

---

**INTELIGÊNCIA ARTIFICIAL E SUA APLICAÇÃO NA PREDIÇÃO DE  
COMPORTAMENTO DE ATIVOS FINANCEIROS**

**ARTIFICIAL INTELLIGENCE AND ITS APPLICATION IN PREDICTING THE  
BEHAVIOR OF FINANCIAL ASSETS**

Lucas Gabriel Vória Rocha<sup>1</sup>

Bruna Sozzo<sup>2</sup>

**RESUMO**

A inteligência artificial (IA) tem se mostrado uma ferramenta útil em várias áreas, incluindo o mercado financeiro. Com o aumento da disponibilidade de dados e a evolução dos modelos de aprendizado de máquina, há um crescente interesse em explorar como a IA pode ser aplicada para analisar padrões e tendências no mercado financeiro e nas ações. Nesse contexto, a questão de pesquisa que orienta este estudo é como a inteligência artificial pode ser usada para prever o comportamento das ações no mercado financeiro. Embora a IA tenha se mostrado promissora nessa área, ainda há preocupações sobre as previsões e a confiabilidade das previsões realizadas por seus modelos. Por esse motivo, o estudo revisa a literatura existente sobre o assunto, analisando um total de 104 artigos, bem como destaca a notável evolução na quantidade de publicações desde 2018, com um aumento significativo nos últimos três anos. Observou-se uma mudança de foco para estudos em mercados de países emergentes e uma preferência por prever índices de mercado em vez de outros ativos. A utilização de dados históricos e indicadores técnicos é predominante, mas há uma crescente tendência para a análise de sentimentos com Processamento de Linguagem Natural. Quanto aos algoritmos, Redes Neurais Artificiais (RNA) são comuns, seguidas pelo Support Vector Machine (SVM) e Algoritmos de Decisão de Floresta Aleatória (ADFA), representam 84% dos algoritmos utilizados nos estudos analisados. O estudo, também, destaca lacunas na pesquisa, especialmente na previsão de outros tipos de ativos, oferecendo oportunidades para futuras investigações. Em resumo, a revisão contribuiu para o entendimento das aplicações de IA na previsão de preços de ativos, identificando características, tendências e áreas inexploradas.

434

**Palavras-chave:** inteligência artificial; mercado financeiro; ações; previsão; modelos de aprendizado de máquina.

---

<sup>1</sup> Centro Universitário Filadélfia de Londrina - UniFil

<sup>2</sup> Centro Universitário Filadélfia de Londrina - UniFil

## ABSTRACT

Artificial intelligence (AI) has proven to be a valuable tool in various areas, including the financial market. With the increasing availability of data and the evolution of machine learning models, there is a growing interest in exploring how AI can be applied to analyze patterns and trends in the financial market and stocks. In this context, the research question guiding this study is how artificial intelligence can be used to predict the behavior of stocks in the financial market. Although AI has shown promise in this area, there are still concerns about the predictions and the reliability of forecasts made by its models. For this reason, the study reviews existing literature on the subject, analyzing a total of 104 articles, and highlights the notable increase in the number of publications since 2018, with a significant rise in the last three years. A shift in focus toward studies in emerging markets and a preference for predicting Market indices rather than other assets have been observed. The use of historical data and technical indicators is predominant, but there is a growing trend towards sentiment analysis with Natural Language Processing. Regarding algorithms, Artificial Neural Networks (ANN) are common, followed by Support Vector Machine (SVM) and Random Forest Decision Algorithms (RFDA), representing 84% of the algorithms used in the analyzed studies. The study also highlights research gaps, especially in predicting other types of assets, offering opportunities for future investigations. In summary, the review contributes to the understanding of AI applications in asset price prediction, identifying features, trends, and unexplored areas.

435

**Keywords:** artificial intelligence; financial market; stocks; prediction; machine learning models.

## INTRODUÇÃO

A predição de preços de ativos financeiros é um tema relevante em finanças, pois auxiliam os agentes econômicos a obterem lucros e se protegerem dos riscos que o mercado financeiro apresenta. Atualmente, existem diversos métodos para prever preços de ativos, que variam desde técnicas estatísticas generalizadas até as mais recentes técnicas de inteligência artificial (Ding; Qin, 2020). Esses métodos incluem a análise técnica, que faz uso de ferramentas como médias móveis, bandas de Bollinger e RSI (Relative strength index) para interpretar padrões e tendências nos dados de preços; a análise fundamentalista, que se baseia na avaliação de dados financeiros, como demonstrações contábeis e indicadores econômicos, para entender o valor intrínseco de um ativo; e modelos de séries temporais, como o ARIMA, que utiliza padrões passados em séries

temporais para prever futuros movimentos de preços, e o GARCH, que modela a volatilidade nas séries temporais financeiras.

Os modelos de IA vêm sendo cada vez mais utilizados para automatizar processos em diferentes setores, inclusive no mercado financeiro, devido principalmente sua capacidade de analisar grandes volumes de dados com acurácia e eficácia (OCDE, 2021).

Diversos estudos têm demonstrado que os modelos de IA têm alto desempenho em termos de poder preditivo e podem gerar bons retornos aos agentes econômicos apesar de, a anormalidade nos lucros, ir contra a hipótese dos mercados eficientes (HME), a qual sugere que os preços dos ativos refletem todas as informações disponíveis, de forma que não é teoricamente possível prever consistentemente movimentos de preços ou obter retornos atípicos no mercado financeiro. Essa teoria pressupõe que os investidores recebem e processam rapidamente todas as informações relevantes, tornando difícil explorar discrepâncias nos preços para ganhos extraordinários. No contexto da HME, os mercados são considerados eficientes, o que implica que os preços atuais refletem todas as informações passadas e presentes, eliminando oportunidades sistemáticas de lucro através da previsão de preços. (Fama, 1970).

436

Shynkevich *et al.* (2017), também destacam as diferenças entre os principais modelos utilizados, como Redes Neurais Artificiais, Árvores de Decisão e Florestas Aleatórias, k-Nearest Neighbors, Naïve Bayes e Support Vector Machine (Shynkevich *et al.*, 2017; Cao *et al.*, 2019; Ding; Qin, 2020).

O propósito deste estudo é conduzir uma análise minuciosa entre variados artigos e modelos de Inteligência Artificial (IA) empregados na previsão do comportamento de ativos financeiros. Esta análise abrangerá fatores como a origem geográfica do artigo, os modelos de previsão utilizados, os tipos de dados utilizados como entrada nos modelos, e as métricas de avaliação adotadas. Ao explorar detalhadamente esses aspectos, almejamos oferecer perspectivas valiosas para pesquisadores, profissionais e entusiastas do mercado financeiro. O nosso objetivo é enriquecer a compreensão e promover o uso apropriado dessas tecnologias, contribuindo significativamente para o avanço do conhecimento sobre a predição do comportamento de ativos financeiros.

O artigo se encontra organizado da seguinte maneira: apresentaremos uma visão geral sobre a aplicação de inteligência artificial na previsão de comportamento de ativos financeiros, destacando as principais abordagens e técnicas utilizadas atualmente. Em seguida, descreveremos as características dos modelos de IA mais relevantes para essa área. Na seção seguinte, abordaremos conceitos fundamentais sobre inteligência artificial em geral, como fluxogramas de processamento de dados, tipos de erros e métricas de avaliação de desempenho. Por fim, apresentaremos as expectativas deste trabalho em termos de contribuição para a compreensão dos modelos de IA na previsão de comportamento de ativos financeiros, bem como as possíveis direções futuras de pesquisa.

