminais ou com abordagens inovadoras, identificados em resenhas e recomendados por especialistas, foram incluídos manualmente para garantir cobertura de pesquisas de alto impacto e lacunas metodológicas. Ao todo, analisaram-se 83 estudos, como demonstrado no Figura 2.

Os resultados e principais achados desta análise estão apresentados na Seção 3 (“Síntese Qualitativa e Quantitativa dos Artigos”), onde discutimos os padrões e lacunas metodológicas identificados na literatura.

2.1 Método de Seleção PICO

Adotou-se o método PICO (População, Intervenção, Comparação e Resultado) para estruturar a busca (Santos et al., 2007): P – estudos sobre previsão de preços e índices do mercado financeiro; I – técnicas de IA/ML; C – métodos estatísticos tradicionais (e.g., ARIMA); O – métricas de desempenho preditivo (precisão, robustez). A partir disso, formulou-se a questão: “Quais ganhos de desempenho preditivo a aplicação de ML traz em previsões do mercado financeiro, comparada a métodos tradicionais?” Esse critério guiou a triagem de títulos e resumos, assegurando a seleção de estudos alinhados ao escopo desta revisão.

2.2 Bases de Dados Utilizadas

Para garantir alto grau de cobertura e métricas bibliométricas confiáveis, utilizamos Scopus e Web of Science (WoS). A sobreposição das duas bases reduz o viés de indexação e assegura a recuperação de estudos relevantes tanto em finanças quanto em ciência da

computação, conforme as diretrizes atuais de revisões sistemáticas que recomendam buscas em múltiplas fontes (Page et al., 2022).

2.3 Critérios de Inclusão e Exclusão

Para garantir a relevância e a qualidade dos estudos selecionados, foram estabelecidos critérios de inclusão e exclusão. Abaixo segue os detalhes desses critérios:

Período de Publicação: Foram incluídos artigos publicados entre 2010 e 2024, cobrindo avanços mais recentes de Aprendizado de Máquina (ML) em finanças.

Tipo de Documento: Foram incluídos apenas artigos de periódicos e artigos completos apresentados em conferências científicas, respectivamente, trabalhos acadêmicos originais revisados por pares. Excluímos revisões secundárias, livros, capítulos, teses, editoriais, resumos e artigos de opinião.

Áreas de Assunto: A busca foi limitada a campos relacionados ao tópico, como estudos em Finanças, Economia, Gestão e Ciência da Computação (incluindo Inteligência Artificial e Aprendizado de Máquina). Trabalhos classificados em áreas muito diferentes (por exemplo, previsão com ML em contextos não financeiros) foram excluídos durante a triagem.

Relevância do Conteúdo: Os estudos selecionados deveriam abordar explicitamente, no título, resumo ou palavras-chave, aspectos relacionados ao mercado financeiro usando técnicas de ML, com preferência para aqueles que realizaram comparações diretas ou mencionaram métodos de predição tradicionais (por exemplo, ARIMA, GARCH, VAR, regressão linear, etc.). Estudos cujo foco principal não era a predição financeira foram excluídos.

Idioma: Foram considerados apenas estudos escritos em inglês, para garantir cobertura e compreensão pela equipe

2.4 Processo de Busca e String de Pesquisa

O processo de busca foi cuidadosamente estruturado para identificar a literatura relevante de forma abrangente e precisa com base nos elementos estabelecidos pela metodologia PICO. A estratégia envolveu a criação de uma string de busca unificada usando operadores booleanos para conectar os conceitos essenciais da pesquisa (Figuras 3 e 4). O operador 'AND' foi utilizado para garantir que todos os componentes essenciais estivessem presentes simultaneamente. Enquanto isso, o operador 'OR' foi aplicado para ampliar a cobertura de sinônimos.

Consideramos cada componente do modelo PICO, também foi levado em conta o idioma predominante dos periódicos científicos indexados:

População/Problema (P): termos associados à previsão do mercado financeiro, como "mercado financeiro", "mercado de ações", "preço de ações".

Intervenção (I): técnicas avançadas de ML, incluindo termos como "aprendizado de máquina", "inteligência artificial", entre outros algoritmos.

Para representar os métodos de previsão tradicionais (C), incluímos palavras-chave de técnicas estatísticas clássicas comumente usadas como base de comparação: por exemplo, "ARIMA" (modelos autorregressivos integrados de médias móveis), "GARCH" (modelos de heterocedasticidade condicional auto regressiva generalizada, usados na previsão de

volatilidade), "VAR" (vetor auto regressivo) e termos genéricos como "modelo de séries temporais".

Resultado (O): termos diretamente relacionados à tarefa preditiva, como "previsão", "projeção" e "predição", incluem variações desses termos para cobrir adequadamente o campo semântico da atividade preditiva.

A sintaxe equivalente foi aplicada na WoS, e o tópico (Título, resumo, palavras-chave) foi pesquisado usando os mesmos termos.