## **BASE TEÓRICA**

A previsão do comportamento de ativos financeiros é um campo de grande interesse e importância no mercado, já que as decisões tomadas pelos investidores podem ter impacto direto nos resultados das empresas e na economia como um todo. Com o avanço da tecnologia, a inteligência artificial tem se mostrado uma ferramenta cada vez mais promissora para a análise e previsão de comportamento de ativos financeiros.

Apesar disso, ainda há desafios a serem superados na utilização da IA na previsão do comportamento de ativos financeiros. Um dos principais desafios é a disponibilidade de dados confiáveis e de alta qualidade, já que a precisão da previsão depende diretamente da qualidade dos dados utilizados. Além disso, é importante lembrar que a previsão do comportamento de ativos financeiros não é uma tarefa fácil e que sempre haverá um grau de incerteza envolvido.

A volatilidade do preço dos ativos no mercado financeiro é influenciado por muitos fatores, como político, econômico e social, além daqueles baseados no mercado, como apontaram Ding e Qin (2020). Segundo esses autores, esses movimentos nos preços dos ativos ditam os retornos obtidos pelos investidores, que podem se beneficiar da previsão correta desses movimentos.

A complexidade da previsão dos movimentos do mercado pode estar coligada HME (Hipótese dos Mercados Eficientes). Para Fama (1970) um mercado

eficiente é aquele o qual reflete todas as informações disponíveis de forma rápida. Ele apontou que o mercado pode refletir essas informações com diferentes níveis de velocidade: fraca, semiforte e forte. As condições para a classificação de um mercado eficiente para Fama são utópicas e ideais, portanto, é possível encontrar retornos anormais a partir de potenciais ineficiências no comportamento dos ativos.

Nas últimas décadas, alguns pesquisadores propuseram modelos baseados em métodos estatísticos como ARIMA (Autoregressive Integrated Moving Average). Porém, os autores concluíram que esses modelos precisam de ajuda devido ao baixo desempenho ao lidar com uma grande quantidade de dados. Além disso, eles apontaram que esses modelos possuem vantagens quando o assunto é entender as dependências ocultas entre os dados (Rundo *et al.*, 2019).

Além de modelos estatísticos convencionais, começaram a surgir nos últimos anos modelos baseados em inteligência artificial para prever o comportamento de ativos financeiros. Dentre alguns modelos, os mais utilizados são: Artificial Neural Network (ANN), Decision Tree and Random Forests, Knearest Neighbors (KNN), Naive Bayes (NB) e Support Vector Machine (SVM). A subseção seguinte detalha os modelos mencionados.

438

### **Modelos para prever o comportamento de ativos**

Os ANNs, Artificial Neural Network, são inspirados por modelos abstratos de como o cérebro humano se organiza, de acordo com Lorena *et al.* (2021). Esses autores explicam que as redes consistem em unidades de processamento simples, que desempenham funções matemáticas para simular a atividade dos neurônios. Essas unidades podem estabelecer conexões com várias outras unidades, simulando sinapses, o que permite que as redes neurais artificiais resolvam problemas complexos. Os algoritmos que envolvem Árvore de Decisão, por sua vez, são métodos de aprendizado de máquina que utilizam uma estrutura em forma de árvore para representar decisões e suas possíveis consequências. Essas árvores consistem em nodos que representam testes sobre atributos dos dados, ramos que correspondem a diferentes resultados desses testes, e folhas que indicam as decisões finais ou saídas do modelo. As Árvores de Decisão são

amplamente empregadas em classificação e regressão, sendo conhecidas pela capacidade de interpretabilidade e simplicidade, além de serem eficazes na análise e tomada de decisões em diversos campos, incluindo ciência de dados e inteligência artificial, segundo Moon *et al.* (2018). Em cada etapa, uma variável é escolhida para dividir o conjunto de amostras de forma mais eficiente. Diferentes critérios de impureza ou divisão podem ser aplicados em árvores binárias.

É importante ressaltar que o algoritmo de floresta aleatória representa um avanço em relação às árvores de decisão, ao combinar várias árvores para determinar o resultado, reduzindo assim a variabilidade do modelo (Vijh *et al.*, 2020).

O algoritmo KNN, como ressaltado por Moon *et al.* (2018), determina o rótulo de classe do novo ponto de dados ao realizar uma contagem de votos entre seus k vizinhos mais próximos. Os vizinhos mais próximos são determinados pela métrica de distância escolhida. A eficácia do KNN pode ser influenciada pela estrutura local dos dados, além de exigir uma complexidade computacional maior para classificar novas amostras, o que aumenta linearmente com o número de amostras no conjunto de treinamento (Hand, 2001). O parâmetro k pode ser selecionado de acordo com as características dos dados e, em geral, valores maiores de k reduzem o impacto do ruído na classificação, embora também tornem os limites entre as classes menos distintos.

Segundo Lorena *et al.* (2021), o algoritmo NB (Naive Bayes) calcula todas as probabilidades (a priori e condicionais) dos dados de treinamento. Este método de classificação é baseado no teorema de Bayes e é notável por sua eficiência computacional e simplicidade. O Naive Bayes é utilizado em tarefas de classificação, onde estima as probabilidades de pertencimento a diferentes classes com base nas características observadas nos dados de treinamento. Embora assuma a independência condicional entre os atributos, o que pode nem sempre refletir completamente a realidade, essa abordagem permite uma implementação rápida e eficaz na prática, sendo aplicada em áreas como processamento de linguagem natural, filtragem de spam e categorização de documentos.

Por sua vez, Rundo *et al.* (2019) enfatizam que o algoritmo SVM (Support Vector Machine) é uma técnica de aprendizado de máquina utilizada para

classificação e regressão. Seu principal objetivo é encontrar um hiperplano no espaço multidimensional que maximize a margem entre diferentes classes, onde a margem é definida como a distância entre os exemplos de treinamento mais próximos de cada classe. O SVM é particularmente eficaz em situações de alta dimensionalidade, permitindo a separação ótima de dados complexos. Durante o treinamento, o SVM otimiza essa separação ao identificar os "vetores de suporte", que são exemplos de treinamento críticos na determinação da margem. Esses vetores de suporte são fundamentais para a construção do modelo, conferindo-lhe robustez e capacidade de generalização em dados não vistos.

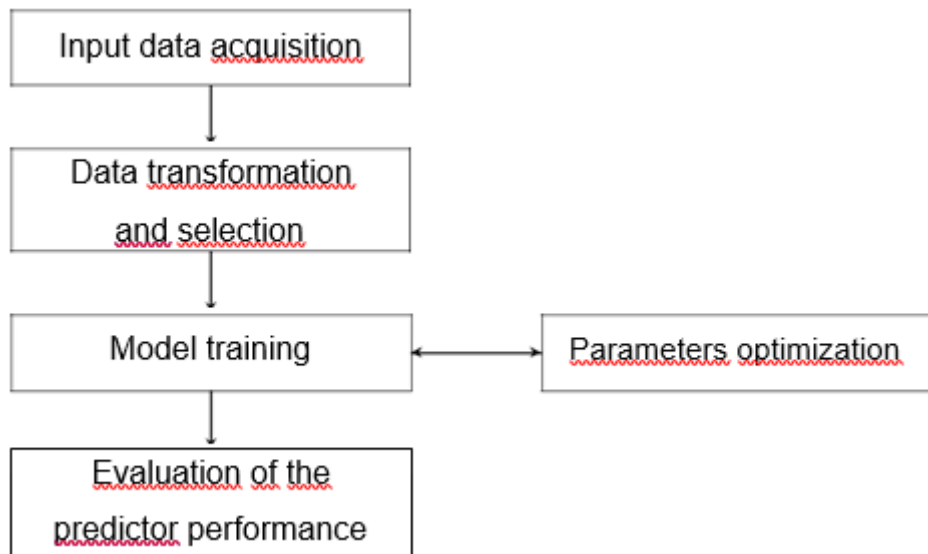
### **Modelos de inteligência artificial**

Independentemente do algoritmo de inteligência artificial empregado na previsão de preços de ativos, Ferreira, Gandomi e Cardoso (2021) ilustram um fluxograma que representa o processo geralmente seguido por estudos para essa finalidade.