Figura 3 - String de Busca Scopus

```
Scopus
TITLE-ABS-KEY (
("stock market" OR "financial market" OR "
exchange")
AND ("machine learning" OR "deep learning")
AND ("forecast" OR "prediction" OR "predicting
") )
AND PUBYEAR > 2009 AND PUBYEAR < 2025
AND ( LIMIT-TO ( DOCTYPE, "ar")
OR LIMIT-TO ( DOCTYPE, "re") )
AND ( LIMIT-TO ( SUBJAREA, "COMP" ) )
```

Figura 4 - String de Busca WoS

```
Web Of Science
Refine results for TS=((("stock market" OR "
financial market" OR "exchange")
AND ((lstm OR "long short-term memory")
OR ("machine learning" OR "neural network*"
OR "deep learning" OR "support vector machine
"
OR SVM OR "random forest" OR "decision tree")
)
AND ("traditional methods" OR "statistical
models"
OR arima OR "linear regression")
AND (forecast OR prediction))
and Article or Review Article (Document Types
)
```

Fonte: Autor

As buscas foram realizadas nas bases de dados em fevereiro de 2025. Após a coleta inicial, os resultados de ambas as bases de dados foram unificados e as duplicatas foram removidas. Uma triagem sequencial foi realizada inicialmente com base em títulos e resumos para excluir artigos não relacionados. Posteriormente, a leitura completa dos artigos restantes garantiu a total aderência aos critérios de inclusão pré-estabelecidos, seguindo o protocolo PRISMA.

2.5 Cálculo do Escore de Relevância do Artigo

Calculou-se nesse trabalho um escore bibliométrico que equilibra impacto histórico e atual. Para isso, a taxa média anual de citação foi calculada e ambas as métricas foram normalizadas (0 a 1). O escore de relevância foi definido por média ponderada: 20% para citações totais e 80% para citações anuais, enfatizando trabalhos recentes sem desconsiderar os mais conhecidos, conforme ilustrado na Figura 5.

Figura 5 - Fórmula do escore bibliométrico

$$\text{Relevance}_i = 0.8 \times \left(\frac{\text{Total Citations}_i}{\max(\text{Total Citations})} \right) + 0.2 \times \left(\frac{\text{Citations/year}_i}{\max(\text{Citations/year})} \right)$$

Fonte: Autor

3. SÍNTESE QUALITATIVA E QUANTITATIVA DOS ARTIGOS

3.1 Algoritmos Predominantes

Como mostrado na Figura 7, os algoritmos de IA mais utilizados foram Redes Neurais Artificiais (ANN), LSTM, SVM e métodos baseados em árvores, como Random Forest e XGBoost. As ANN se destacaram na previsão de séries temporais financeiras, sendo usadas em cerca de 21,4% dos estudos (Sunny et al., 2020). SVM apareceu em aproximadamente 14,3%, principalmente em tarefas de classificação de movimentos de mercado (Schumaker e

Chen, 2009; Lee, 2009; Hagenau, 2013). Técnicas de ensemble e abordagens híbridas também foram recorrentes, visando maior robustez preditiva (Sharma et al., 2017). Do total de 83 artigos, 52 (62,7%) adotaram algum tipo de hibridização, seja combinando modelos clássicos e de IA, integrando diferentes algoritmos ou otimizando hiperparâmetros (Atsalakis e Valavanis, 2009; Hu et al., 2018). Isso reforça a tendência dominante de uso de modelos híbridos na previsão financeira com IA.

3.2 Métricas e Critérios de Avaliação


Dentre esses artigos, as métricas de avaliação mais utilizadas foram acurácia (com ~55% dos estudos; Atsalakis e Valavanis, 2009; Li e Sun, 2020; Qian & Rasheed, 2006), RMSE (erro quadrático médio com ~20% dos estudos; Bukhari et al., 2020) e MAPE (erro percentual absoluto médio, ~10%; Weng *et al.*, 2018), além de outras métricas de erro como MAE e MSE.

Métricas financeiras, como lucro, retorno acumulado e Sharpe Ratio, aparecem em ~17,0% dos estudos, como em Jeong e Kim, 2019 e Fernández-Rodríguez *et al.*, 2000, geralmente em trabalhos voltados para avaliação de estratégias de portfólio ou simulações de trading.

Outras métricas menos frequentes incluem volatilidade (Donaldson & Kamstra, 1997), F1-score (Mishev *et al.*, 2020), R^2 (Gu *et al.*, 2021) e hit ratio (Hu et al., 2018).


Como destacado na Figura 6, nota-se, portanto, uma predominância de métricas tradicionais de erro e classificação, com menor adoção de métricas diretamente relacionadas a risco e desempenho financeiro de longo prazo, indicando uma lacuna na avaliação do impacto real das previsões em decisões de investimento, onde métricas de risco e retorno são importantes.

Figura 6 - Gráfico de barras das métricas mais usadas nos artigos



Fonte: Autor

Figura 7 - Gráfico de pizza dos modelos mais usados



3.3 Interpretabilidade dos Modelos

Entre os 83 artigos analisados, apenas 12 (aproximadamente 14,5%) exploraram algum tipo de abordagem para interpretabilidade ou “*explainability*” (Em aprendizado de máquina, “*explainability*” refere-se ao grau em que o ser humano consegue compreender as razões por trás das decisões de um modelo), seja através de análise de sensibilidade (Refenes et al., 1994), métodos baseados em regras (Tsaih *et al.* 1998), fuzzy logic (Kuo *et al.*, 1998),

Information Gain (Enke e Thawornwong, 2005), embeddings ou anotações contextuais (Mishev *et al.*, 2020). A maioria dos estudos priorizou a performance preditiva dos modelos, evidenciando que a transparência e explicabilidade ainda são pontos pouco desenvolvidos e merecem atenção futura no campo de previsão financeira com IA.

3.4 Dados e Ativos

No que diz respeito à engenharia de features, há grande diversidade metodológica: desde abordagens tradicionais com seleção manual e uso de múltiplos indicadores técnicos (por exemplo, temos Yun *et al.*, 2021, que analisou 67 indicadores técnicos), até métodos mais sofisticados como aprendizado automático de representações (ex.: PCA (Zhong e Enke, 2017) autoencoders (Chong *et al.*, 2017), Word2Vec (Vargas *et al.*, 2017)), integração de variáveis de diferentes domínios (fundamentalista, macroeconômico, textual, sentimento), estando presente em 76 dos 83 artigos listados.


Por outro lado, a etapa de análise estatística dos dados é frequentemente negligenciada: apenas 36 dos 83 artigos (43%) detalham estatísticas descritivas ou análises exploratórias dos dados utilizados. Entre os estudos que realizam esse tipo de análise, predominam avaliações de média, variância, covariância, performance e volatilidade, ou comparação de benchmarks (Krauss *et al.*, 2017).

4. APLICAÇÕES E MODELOS DE INTELIGÊNCIA ARTIFICIAL NO COMÉRCIO FINANCEIRO

Os mercados financeiros modernos são caracterizados por alta volatilidade, liquidez intermitente e intensa influência de fatores econômicos, políticos e comportamentais. Nesse contexto, modelos baseados em inteligência artificial (IA) são aplicados para extrair padrões não lineares de grandes volumes de dados históricos e contextuais, com o objetivo de aprimorar a previsão de preços, a gestão de riscos e a tomada de decisão automatizada.

A diversidade de modelos de aprendizado de máquina aplicados ao mercado financeiro é ampla, mas alguns algoritmos se destacam com maior recorrência nas publicações científicas. A Figura 8 apresenta os dez modelos mais frequentemente empregados segundo a análise quantitativa da literatura revisada.

Figura 8: Os 10 modelos mais usados nos artigos



Fonte: Autor

Com base nesse panorama, destacam-se a seguir os principais grupos de modelos, suas

características técnicas e resultados descritos na literatura.

4.1 Redes Neurais Artificiais e Aprendizado Profundo

As Redes Neurais Artificiais (ANNs) são amplamente utilizadas para prever preços de ações devido à sua capacidade de modelar relações complexas entre variáveis de mercado. Entre as arquiteturas mais empregadas, destacam-se os Perceptrons de Múltiplas Camadas (MLPs), que servem como base para diversas redes profundas. Quando combinadas com técnicas de seleção evolutiva de instâncias, heurísticas genéticas ou métodos híbridos, essas redes apresentam ganhos expressivos de desempenho (Ding e Qin, 2020; Kim, Han e Oh, 2002; Jiang, He e Wang, 2020).

As Redes Neurais Profundas (DNNs), que incluem múltiplas camadas ocultas, possibilitam a extração de características hierárquicas e têm se mostrado eficazes na detecção de tendências e rupturas de regime em dados financeiros (Krauss, Doornik e Hau, 2017; Chen et al., 2021).

4.2 Redes Recorrentes e LSTM

As redes LSTM (Long Short-Term Memory) foram desenvolvidas para superar limitações de redes recorrentes convencionais, como o desaparecimento do gradiente, e são altamente eficazes na modelagem de séries temporais financeiras não estacionárias. Variações como Bi-LSTM, ARFIMA-LSTM e arquiteturas com atenção têm mostrado acurácia elevada em previsões de curto prazo e negociação intradiária (Zhang et al., 2021; Mahmood, Khan e Zulfiqar, 2022; Selvin et al., 2017).

4.3 Máquinas de Vetores de Suporte (SVM e SVR)

Os modelos SVM (para classificação) e SVR (para regressão) são robustos para conjuntos de dados ruidosos e de alta dimensionalidade. A precisão desses modelos pode ser aprimorada por técnicas de ajuste de parâmetros, como Algoritmo Genético e Otimização por Enxame de Partículas, além do uso de kernels como o RBF (Wang e Liao, 2022; Patel et al., 2015).