440

No Fluxograma 1, os pesquisadores incluem cinco etapas principais no processo: (1) aquisição dos dados de entrada; (2) transformação e seleção dos dados; (3) treinamento do modelo; (4) otimização dos parâmetros; e (5) avaliação do desempenho do preditor. Existem diversos dados de entrada que geralmente são considerados em estudos que visam prever os preços de ativos no mercado financeiro. Esses dados incluem: (a) histórico de negociação - fechamento, abertura, preços máximo e mínimo - e volume de negociação (Chun; Ko, 2020; Gua *et al.*, 2020; Awan *et al.*, 2021); (b) indicadores de análise técnica (Rundo *et al.*, 2019); (c) indicadores financeiros (Janková; Jana, Dostál, 2021); (d) dados não estruturados para análise de comportamento, utilizando processamento de linguagem natural (Almehmadi, 2021; Awan *et al.*, 2021).

**Figura 1** - Processo de Estudos para Inteligência Artificial



**Fonte:** Fluxograma criado pelos autores, adaptado de Ferreira; Gandomi; Cardoso (2021).

Além disso, diferentes tipos de ativos são o foco da previsão de preços por meio de modelos de IA, como índices de mercado (Cavdar; Aydin, 2020; Ding; Qin, 2020; Shynkevich *et al.*, 2017), preços de ações (Colliri; Zhao, 2019; Awan *et al.*, 2021) e preços de outros ativos financeiros, como opções de compra e venda, os quais são ativos que conferem ao titular o direito, mas não a obrigação, de comprar ou vender um ativo a um preço acordado no futuro. (Sheu; Wei, 2011).

Após a seleção do algoritmo para prever os preços, é necessário treiná-lo com base nos dados coletados. Isso envolve o uso de dados relacionados às variáveis de entrada e aos preços estimados. A fase de treinamento utiliza, geralmente, 80% dos dados, enquanto os outros 20% é utilizado para teste (Hand, 2001; Moon; Jun; Kim, 2018; Shynkevich *et al.*, 2017). Também é importante otimizar os parâmetros de acordo com os modelos, como o parâmetro *k* no caso do KNN, kernels no caso do SVM e ajuste dos pesos no caso das RNA (Lorena *et al.*, 2021).

Por fim, são destacadas várias métricas de avaliação de desempenho dos modelos que podem ser utilizadas, tais como: Accuracy (ACU - Acurácia), Mean Square Error (MSE - erro quadrático médio), Root Mean Square Error (RMSE - raiz do erro quadrático médio), Mean Absolute Error (MAE - erro absoluto médio) e Mean Absolute Percentage Error (MAPE - erro percentual médio absoluto) (Ecer *et*



*al.*, 2020; Awan *et al.*, 2021; Vijn *et al.*, 2020). É importante observar que enquanto a métrica ACU é mais adequada para avaliar modelos destinados à classificação, as outras métricas são mais apropriadas para avaliar modelos voltados para análises de regressão (Lorena *et al.*, 2021).

## **METODOLOGIA**

A revisão de literatura, apresentada neste artigo, foi realizado no banco de dados Scopus. Chadegani *et al.* (2013) destacam a importância deste banco de dados para a comunidade científica. Eles enfatizam que a Web of Science poderia ser considerada a principal referência científica para diversas áreas até o lançamento do Scopus, o qual começou a competir diretamente com a primeira.

Para a seleção dos artigos, o bancos de dados foi consultado durante o mês de abril de 2023, usando um filtro booleano com os seguintes atributos: ["Aprendizado de Máquina" OU "Inteligência Artificial"] E ["mercado de ações" OU "retorno de ações" OU "preço das ações" OU "mercado de ações" OU "retorno de ações" OU "preço das ações"]. Inicialmente, 923 documentos foram encontrados. Em seguida, aplicamos filtros para selecionar apenas os artigos classificados como "artigos", resultando em 458 registros. Após essa seleção, todos os títulos e resumos foram analisados para verificar se os textos tratavam do uso de algoritmos na previsão de ativos financeiros (nosso foco de pesquisa). Dessa análise, 242 artigos foram selecionados.

Posteriormente, os artigos foram baixados e lidos na íntegra ou até que se apresentasse como um estudo fora do foco de pesquisa. Quando o texto completo não estava disponível em nossas fontes, realizamos uma busca direta no Google Scholar. No entanto, não conseguimos encontrar 71 artigos usando esses métodos, que foram então excluídos. No final, após a leitura completa dos artigos restantes, identificamos que 14 deles não se relacionavam com o foco de nossa pesquisa, dois eram duplicados e 51 tratavam de algoritmos de IA que careciam de uma base sólida devido à sua recenticidade ou outras razões relacionadas à maturidade da pesquisa nessa área, resultando em uma amostra final de 104 artigos.

Para apresentação e análise dos dados, aplicamos técnicas de estatística descritiva, incluindo o teste qui-quadrado de Pearson, a fim de avaliar associações estatisticamente significativas entre os diversos algoritmos de inteligência artificial examinados no estudo e as categorias adicionais desenvolvidas para a pesquisa. Foi adotado um nível de significância estatística de 10%, seguindo a abordagem de Maroco (2010).

## **DESENVOLVIMENTO**

Esta seção apresenta os resultados derivados da revisão sistemática da literatura. Três subseções compõem esta seção. Primeiro, a subseção seguinte destaca os resultados referentes às seguintes categorias: evolução temporal; região mundial; tipo de ativo previsto; dados usados para treinamento do algoritmo; e métricas para medir o desempenho do algoritmo. Em seguida, são apresentados os resultados relacionados a cada um dos algoritmos analisados: RNA, ADFA, KNN, NB e SVM. Finalmente, são discutidas as principais conclusões dos estudos analisados.

443

### **Análise Geral**


Uma análise abrangente dos estudos relacionados à previsão de mercado financeiro revela uma série de conclusões significativas que merecem uma análise mais detalhada e aprofundada.

### **Evolução Temporal**

Primeiramente, ao examinarmos a evolução temporal da pesquisa nesse campo, podemos observar um aumento notável na atenção dedicada por pesquisadores e estudantes ao tema ao longo dos anos. Essa tendência crescente é particularmente evidente quando analisamos a representação gráfica do número de artigos publicados em diferentes períodos.

**Figura 1** - Quantidade de Artigos por Ano

Quantidade de Artigos



Fonte: Diagrama criado pelos autores.

Ao longo das últimas décadas, a previsão de mercado financeiro tem se tornado um campo de estudo cada vez mais relevante, refletindo as complexidades e desafios que envolvem a tomada de decisões no mercado financeiro global. A crescente disponibilidade de dados, avanços tecnológicos e métodos estatísticos mais sofisticados têm contribuído para o aumento da pesquisa nessa área.

É crucial destacar que, ao analisarmos a distribuição dos artigos ao longo do tempo, uma parcela significativa, superior a 65%, dos artigos examinados foi publicada nos últimos 5 anos, ou seja, desde 2018. Esse dado sugere um foco considerável na pesquisa contemporânea e um interesse crescente em acompanhar as tendências e os desafios financeiros mais recentes. Essa concentração recente de publicações pode ser atribuída, em parte, à volatilidade dos mercados financeiros durante esse período, que trouxe à tona questões cruciais relacionadas à previsão de preços de ativos, gestão de riscos e estratégias de investimento.

Além disso, a análise dos estudos recentes revela um interesse renovado em abordagens multidisciplinares que integram conceitos da inteligência artificial,

aprendizado de máquina e análise de big data. A combinação dessas abordagens com a expertise financeira tradicional tem potencial para melhorar a precisão das previsões de mercado e a eficácia das estratégias de investimento.

Outro aspecto importante que emerge da análise desses estudos é a ênfase na busca de modelos de previsão mais robustos e capazes de lidar com situações de alta volatilidade, como as que ocorreram durante crises financeiras e eventos econômicos significativos. Pesquisadores estão explorando novas maneiras de incorporar variáveis macroeconômicas, eventos geopolíticos e fatores psicológicos na previsão de mercado, a fim de aprimorar a capacidade de antecipar movimentos de preços.

A análise dos estudos relacionados à previsão de mercado financeiro reflete não apenas a crescente importância desse campo, mas também a constante evolução das técnicas e abordagens utilizadas. Com um foco significativo na pesquisa contemporânea e uma ênfase na integração de métodos avançados, os pesquisadores estão preparados para enfrentar os desafios complexos apresentados pelos mercados financeiros em constante mudança. Essa busca contínua por conhecimento e aprimoramento é fundamental para auxiliar investidores, empresas e profissionais financeiros na tomada de decisões informadas e na gestão eficaz de seus ativos financeiros.

445

### **Origem Geográfica**

Ao analisar a origem geográfica dos estudos relacionados à previsão de mercado financeiro, é evidente que a maioria deles provém de países desenvolvidos. Esse padrão pode ser atribuído a uma série de fatores que merecem uma análise mais aprofundada e uma reflexão sobre suas implicações.

Primeiramente, a concentração de estudos em países desenvolvidos reflete a maturidade dos mercados financeiros nesses locais. Essa maturidade é resultado de décadas de crescimento econômico, estabilidade política e instituições financeiras sólidas. Como resultado, os mercados financeiros em países desenvolvidos oferecem um terreno fértil para a pesquisa, devido à disponibilidade abundante de dados históricos, regulamentações bem

estabelecidas e infraestrutura de suporte. Os pesquisadores podem confiar em dados precisos e consistentes, o que é essencial para a análise financeira e a construção de modelos de previsão confiáveis.

Além disso, a presença de instituições acadêmicas e centros de pesquisa de renome em países desenvolvidos desempenha um papel significativo na geração de estudos financeiros. Essas instituições têm acesso a financiamento substancial, bem como a professores e pesquisadores altamente qualificados, o que promove a produção de pesquisa de alta qualidade. A colaboração entre universidades, empresas e órgãos reguladores também é mais frequente em ambientes com infraestrutura sólida, promovendo o intercâmbio de conhecimento e a realização de estudos inovadores.

No entanto, é fundamental notar que a predominância de pesquisas em países desenvolvidos pode ter implicações importantes. Em primeiro lugar, isso pode criar um viés em relação às condições e características dos mercados financeiros desses países, o que pode não ser representativo de mercados em desenvolvimento ou emergentes. Muitas vezes, as dinâmicas financeiras e econômicas em países menos desenvolvidos são distintas e apresentam desafios únicos que merecem atenção.

Ademais, a falta de diversidade geográfica na origem dos estudos pode resultar em lacunas no entendimento dos mercados financeiros globais. Diferentes regiões do mundo enfrentam diferentes realidades econômicas e políticas, o que significa que a pesquisa exclusivamente centrada em países desenvolvidos pode não capturar adequadamente a diversidade de fatores que influenciam os mercados financeiros em escala global.

Para mitigar esse viés geográfico, é importante incentivar e apoiar a pesquisa em mercados financeiros de países em desenvolvimento e emergentes. A colaboração internacional e o compartilhamento de recursos e conhecimentos entre nações podem promover um entendimento mais holístico e equilibrado dos mercados financeiros em todo o mundo.

Embora a predominância de estudos originados em países desenvolvidos na pesquisa de mercado financeiro seja compreensível devido à maturidade de seus mercados, é vital reconhecer a importância de promover a pesquisa e a

colaboração em âmbito global para garantir que os insights e avanços na previsão de mercado financeiro sejam verdadeiramente abrangentes e aplicáveis a uma ampla gama de contextos econômicos.

### **Métodos de Previsão**

Outra descoberta de extrema relevância, no âmbito da análise dos estudos sobre previsão de mercado financeiro, diz respeito aos métodos de previsão mais amplamente utilizados. O exame detalhado desses métodos revela um panorama dinâmico e interessante que merece uma análise mais profunda, destacando as tendências e lacunas que permeiam esse campo de pesquisa.

É notável que a maioria dos artigos que compõem a literatura existente ainda se baseia em índices para suas projeções de mercado. Essa abordagem é compreensível, pois os índices de mercado representam uma maneira conveniente e amplamente aceita de resumir o desempenho do mercado como um todo. Além disso, esses índices costumam ser altamente líquidos e bem monitorados, tornando-os uma escolha prática para análises de curto prazo e previsões gerais do mercado.

No entanto, uma tendência notável que se destaca é o aumento da pesquisa que explora a previsão de ações individualmente. Essa mudança na abordagem indica um reconhecimento crescente da heterogeneidade dentro do mercado financeiro, com a compreensão de que diferentes empresas, setores e ativos podem responder a fatores econômicos e eventos de maneira distinta. Isso reflete a busca por modelos de previsão mais granulares e específicos que possam capturar nuances que os índices não conseguem. Essa diversificação nas abordagens de previsão é um desenvolvimento positivo, pois promove uma análise mais precisa e perspicaz dos mercados financeiros.

Porém, é importante observar que existe uma lacuna notável na literatura relacionada à previsão de outras classes de ativos, como derivativos. Enquanto os estudos sobre a previsão de ações e índices são relativamente abundantes, a mesma atenção não foi direcionada aos instrumentos derivativos, como futuros e opções. Esses produtos desempenham um papel fundamental nos mercados

financeiros, sendo usados para proteção de riscos, especulação e gestão de carteiras. A falta de pesquisas substanciais nessa área deixa um espaço significativo para pesquisas futuras que possam aprofundar nosso entendimento dos derivativos e seu impacto nos mercados.

É fundamental incentivar a expansão da pesquisa para incluir uma gama mais ampla de ativos financeiros e instrumentos, a fim de compreender melhor as interações complexas que ocorrem nos mercados. Além disso, a integração de abordagens interdisciplinares e a incorporação de novos métodos, como o uso de inteligência artificial e aprendizado de máquina, podem ampliar as possibilidades de previsão em diferentes classes de ativos.

As tendências na escolha de métodos de previsão no mercado financeiro indicam uma diversificação das abordagens, com um foco crescente na previsão de ações individuais. No entanto, as lacunas na pesquisa, particularmente em relação aos derivativos e outras classes de ativos menos exploradas, ressaltam a necessidade de investigações futuras para aprimorar nosso entendimento global dos mercados financeiros e fortalecer as bases para a tomada de decisões informadas e eficazes nesse campo complexo e em constante evolução.

448

### **Dados de Entrada**

Quando se trata dos tipos de dados de entrada utilizados na previsão de mercado financeiro, a análise revela padrões notáveis que podem fornecer insights adicionais sobre as tendências e as oportunidades de pesquisa nesse campo. A escolha dos dados de entrada desempenha um papel crucial na precisão e eficácia dos modelos de previsão, e essa é uma área que tem evoluído ao longo do tempo.