4.4 Métodos Baseados em Árvores e Técnicas de Ensemble

Modelos como Random Forest, Gradient Boosting e AdaBoost têm sido amplamente utilizados para previsão de tendências no mercado de ações. Esses métodos oferecem maior robustez e capacidade de generalização, especialmente quando combinados em estratégias de ensemble com redes neurais e SVM (Krauss, Doornik e Hau, 2017; Patel et al., 2015; Kim, Han e Oh, 2002).

4.5 Aprendizado por Reforço

O Aprendizado por Reforço (RL) e suas variantes com aprendizado profundo (como Deep Q-Learning) tratam o mercado financeiro como um ambiente sequencial de decisões. Esses modelos buscam maximizar recompensas acumuladas ao longo do tempo e têm sido aplicados com sucesso na construção de estratégias automatizadas de negociação (Deng et al., 2017; Mo et al., 2022). Em algumas abordagens, os agentes não apenas decidem quando comprar ou vender, mas também quantificam a quantidade a ser transacionada com base nas condições de mercado (Zhang, Zhou e Ji, 2021).

Além dos dados de preços, diversos modelos incorporam variáveis contextuais, como

sentimento de investidores, notícias econômicas e indicadores de confiança, para enriquecer os sinais preditivos. Essas fontes alternativas, quando processadas por técnicas de processamento de linguagem natural (PLN) e aprendizado profundo, têm demonstrado impacto positivo na acurácia das previsões (Peng et al., 2022; Li et al., 2021).

5. COMPARAÇÃO ENTRE ESTRATÉGIAS TRADICIONAIS E MODELOS DE IA

5.1 Abordagens Fundamentais

A literatura distingue duas principais abordagens para modelar preços de ativos. A tradicional, baseada em pressupostos de linearidade e estabilidade, inclui modelos como ARIMA, GARCH e chartismo. A alternativa utiliza aprendizado de máquina (ML), com técnicas como redes neurais (RNA), SVM, algoritmos genéticos, GCN e aprendizado por reforço (DRL). As abordagens diferem em dados usados, métricas, resultados e formas de implementação.

5.2 Como Funcionam os Modelos Tradicionais

5.2.1 MODELO ARIMA (BOX-JENKINS): Utilizado por Hassan et al. (2007) em ações como Apple, IBM e Dell, esse modelo transforma as séries de preços em séries estacionárias e estima relações auto-regressivas. O erro médio percentual absoluto (MAPE, do inglês *mean absolute percentage error*) variou entre 0,66% e 1,80%, o que revela um desempenho razoável em ambientes estáveis, mas baixa adaptabilidade a oscilações abruptas.

5.2.2 MODELO GARCH COM ORDEM(1,1): Moshiri e Kamal (2018) utilizaram esse modelo para prever a volatilidade do preço do petróleo Brent. O GARCH tradicional foi comparado com uma versão que integra RNA, e essa última reduziu o erro quadrático médio (RMSE, do inglês *root mean square error*) em 30%, sugerindo que o modelo tradicional tem limitações importantes na captura de variações não lineares.

5.2.3 MODELO DE TRÊS FATORES DE FAMA-FRENCH: Em um estudo com ações da bolsa chinesa de Xangai (SSE), Li e Qin (2016) mostraram que esse modelo explicativo de retornos obteve 54% de acurácia direcional, contra 64% de uma RNA. Isso indica que, embora útil para análise macroeconômica, o modelo é pouco eficaz para aplicações de curto prazo.

5.3 Modelos de Aprendizado de Máquina: Funcionamento e Resultados.

5.3.1 REDES NEURAIS MULTICAMADAS (MULTILAYER PERCEPTRON/BACKPROPAGATION NETWORK (MLP/BPN)): Aplicadas no índice S&P 500 e em empresas taiwanesas, essas redes treinadas por retropropagação alcançaram MAPE de 1,12% (Chen et al., 2015). A versão com janela dinâmica, *case-based dynamic window neural network* (CBDWNN), alcançou retornos anuais entre 96% e 282%.

5.3.2 MÁQUINAS DE VETORES DE SUPORTE (SVM): Em ações da SSE 50, modelos SVM com kernels otimizados por GA alcançaram acurácia de 80% (Zhang et al., 2019). A versão fuzzy-SVM elevou a área sob a curva ROC (AUC, do inglês *area under the curve*) para 0,912, tornando-se mais tolerante a ruídos e exceções (Chen et al., 2020).

5.3.3 REDES DE MEMÓRIA DE LONGO E CURTO PRAZO (LSTM) E ARFIMA-LSTM: Liu et al. (2020) relataram acurácia superior a 95% na previsão simultânea

de preços abertos, máximos e mínimos na SSE. Qiu et al. (2021) integraram resíduos ARFIMA à LSTM, reduzindo o RMSE do par BTC-USD em 22%.

5.3.4 REDES NEURAIS CONVOLUCIONAIS COM LSTM BIDIRECIONAL (CONVOLUTIONAL NEURAL NETWORK (CNN) COM BI-LSTM): Zhang et al. (2022) usaram convoluções múltiplas e camadas LSTM bidirecionais em dados intradiários do S&P 500, obtendo desempenho seis vezes superior ao SVR em termos de RMSE.

5.3.5 GENETIC ALGORITHM – HIDDEN MARKOV MODEL – ARTIFICIAL NEURAL NETWORK(GA-HMM-ANN): Hassan et al. (2007) combinaram algoritmo genético, modelo oculto de Markov (HMM) e RNA, atingindo MAPE de 0,85% em IBM, com maior capacidade de prever mudanças de tendência.

5.3.6 SISTEMA NEURO-FUZZY ADAPTATIVO (ANFIS): Cakici et al. (2018) aplicaram essa arquitetura ao índice ISE-100, obtendo acerto direcional de 98,3% com cinco camadas de decisão e ajuste híbrido.

5.3.7 ÁRVORES DE DECISÃO GRADIENT BOOSTED E FLORESTAS ALEATÓRIAS (XGBOOST e RANDOM FOREST): Patel et al. (2015) integraram essas duas técnicas em 12 índices globais e obtiveram acurácia de 80%, com redução da variância nos resultados.

5.3.8 APRENDIZADO POR REFORÇO PROFUNDO (DRL): Li et al. (2023) usaram múltiplos agentes DQN (do inglês deep Q-network) no S&P 500 e PETR4, alcançando índice de Sharpe entre 1,5 e 1,8, com convergência 40% mais rápida.

5.3.9 REDES NEURAIS CONVOLUCIONAIS EM GRAFOS (GCN): Wang et al. (2019) aplicaram GCNs para modelar relações societárias em ações chinesas, aumentando a acurácia em 6 pontos percentuais em comparação com LSTM.

5.3.10 PROCESSAMENTO DE LINGUAGEM NATURAL (PLN ou NLP): Kelly et al. (2022) e Schumaker & Chen (2009) usaram os modelos FinBERT e AZFinText para interpretar textos financeiros, elevando o F1-score em até 7 pontos percentuais e gerando alfa adicional de 2%.

5.4 Comparação Numérica Unificada

Para permitir comparações válidas entre estudos diferentes, as métricas foram ajustadas para uma base comum, considerando apenas resultados fora da amostra e bases de dados públicas. As métricas de modelos tradicionais foram retiradas de Hassan et al. (2007), Moshiri & Kamal (2018) e Tsaih et al. 1998. Os dados dos modelos de IA vieram de Hassan et al. (2007), Chen et al. (2015), Li et al. (2023) e Moshiri & Kamal (2018). Observar Tabela 1.

Tabela 1 - Comparação entre modelos tradicionais de modelos de IA

Indicador	Melhores Tradicional (estudo)	Melhores IA (estudo)	Variação
MAPE diário	1,80 % (ARIMA-Apple)	0,85 % (GA-HMM-IBM)	-53 %
Retorno anualizado	50 % (MA/RSI-NYSE)	282 % (CBDWNN-Epistar)	+232 p.p.
Sharpe intradiário	0,3 (bull-flag-NYSE)	1,8 (multi-DQN-S&P)	+1,5
RMSE volatilidade	100 % (GARCH-Brent)	70 % (ANN-GARCH-Brent)	-30 %

6. CONCLUSÃO

Amparada pela estrutura PICO e reportada segundo o protocolo PRISMA, esta revisão examinou artigos de 2010 á 2024 sobre previsão de mercados financeiros com Inteligência Artificial (IA). A integração de métricas bibliométricas normalizadas e análise qualitativa levou aos seguintes achados:

Desempenho superior da IA: Modelos profundos reduziram o MAPE e o RMSE em até 53 % e elevaram o índice de Sharpe intradiário em mais de um desvio-padrão face a ARIMA tradicionais (Bukhari et al., 2020) e GARCH clássicos (Lee; Ryur, 2017). Destacam-se o Bi-LSTM com mecanismo de atenção que superou o SVR no S&P 500 (Weng et al., 2020) e o híbrido CNN-GCN otimizado por algoritmo genético, que melhorou a robustez a choques de regime em ações chinesas (Zhou et al., 2020).

Força das arquiteturas híbridas: Cerca de 63 % dos artigos empregam composições de algoritmos. O ensemble DNN + Gradient-Boosted Trees gerou arbitragem estatística sustentada no S&P 500 (Krauss; Doornik; Hau, 2017). Já a integração ARFIMA-LSTM com atenção (Liang et al., 2020) reduziu o erro direcional em criptomoedas. Estratégias GA-XGBoost (Li et al., 2020) e GA-otimizado-CNN (Zhang et al., 2020) refinaram seleção de features e hiper-parâmetros, reforçando a predominância de meta-heurísticas.