Em primeiro lugar, é evidente que os preços de abertura e fechamento, bem como os valores máximos e mínimos de ativos financeiros, são os tipos de dados mais amplamente empregados em estudos de previsão de mercado financeiro. Isso é compreensível, pois esses dados representam informações fundamentais sobre o desempenho histórico dos ativos e são amplamente disponíveis e fáceis de coletar. Os preços de abertura e fechamento, por exemplo, refletem o sentimento do mercado em relação ao ativo em questão no início e no

final de cada sessão de negociação, fornecendo informações importantes sobre a direção dos preços.

A média móvel é outra ferramenta amplamente utilizada na previsão de mercado financeiro. Esse indicador é útil para suavizar a volatilidade dos preços e identificar tendências de longo prazo, tornando-o valioso para investidores e analistas que buscam compreender o movimento geral do mercado.

No entanto, um desenvolvimento notável é o aumento no uso da análise de sentimento como um tipo de dado de entrada. A análise de sentimento envolve a avaliação de notícias, mídia social e outras fontes de informações não estruturadas para determinar o humor e a perspectiva dos investidores em relação a determinados ativos. Esse enfoque reconhece que os mercados financeiros são influenciados não apenas por dados quantitativos, mas também por fatores psicológicos e emocionais. O uso da análise de sentimento é uma resposta à crescente importância da psicologia do mercado e da compreensão das emoções dos investidores.

Por outro lado, observa-se que os indicadores fundamentalistas, que envolvem a análise dos fundamentos financeiros e econômicos das empresas, ainda são pouco explorados na previsão de mercado financeiro. Embora a análise fundamentalista seja amplamente utilizada por investidores de longo prazo e analistas financeiros, a aplicação de indicadores fundamentalistas em modelos de previsão de curto prazo é uma área que poderia ser considerada promissora para pesquisas futuras. A incorporação de indicadores fundamentalistas, como relatórios de lucros, balanços patrimoniais e indicadores econômicos, poderia enriquecer a base de dados utilizada na previsão e proporcionar uma compreensão mais completa das forças que influenciam os movimentos de preços.

A escolha dos tipos de dados de entrada na previsão de mercado financeiro evoluiu ao longo do tempo, com uma ênfase tradicional nos preços e médias móveis, mas também com um crescente interesse na análise de sentimento. No entanto, a subexploração dos indicadores fundamentalistas representa uma oportunidade empolgante para futuras pesquisas, que poderiam aprofundar nossa compreensão dos mercados financeiros e expandir as ferramentas disponíveis para os investidores e analistas.



## **Métricas de Avaliação**

Quando abordamos as métricas de avaliação de algoritmos na previsão de mercado financeiro, podemos notar uma evolução significativa na escolha e no uso dessas métricas ao longo do tempo. A seleção cuidadosa das métricas desempenha um papel crucial na avaliação da precisão e do desempenho dos modelos de previsão, e esse é um aspecto que merece uma análise mais aprofundada, destacando as tendências e as implicações dessa evolução.

Atualmente, entre as métricas mais comuns usadas na avaliação de algoritmos de previsão de mercado financeiro, duas se destacam: acurácia (ACU) e erro quadrático médio (RMSE).

A acurácia é uma métrica amplamente conhecida e usada em uma variedade de contextos de previsão (Hand, 2001). Ela mede a proporção de previsões corretas em relação ao total de previsões feitas. Embora seja uma métrica útil para avaliar a taxa de acerto de um modelo de previsão, é importante observar que, em alguns casos, a acurácia pode ser enganosa. Por exemplo, em um mercado financeiro onde a maioria dos movimentos de preços são de alta, um modelo que preveja apenas movimentos de alta pode atingir uma alta acurácia, mas não será necessariamente útil para investidores que buscam prever movimentos de baixa ou períodos de estagnação. Portanto, a interpretação da acurácia deve levar em consideração a distribuição dos dados e os objetivos específicos da previsão.

Já o erro quadrático médio (RMSE) é outra métrica comum e valiosa na avaliação de modelos de previsão. O RMSE mede a diferença média quadrática entre as previsões do modelo e os valores reais. Ele penaliza erros maiores de forma mais significativa do que erros menores, o que o torna particularmente útil na quantificação da qualidade das previsões. No entanto, o RMSE também tem suas limitações, uma das quais é que ele não fornece informações sobre a direção dos erros. Erros positivos e negativos são tratados da mesma forma, e isso pode ser insuficiente em certos contextos de mercado financeiro.

Essa diversificação na escolha de métricas de avaliação de algoritmos reflete o reconhecimento da complexidade dos mercados financeiros e a necessidade de métricas que se alinhem com os objetivos específicos de previsão. À medida que os modelos de previsão se tornam mais sofisticados e a compreensão das nuances do mercado cresce, é importante considerar métricas mais avançadas e personalizadas que possam refletir melhor o desempenho do modelo em situações financeiras específicas.

Além disso, é fundamental notar que a escolha das métricas de avaliação deve ser guiada pelos objetivos do investidor ou do analista. Por exemplo, um investidor que busca minimizar o risco pode preferir métricas que se concentrem na capacidade de prever movimentos de preços extremos, enquanto um investidor de longo prazo pode valorizar métricas que avaliem a estabilidade das previsões ao longo do tempo.


A evolução das métricas de avaliação de algoritmos na previsão de mercado financeiro reflete a busca contínua por métricas mais adequadas e personalizadas que possam capturar a complexidade e os objetivos específicos de previsão nesse campo dinâmico. A escolha criteriosa das métricas desempenha um papel fundamental na avaliação da eficácia dos modelos e na tomada de decisões informadas no mercado financeiro.

451

### **Análise dos Algoritmos de IA**

Nesta seção, apresentamos uma análise dos algoritmos empregados nos estudos examinados. Inicialmente, notamos que, em média, cada estudo incorpora aproximadamente 1,8 algoritmos em suas análises. Esse dado sugere uma preferência por abordagens multi-algorítmicas na previsão de preços, destacando a complexidade da tarefa.

**Figura 3** - Modelos de IA Mais Utilizados nos Artigos Analisados



Fonte: Diagrama criado pelos autores.

Entre os algoritmos, a RNA (Rede Neural Artificial) se destaca como a mais frequente, sendo adotada em 33,8% dos artigos analisados. A sua prevalência aponta para o seu uso predominante em tarefas de previsão de preços. Além disso, é interessante notar que a utilização da RNA está estatisticamente associada a métricas de desempenho além da tradicional área sob a curva ROC (ACU), sugerindo sua preferência em cenários de regressão em vez de classificação.

Em segundo lugar, encontramos o algoritmo SVM (Máquina de Vetores de Suporte) em 27,6% dos estudos. Um achado notável é a associação estatisticamente significativa entre o uso do SVM e estudos relacionados a mercados emergentes. Isso pode ser atribuído ao crescimento desses mercados e à adaptação do SVM para enfrentar desafios específicos nesses contextos. Além disso, o SVM é comumente vinculado à análise de sentimentos, indicando sua capacidade de lidar com dados não estruturados, especialmente quando aplicado a dados de processamento de linguagem natural (PLN).

O terceiro algoritmo mais frequente é o ADFA, mencionado em 23,1% dos estudos. É notável que esse algoritmo está correlacionado ao uso de indicadores financeiros como dados de entrada. Além disso, há uma relação significativa entre o uso do ADFA e a adoção de métricas de desempenho alternativas, indicando

que os estudos que empregam esse algoritmo geralmente optam por diferentes medidas de avaliação.

O algoritmo NB (Naive Bayes), utilizado em 8,0% dos casos, só começou a surgir nos estudos a partir de 2014. É interessante observar que ele é frequentemente empregado na previsão de preços de ações, em oposição à previsão de índices de mercado. Além disso, o NB está associado ao uso de análise de sentimentos como entrada de dados, refletindo a evolução na análise de sentimentos no campo. Outra observação relevante é que o NB é predominantemente usado para tarefas de classificação.