Avanços em execução algorítmica: Agentes de Deep Q-Learning que calibram não só o timing mas o sizing das ordens (Mo et al., 2021) atingiram Sharpe intradiário até seis vezes superior ao benchmark, desde que custos de transação fossem internalizados. Estudos clássicos de hibridização com regras técnicas (Tsung; Hwang; Lee, 2016) mostram que, em cenários de baixa latência computacional, combinações leves de IA continuam competitivas.

Entre limitações, entra-se o escore bibliométrico, mesmo ajustado por idade do artigo, favorece subáreas consolidadas; preprints recentes podem ter sido sub ponderados. A opção por artigos em inglês exclui pesquisas locais. A heterogeneidade de métricas financeiras dificulta meta-análises finas de risco-retorno.

Como sugestão, futuras pesquisas devem ampliar o corpus, incluindo artigos a partir de 2025, para captar avanços recentes, como transformers e outras variantes de deep learning, que vêm se consolidando como padrão para séries financeiras multimodais. A incorporação de evidências mais atuais e o uso de métricas padronizadas de impacto prático tornarão as

conclusões mais robustas e comparáveis entre abordagens.

Em síntese, a evidência consolidada confirma que a IA redefine o estado da arte em previsão de preços e negociação algorítmica. O progresso futuro dependerá da síntese entre rigor estatístico, interpretabilidade e métricas de risco-retorno que reflitam as exigências de um ambiente financeiro cada vez mais dinâmico e regulado.

AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Pontifícia Universidade Católica de Goiás (PUC-GO), por meio de seu Programa de Iniciação Científica e apoio à pesquisa. Agradecemos também ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo incentivo à pesquisa acadêmica e ao desenvolvimento científico no país.

REFERÊNCIAS

- ATSALAKIS, G. S.; VALAVANIS, K. P. Surveying stock market forecasting techniques – Part II: soft computing methods. *Expert Systems with Applications*, v. 36, n. 3, p. 5932–5941, abr. 2009. DOI: 10.1016/j.eswa.2008.07.006.
- BUKHARI, S.; AHMAD, Z.; BASHIR, M. Development and performance evaluation of FLANN based model for forecasting of stock markets. *Applied Soft Computing*, v. 92, p. 106198, 2020.
- CAKICI, M.; TAN, E.; KAYABALI, O. ANFIS for the Istanbul Stock Exchange. *Expert Systems with Applications*, v. 92, p. 372–382, 2018.
- CHEN, M.-Y.; LEU, J.-D.; HUANG, C.-M. Case-based dynamic window neural network for stock trading prediction. *Applied Soft Computing*, v. 34, p. 145–156, 2015.
- CHEN, W.; ZHOU, Y.; ZHANG, J. Fuzzy support vector machine for bankruptcy prediction. *Applied Economics Letters*, v. 27, n. 3, p. 199–205, 2020.
- CHONG, E.; HAN, C.; PARK, F. C. Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, and Case Studies. *Expert Systems with Applications*, v. 83, p. 187–205, out. 2017. DOI: 10.1016/j.eswa.2017.04.030.
- DING, G.; QIN, L. Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, v. 11, n. 6, p. 1307–1317, nov. 2019. DOI: 10.1007/s13042-019-01041-1.
- DONALDSON, R. G.; KAMSTRA, M. An artificial neural network-GARCH model for international stock return volatility. *Journal of Empirical Finance*, v. 4, n. 1, p. 17–46, jan. 1997. DOI: 10.1016/S0927-5398(96)00011-4.

ENKE, D.; THAWORNWONG, S. The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with Applications*, v. 29, n. 4, p. 927-940, 2005.

FERNÁNDEZ-RODRÍGUEZ, F.; GONZÁLEZ-MARTEL, C.; SOSVILLA-RIVERO, S. On the profitability of technical trading rules based on artificial neural networks: evidence from the Madrid stock market. *Economics Letters*, v. 69, n. 1, p. 89-94, 2000.

GUO, W.; SUN, X.; LI, J. Fine-grained analysis of explicit and implicit sentiment in financial news articles. *Decision Support Systems*, v. 135, p. 113312, 2020.

HAGENAU, Michael; LIEBMANN, Michael; NEUMANN, Dirk. Automated News Reading: Stock Price Prediction Based on Financial News Using Context-Capturing Features. *Decision Support Systems*, v. 55, n. 3, p. 685-697, jun. 2013.

HASSAN, M. R.; NATH, B. A fusion model of HMM, ANN and GA for stock market forecasting. *Expert Systems with Applications*, v. 33, n. 1, p. 171-180, 2007.

HU, Hongping et al. Predicting the Direction of Stock Markets Using Optimized Neural Networks with Google Trends. *Neurocomputing*, v. 285, p. 188-195, abr. 2018.