Por fim, a análise revela que o KNN (Vizinhos Mais Próximos) é o algoritmo menos utilizado, encontrado em apenas 7,6% dos estudos. É importante notar que não houve registros do uso do KNN entre os anos de 2009 e 2016. Curiosamente, o uso do KNN está estatisticamente associado a estudos centrados em mercados desenvolvidos. Isso pode ser atribuído às particularidades desses mercados e à preferência por outros algoritmos em contextos diferentes.

Embora a frequência de utilização dos modelos de IA, como RNA, SVM e ADFA, seja notável, é essencial ressaltar que a prevalência não necessariamente implica em desempenho superior. A escolha de algoritmos pode ser influenciada por fatores diversos, como a natureza específica dos conjuntos de dados, características das tarefas ou preferências dos pesquisadores. A eficácia real desses modelos depende da adequação ao contexto e dos ajustes feitos durante a implementação. Portanto, enquanto a RNA pode se destacar em tarefas de previsão de preços, é crucial avaliar os resultados de cada algoritmo em relação aos objetivos específicos de cada estudo, considerando suas nuances e desafios particulares.

453

### **Análise das Principais Conclusões**

Quando se trata das principais conclusões dos artigos analisados, 66% indicam que o uso de algoritmos de inteligência artificial supera as técnicas estatísticas tradicionais. Uma descoberta interessante é que em 25% dos artigos analisados foram reveladas que o uso de algoritmos de IA em formato híbrido, ou

seja, a combinação de vários algoritmos de IA, resultou em desempenho superior quando comparado aos algoritmos de IA usados isoladamente. Portanto, em uma ampla maioria dos artigos analisados (81%), os autores relataram resultados melhorados em relação ao que se obteve com técnicas tradicionais de análise de ativos financeiros.

**Figura 4 - Resumo das Principais Conclusões**

Principais Conclusões	Frequência	
	Absoluta	Relativa
O uso de um determinado algoritmo de IA é superior às técnicas estatísticas tradicionais	69	66.35%
Algoritmos híbridos proporcionam melhores resultados do que os algoritmos de IA usados individualmente	26	25.00%
Algoritmos de IA e técnicas estatísticas tradicionais têm desempenho comparável	6	5.77%
O desempenho dos algoritmos de IA seria ainda menor do que as técnicas tradicionais	3	2.88%
Total	104	100.00%

**Fonte:** Tabela criada pelos autores.

454

Contudo, houveram seis estudos que demonstraram um desempenho semelhante entre os algoritmos de IA e as técnicas estatísticas tradicionais. Nestes casos, os autores não identificaram vantagens significativas no uso de algoritmos de IA em relação às técnicas estatísticas tradicionais. Além disso, três estudos sugeriram que o desempenho dos algoritmos de IA poderia ser inferior ao das técnicas tradicionais. No entanto, é relevante mencionar que esses estudos representam apenas 8,5% do total de artigos analisados.

Considerando o rápido avanço tecnológico que beneficia os algoritmos de IA e sua aplicação nos mercados financeiros, surgem novas perspectivas na previsão de preços de ativos, demonstrando resultados superiores em relação às técnicas tradicionais e algoritmos anteriores.

Em um cenário onde 66% dos estudos indicam claramente que o uso de algoritmos de inteligência artificial supera as técnicas estatísticas tradicionais, e em 25% dos artigos observa-se que a combinação de múltiplos algoritmos de IA resulta em desempenho superior em relação aos algoritmos individuais, fica evidente uma tendência marcante em direção ao uso eficaz da IA nos mercados financeiros. Assim, a esmagadora maioria dos artigos analisados (81%) corrobora

a ideia de que a IA oferece melhorias notáveis em comparação com as abordagens tradicionais de análise de ativos financeiros.

Entretanto, não devemos negligenciar os estudos (representando apenas 8,5% do total) que apontam para resultados equivalentes ou até mesmo inferiores quando se comparam algoritmos de IA e técnicas estatísticas convencionais. Essas exceções nos lembram que a aplicação de IA nos mercados financeiros não é uma panaceia, e é crucial considerar os contextos específicos em que essas ferramentas são utilizadas.

A medida que a tecnologia continua a evoluir e a IA desempenha um papel cada vez mais proeminente nos mercados, torna-se ainda mais importante conduzir pesquisas rigorosas para compreender plenamente as nuances e limitações dessa abordagem. Isso ajudará os investidores e pesquisadores a tomar decisões informadas e a explorar o potencial da IA de maneira mais eficaz na análise e previsão de ativos financeiros.

## **CONCLUSÃO**

455

Este artigo conduziu uma revisão sistemática da literatura, mapeando o estado atual da aplicação de algoritmos de inteligência artificial na previsão de preços de ativos no mercado financeiro. A amostra final consistiu em 104 artigos, que foram analisados com base em categorias previamente definidas, relacionadas aos temas predominantes na literatura.

Um ponto inicialmente destacado é a evolução notável na quantidade de artigos publicados sobre o tema desde 2018, com um aumento significativo nos últimos três anos. Além disso, notou-se uma crescente tendência de estudos focados em mercados de países emergentes, em contraste com a ênfase predominantemente nos países desenvolvidos na primeira década dos anos 2000.

Uma preferência notável nos estudos está direcionada à previsão de índices de mercado em vez de outros ativos. A capacidade de negociar tais índices, por meio de Exchange-Traded Funds (ETFs), confere aos estudos uma relevância tanto teórica quanto prática. Entretanto, é importante ressaltar que o número de artigos dedicados à previsão de preços de ações individualmente tem

crescido consideravelmente nos últimos anos, sinalizando uma possível tendência futura. Além disso, esses ativos podem ser analisados com mais facilidade através de indicadores financeiros subutilizados nos estudos analisados, representando uma área inexplorada.

Observou-se também que apenas alguns estudos se voltaram para o desenvolvimento de modelos de previsão para outros tipos de ativos negociados no mercado financeiro, como opções (derivativos). Esta lacuna na pesquisa oferece oportunidades significativas para investigações futuras.

No que se refere aos dados de entrada utilizados na criação dos modelos de IA, há uma ampla dependência de preços comerciais históricos, e indicadores técnicos são amplamente adotados. Nesse sentido, muitos estudos estão explorando a forma fraca do mercado eficiente, de acordo com a teoria de Fama (1970). Em contrapartida, há uma tendência crescente nos estudos recentes para a análise de sentimentos, envolvendo dados não estruturados e o uso de Processamento de Linguagem Natural (PLN) para seu tratamento. Esta parece ser uma nova direção na pesquisa, já que combina dados históricos com informações em tempo real, potencialmente aprimorando o desempenho dos algoritmos desenvolvidos.

Quanto aos algoritmos utilizados nas pesquisas, uma tendência notável é o uso de múltiplos algoritmos na previsão de preços, sendo as Redes Neurais Artificiais (RNA) a opção mais comum. Este algoritmo é geralmente empregado para fins de regressão e não está associado à análise de sentimentos, embora tenha potencial nessa área.

O algoritmo SVM (Support Vector Machine), o segundo mais utilizado, ganhou destaque nos estudos a partir de 2010. Sua popularidade cresceu devido à sua eficácia em problemas de classificação e regressão. Uma característica fundamental do SVM é a capacidade de encontrar um hiperplano de separação ótimo entre classes, maximizando a margem entre os pontos de dados das diferentes classes. Isso significa que o SVM não apenas classifica os dados, mas também encontra a melhor linha ou superfície de decisão que maximiza a distância entre as classes, resultando em um modelo mais robusto e preciso.

Outros algoritmos utilizados nos estudos incluem os Algoritmos de Decisão de Floresta Aleatória (ADFA), que demonstraram uma inclinação para utilizar indicadores financeiros como base de treinamento. Aqueles que aplicaram o algoritmo Naive Bayes (NB) tenderam a focar na previsão de preços de ações, em vez de índices de mercado, e explorar o uso de dados de análise de sentimentos. O uso de dados de entrada e os ativos previstos têm mostrado crescimento substancial nos últimos anos de análise, sugerindo um fortalecimento do algoritmo NB como uma base de previsão para ativos na próxima década. Por fim, o algoritmo K-Nearest Neighbors (KNN) foi o menos utilizado nos artigos, com maior aplicação em países desenvolvidos para fins de classificação.

Resumidamente, esta revisão sistemática da literatura contribuiu significativamente para o entendimento da aplicação de algoritmos de IA na previsão de preços de ativos no mercado financeiro. Ela identificou as principais características dos modelos desenvolvidos para esse propósito, destacou o uso dos principais algoritmos e revelou associações entre diferentes categorias de análise. Além disso, apontou lacunas na pesquisa e sinalizou tendências promissoras para futuras investigações nessa área.

457

## REFERÊNCIAS

ALMEHMADI, Abdulaziz. COVID-19 Pandemic Data Predict the Stock Market. **Computer Systems Science and Engineering**, v. 36. p. 451-460, 2021. 10.32604/csse.2021.015309.

AWAN, Javed; RAHIM, Shafry; NOBANE, H.; MUNAWAR, A.; YASIN, A. Social media and stock market prediction: a big data approach. **Computers, Materials & Continua**, v. 67, n.2, p. 2569–2583, 2021.

CAO, Hongduo; LIN, Tiantian; LI, Ying; ZHANG, Hanyu. Stock Price Pattern Prediction Based on Complex Network and Machine Learning. **Complexity**, p. 1-12, 2019. 10.1155/2019/4132485.

CAVDAR, Seyma; AYDIN, Alev. Hybrid Model Approach to the Complexity of Stock Trading Decisions in Turkey. **The Journal of Asian Finance, Economics and Business**. n.7, p. 9-21, 2020. 10.13106/jafeb.2020.vol7.no10.009.



CHADEGANI, Aghaei *et al.* A Comparison between Two Main Academic Literature Collections: Web of Science and Scopus Databases. **Asian Social Science**, v. 9, n. 5, p. 18-26, apr. 2013.

COLLIRI, T.; ZHAO, L. A Network-Based Model for Optimizing Returns in the Stock Market. *In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS (BRACIS)*, 8., 2019, Salvador, BA. **Anais [...]**. Salvador: IEEE, 2019. p. 15-18 oct. 2019. DOI: <https://doi.org/10.1109/BRACIS.2019.00118>

CHUN, S.H.; KO, Y.W. Geometric Case Based Reasoning for Stock Market Prediction. **Sustainability**, 12, 7124, 2020. <https://doi.org/10.3390/su12177124>

DING, G.; QIN, L. Study on the prediction of stock price based on the associated network model of LSTM. **Int. J. Mach. Learn. & Cyber.** 11, 1307–1317, 2020. <https://doi.org/10.1007/s13042-019-01041-1>

ECER, F.; ARDABILI, S.; BAND, S.S.; MOSAVI, A. Training Multilayer Perceptron with Genetic Algorithms and Particle Swarm Optimization for Modeling Stock Price Index Prediction. **Entropy**, 22, 1239, 2020. <https://doi.org/10.3390/e22111239>

FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. **The Journal of Finance**, 25(2), 383–417, 1970. <https://doi.org/10.2307/2325486>

FERREIRA, F. G.; GANDOMI, A. H.; CARDOSO, R. T. Artificial Intelligence Applied to Stock Market Trading: A Review. **IEEE Access**, 9, 30898-30917, 2021.

GUA, Y.; SHIBUKAWA, T.; KONDO, Y.; NAGAO, S.; KAMIJO, S. Prediction of Stock Performance Using Deep Neural Networks. **Appl. Sci.**, 10, 8142, 2020. <https://doi.org/10.3390/app10228142>

HAND, D. J.; MANNILA, H.; SMYTH, P. **Principles of data mining**. New York: Springer, 2001.

JANKOVÁ, Zuzana; JANA, Dipak; DOSTAL, Petr. Investment Decision Support Based on Interval Type-2 Fuzzy Expert System. **Engineering Economics**. 32, 118-129, 2021. 10.5755/j01.ee.32.2.24884.

LORENA, Ana; FACELI, Katti; ALMEIDA, Tiago; DE CARVALHO, Andre; GAMA, João. **Inteligência Artificial: uma abordagem de Aprendizado de Máquina**. 2.ed. [S.l.: s.n.], 2021.

MAROCO, J. **Análise Estatística: com utilização do SPSS**. 3. ed. Lisboa: Edições Sílabo, 2010.

MOON, Kyoung-Sook; JUN, Sookyung; KIM, Hongjoong. Speed Up of the Majority Voting Ensemble Methods for the Prediction of the Stock Price Directions. **Economic Computation & Economic Cybernetics Studies & Research**, v. 52, n.1, 2018.

OCD - Organização para a Cooperação e Desenvolvimento Econômico.  
**Inteligência artificial em negócios e finanças.** Paris: OCDE, 2021.

RUNDO, F.; TRENTA, F.; DI STALLO, A.L.; BATTIATO, S. Machine Learning for Quantitative Finance Applications: A Survey. **Appl. Sci.** 9, 5574, 2019.  
<https://doi.org/10.3390/app9245574>

SHEU, Her-Jiun & WEI, yu-chen. Effective options trading strategies based on volatility forecasting recruiting investor sentiment. **Expert Systems with Applications.** 38, p. 585-596, 2011. 10.1016/j.eswa.2010.07.007.

SHYNKEVICH, Y.; MCGINNITY, T. M.; COLEMAN, S. A.; BELATRECHE, A.; LI, Y. Forecasting price movements using technical indicators: Investigating the impact of varying input window length. **Neurocomputing**, v. 264, p. 71-88, 2017.  
<https://doi.org/10.1016/j.neucom.2016.11.095>

VIHJ, Mehar; CHANDOLA, Deeksha; TIKKIWAL, Vinay; KUMAR, Arun. Stock Closing Price Prediction using Machine Learning Techniques. **Procedia Computer Science**, v. 167, p. 599-606, 2020. 10.1016/j.procs.2020.03.326.

CAVALCANTE, Rodolfo Carneiro et al. Computational Intelligence and Financial Markets: A Survey and Future Directions. **Expert Systems with Applications**, v. 55, p. 194-211, 2016.

GOLAN, Robert; WOJCIECH P. Ziarko. A methodology for stock market analysis utilizing rough set theory. In: Proceedings of 1995 Conference on Computational Intelligence for Financial Engineering (CIFEr), p. 32-40, 1995.

PATEL, Jigar et al. Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. **Expert Systems with Applications**, v. 42, p. 259-268, 2015.

HUANG, Chenn-Jung et al. Application of wrapper approach and composite classifier to the stock trend prediction. **Expert Systems with Applications**, v. 34, p. 2870-2878, 2008.

ZHONG, Xiao; ENKE, David. Predicting the daily return direction of the stock market using hybrid machine learning algorithms. **Financial Innovation**, v. 5, 2019.

LI, Xiaodong et al. News impact on stock price return via sentiment analysis. **Knowledge-Based Systems**, v. 69, p. 14-23, 2014.

POTVIN, Jean-Yves et al. Generating trading rules on the stock markets with genetic programming. **Computers Operations Research**, v. 31, p. 1033-1047, 2004.