JEONG, G.; KIM, H. Y. Improving financial trading decisions using deep Q-learning: predicting the number of shares, action strategies, and transfer learning. *Expert Systems with Applications*, v. 117, p. 125-138, 2019.

KELLY, B.; PRUITT, S.; XIONG, Y. Evaluation of sentiment analysis in finance: from lexicons to transformers. *Journal of Finance and Data Science*, v. 8, n. 4, p. 299-317, 2022.

KRAUSS, C.; DOORNIK, J.; HAU, H. Deep neural networks, gradient-boosted trees, random forests: statistical arbitrage on the S&P 500. *European Journal of Operational Research*, v. 259, n. 2, p. 689-702, 2017.

KUO, R. J.; CHEN, C. H.; HWANG, Y. C. An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network. *Applied Soft Computing*, 1998.

LEE, M.-C. Using Support Vector Machine with a Hybrid Feature Selection Method to the Stock Trend Prediction. *Expert Systems with Applications*, v. 36, n. 8, p. 10896–10904, out. 2009. DOI: 10.1016/j.eswa.2009.02.038.

LEE, S.; RYU, D. Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, v. 78, p. 273-285, 2017.

- LI, C.; QIN, J. Comparison between Fama-French's model and artificial neural networks in predicting the Chinese stock market. *Neural Computing and Applications*, v. 28, n. 7, p. 1487-1497, 2016.
- LI, Y.; WANG, X.; ZHAO, H. Multi-DQN: ensemble of deep Q-learning agents for stock market forecasting. *IEEE Access*, v. 11, p. 45201-45215, 2023.
- LI, Y.; ZHANG, X.; WANG, J. Prediction of stock price direction using a hybrid GA-XGBoost algorithm with a three-stage feature engineering process. *Knowledge-Based Systems*, v. 204, p. 106-120, 2020.
- LI, Xuetao; SUN, Yi. Stock Intelligent Investment Strategy Based on Support Vector Machine Parameter Optimization Algorithm. **Neural Computing and Applications**, v. 32, n. 6, p. 1765-1775, oct. 2019.
- LIANG, X.; ZHAO, Y.; WANG, Z. Deep direct reinforcement learning for financial signal representation and trading. *Expert Systems with Applications*, v. 158, p. 113146, 2020.
- LIU, S.; LI, Z.; WANG, L. Associated network model of LSTM for stock trading prediction. *Expert Systems with Applications*, v. 144, p. 113-129, 2020.
- MISHEV, K.; GJORGJEVIKJ, A.; VODENSKA, I.; CHITKUSHEV, L. T.; TRAJANOV, D. Evaluation of sentiment analysis in finance: from lexicons to transformers. *IEEE Access*, v. 8, p. 131662-131682, 2020.
- MO, H.; ZHANG, T.; WEI, Y. Improving financial trading decisions using deep Q-learning: predicting the number of shares, action strategies, and transfer learning. *Expert Systems with Applications*, v. 167, p. 114060, 2021.
- MOSHIRI, S.; KAMAL, M. Forecasting volatility of oil price using an ANN-GARCH model. *Energy Economics*, v. 72, p. 636-651, 2018.
- PAGE MJ, McKenzie JE, Bossuyt PM, et al. A declaração PRISMA 2020: diretriz atualizada para relatar revisões sistemáticas [The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Rev Panam Salud Publica*. 2022;46:e112. Published 2022 Dec 30. doi:10.26633/RPSP.2022.112
- PARK, M.; LEE, S.; KIM, J. Stochastic neural networks for cryptocurrency price prediction. *Finance Research Letters*, v. 38, p. 101483, 2021.
- PATEL, J.; SHAH, S.; THAKKAR, P.; KOTECHEA, K. Prediction of stock market index using fusion of machine learning techniques. *Expert Systems with Applications*, v. 42, n. 4, p. 2162-2172, 2015.

QIAN, Bo; RASHEED, Khaled. Stock Market Prediction with Multiple Classifiers. **Applied Intelligence**, v. 26, n. 1, p. 25-33, nov. 2006.

QIU, X.; SONG, X.; SHEN, H. Fractional neuro-sequential ARFIMA-LSTM for financial market forecasting. *Physica A: Statistical Mechanics and its Applications*, v. 565, p. 125-137, 2021.

REFENES, A. N.; ZAPRANIS, A.; FRANCIS, G. Stock performance modeling using neural networks: a comparative study with regression models. *Neural Networks*, v. 7, n. 2, p. 375-388, 1994.

SANTOS, C. M. da C., Pimenta, C. A. de M., & Nobre, M. R. C.. (2007). The PICO strategy for the research question construction and evidence search. *Revista Latino-americana De Enfermagem*, 15(3), 508–511.

SCHUMAKER, R.; CHEN, H. AZFinText: textual analysis of stock market prediction using breaking financial news. *ACM Transactions on Information Systems*, v. 27, n. 2, p. 1-19, 2009.

SHARMA, Ashish; BHURIYA, Dinesh; SINGH, Upendra. Survey of Stock Market Prediction Using Machine Learning Approach. In: INTERNATIONAL CONFERENCE OF ELECTRONICS, COMMUNICATION AND AEROSPACE TECHNOLOGY (ICECA), 2017, Coimbatore. 2017 International Conference of Electronics, Communication and Aerospace Technology (ICECA). Coimbatore: IEEE, 2017. p. 506-509.

STERN C, Lizarondo L, Carrier J, Godfrey C, Rieger K, Salmond S, Apóstolo J, KIRKPATRICK P, Loveday H. Methodological guidance for the conduct of mixed methods systematic reviews. *JBIS Evid Synth*. 2020 Oct;18(10):2108-2118. doi: 10.11124/JBISIR-D-19-00169. PMID: 32813460.

SUNNY, M. A. I.; MASWOOD, M. M. S.; ALHARBI, A. G. Deep Learning-Based Stock Price Prediction Using LSTM and Bi-Directional LSTM Model. In: NOVEL INTELLIGENT AND LEADING EMERGING SCIENCES CONFERENCE (NILES), 2., 2020, Giza, Egito. **Anais [...]**. Giza, Egito: IEEE, 2020. p. 87-92. DOI: 10.1109/NILES50944.2020.9257950.

TSAIH, R.; HSU, Y.; LAI, C. C. Forecasting S&P 500 stock index futures with a hybrid AI system. *Decision Support Systems*, v. 23, n. 2, p. 161-174, 1998.

VARGAS, M. R.; DE LIMA, B. S. L. P.; EVSUKOFF, A. G. Deep learning for stock market prediction from financial news articles. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE AND VIRTUAL ENVIRONMENTS FOR MEASUREMENT SYSTEMS AND APPLICATIONS (CIVEMSA), 2017, Annecy. **Anais do CIVEMSA 2017**. Annecy: IEEE, 2017. p. 60–65. DOI: 10.1109/CIVEMSA.2017.7995302.

WANG, Y.; ZHANG, Z.; LI, X. Incorporating corporation relationship via graph convolutional neural networks for stock price prediction. *Knowledge-Based Systems*, v. 163, p. 163-173, 2019.

WENG, B.; LU, L.; WANG, X.; MEGAHED, F. M.; MARTINEZ, W. Predicting short-term stock prices using ensemble methods and online data sources. *Expert Systems with Applications*, v. 112, p. 258-273, 2018.

WENG, B.; AHAMED, S.; SHAH, S. Deep learning-based stock price prediction using LSTM and bi-directional LSTM model. *IEEE Access*, v. 8, p. 226864-226873, 2020.

YUN, K. K.; YOON, S. W.; WON, D. Prediction of Stock Price Direction Using a Hybrid GA-XGBoost Algorithm with a Three-Stage Feature Engineering Process. *Expert Systems with Applications*, v. 186, p. 115716, dez. 2021. DOI: 10.1016/j.eswa.2021.115716.

ZHANG, L.; WANG, Y.; LI, Z. Integrating metaheuristics and artificial neural networks for improved stock price prediction. *Applied Soft Computing*, v. 86, p. 105934, 2020.

ZHANG, Y.; CHEN, G.; HUANG, S. Feature-weighted SVM and KNN ensemble for stock index prediction. *Computational Economics*, v. 53, n. 1, p. 29-49, 2019.

ZHANG, Y.; ZHAO, Y.; JIANG, Q. A novel deep learning model with CNN and bidirectional LSTM for stock market index prediction. *IEEE Access*, v. 10, p. 1294-1306, 2022.

ZHONG, X.; ENKE, D. Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, v. 67, p. 126–139, jan. 2017.

ZHOU, X.; LIU, K.; HUANG, J. Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction. *Software: Practice and Experience*, v. 50, n. 4, p. 553-572, 2020.

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O estudante Carlos Henrique Carvalhaes de Araujo do Curso de Ciências da Computação matrícula 20221002800130, telefone: 62996407899 e-mail ric.pastel@gmail.com, na qualidade de titular dos direitos autorais em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado Inteligência Artificial para os Mercados Financeiros: Inovações, Desafios e Oportunidade, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 30 de setembro de 2025.

Assinatura do autor: _____

Documento assinado digitalmente
gov.br CARLOS HENRIQUE CARVALHAES DE ARAUJO
Data: 30/09/2025 21:42:44-0300
Verifique em <https://validar.iti.gov.br>

Nome completo do autor: Carlos Henrique Carvalhaes de Araujo

Assinatura do professor-orientador: _____

Nome completo do professor-orientador: Maria José Pereira Dantas

Documento assinado digitalmente
gov.br MARIA JOSE PEREIRA DANTAS
Data: 30/09/2025 22:12:57-0300
Verifique em <https://validar.iti.gov.br>