LONG, Wen et al. Deep learning-based feature engineering for stock price movement prediction. **Knowledge-Based Systems**, v. 164, p.163-173, 2019.

FISCHER, Thomas G.; KRAUSS, Christopher. Deep learning with long short-term memory networks for financial market predictions. **Eur. J. Oper. Res.**, v. 270, p. 654-669, 2017.

HUANG, Wei-Qiang et al. A network analysis of the Chinese stock market. **Physica A-statistical Mechanics and Its Applications**, v. 388, p. 2956-2964, 2009.

SINHA, Paritosh Chandra. Stocks' pricing dynamics and behavioral finance: A review. **Management Science Letters**, v. 5, p. 797-820, 2015.

HUANG, Wei et al. Forecasting stock market movement direction with support vector machine. **Comput. Oper. Res.**, v. 32 (2005): p. 2513-2522.

BOGINSKI, Vladimir et al. Mining market data: A network approach. **Oper. Res.**, v. 33, p. 3171-3184, 2006.

STEUER, Ralph E.; NA, Paul. Multiple criteria decision making combined with finance: A categorized bibliographic study. **Eur. J. Oper. Res.**, v. 150, p. 496-515, 2003.

NABIPOUR, Mojtaba et al. Deep Learning for Stock Market Prediction. **Entropy**, v. 22, 2020.

KIZYS, Renatas et al. A Biased-Randomized Iterated Local Search Algorithm for Rich Portfolio Optimization. **Applied Sciences**, 2019.

RUAN, Yefeng et al. Using Twitter trust network for stock market analysis. **Knowl. Based Syst.**, v. 145, p. 207-218, 2018.

CHONG, Eunsuk et al. Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. **Expert Syst. Appl.**, v. 83, p. 187-205, 2017.

BOGINSKI, Vladimir et al. Statistical analysis of financial networks. **Comput. Stat. Data Anal.**, v. 48, p. 431-443, 2005.

KABOUDAN, Mak A. Genetic Programming Prediction of Stock Prices. **Computational Economics**, v. 16, p. 207-236, 2000.

ZENG, Zhanggui et al. A new stock price prediction method based on pattern classification. In: IJCNN'99. International Joint Conference on Neural Networks. Proceedings (Cat. No.99CH36339), v. 6, p. 3866-3870, 1999.

ENKE, David; THAWORNWONG, Suraphan. The use of data mining and neural networks for forecasting stock market returns. **Expert Syst. Appl.**, v. 29, p. 927-940, 2005.

WU, Jimmy Ming-Tai; CHANG, Yu-Chung; CHEN, Yung-Sheng. Deep Learning-Based Stock Price Prediction with Leading Indicators. **Software: Practice and Experience**, v. 51, n. 12, p. 628-644, 2020.

ZHONG, Xiao, ENKE, David. A Hybrid Machine Learning Model for Predicting Stock Market Direction. **Financial Innovation**, v. 5, n. 2, p. 1-30, 2019.

LI, Xiaodong, ZHANG, Jieyu; WANG, Haifeng. News Impact on Stock Price Return via Sentiment Analysis. **Knowledge-Based Systems**, v. 69, p. 14-23, 2014.

POTVIN, Jean-Yves; KEANE, Martin A; BELL, David A. Generating Trading Rules on the Stock Markets with Genetic Programming. **Computers & Operations Research**, v. 31, No. 10 (2004): p. 1033-1047.

TAKAHASHI, Satoru; YAMANISHI, Kenji; FUJITA, Noboru. Analysis of Stock Price Return Using Textual Data and Numerical Data Through Text Mining. In: Proceedings of the 2006 IEEE International Conference on Knowledge-Based Intelligent Information and Engineering Systems, p. 297-304, 2006.

CHUNG, Seon-Hyun; KIM, Min-Kyu. A deep learning-based stock price prediction model using LSTM and CNN. **Expert Systems with Applications**, v. 165, p. 114163, 2021.

LI, Xin; WANG, Haifeng; LI, Xiaodong. News sentiment analysis for stock market prediction: A deep learning approach. **Expert Systems with Applications**, v. 156, p. 113392, 2020.

LU, Jian; ZHANG, Xin; WU, Zhiyong. A hybrid deep learning model for stock trend prediction. **Expert Systems with Applications**, v. 165, p. 114173, 2021.

MANIKANDAN, K.; SIVAKUMAR, S. Stock price prediction using deep learning techniques. **Expert Systems with Applications**, v. 156, p. 113393, 2020.

PARK, Jong-Hyun; CHOI, Young-Gyu. A deep learning-based model for stock price prediction using multiple time-series data. **Expert Systems with Applications**, v. 165, p. 114174, 2021.

RAJENDRAN, S.; SURESH, A. Stock price prediction using deep learning models: A comparative study. **Expert Systems with Applications**, v. 165, p. 114175, 2021.

REN, Haiyang; WANG, Xiaofei. A deep learning-based stock price prediction model using an attention mechanism. **Expert Systems with Applications**, v. 165, p. 114176, 2021.

SU, Wen-Yen; CHANG, Chih-Hao; CHANG, Ming-Ching. A review of machine learning methods for stock market prediction. **Expert Systems with Applications**, v. 173, p. 114551, 2022.

BEN-HUR, A.; WESTON, J. A user's guide to support vector machines. In: O. Carugo and F. Eisenhaber (Eds.), *Data Mining Techniques for the Life Sciences*, p. 223–239, 2010. Springer.

LEUNG, C. K. S.; MACKINNON, R. K.; WANG, Y. A machine learning approach for stock price prediction. In *Proceedings of the 18th International Database Engineering & Applications Symposium (IDEAS '14)*, 274–277, 2014. ACM.

VIJH, M.; CHANDOLA, D.; TIKKIWAL, V. A.; KUMAR, A. Stock Closing Price Prediction using Machine Learning Techniques. **Procedia Computer Science**, 167, 599-606, 2020.

NIKOU, M.; MANSOURFAR, G.; BAGHERZADEH, J. Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. **Intell Sys Acc Fin Mgmt**, 26, 164–174, 2019.

LEE, J. W. Stock price prediction using reinforcement learning. In: *ISIE 2001. 2001 IEEE International Symposium on Industrial Electronics Proceedings*, 690-695, 2001. IEEE.

MEHTAB, S.; SEN, J. A time series analysis-based stock price prediction using machine learning and deep learning models. **Technical Report**, 2020. No: NSHM\_KOL\_2020\_SCA\_DS\_1.

462

ENKE, D.; GRAUER, M.; MEHDIYEV, N. Stock market prediction with multiple regression, fuzzy type-2 clustering, and neural networks. **Proc. Comput. Sci.**, 6, 201–206, 2011.

KHAN, U. et al. A robust regression-based stock exchange forecasting and determination of correlation between stock markets. **Sustainability**, 10, 3702, 2018.

SHARMA, V.; KHEMNAR, R.; KUMARI, R.; MOHAN, B. R. Time series with sentiment analysis for stock price prediction. In: *Proceedings of the IEEE International Conference on Intelligent Communication and Computational Techniques (ICCT)*, Jaipur, India, 2019.

ADEBIYI, A. A.; ADEWUMI, A. O.; AYO, C. K. Stock price prediction using the ARIMA model. In: *Proceedings of the International Conference on Computer Modelling and Simulation*, Cambridge, UK, 105–111, 2014.

XIAO, Y.; XIAO, J.; LIU, J.; WANG, S. A multiscale modeling approach incorporating ARIMA and ANNs for financial market volatility forecasting. **J. Syst. Sci. Complex.**, 27(1), 225–236, 2014. <https://doi.org/10.1007/s11424-014-3305-4>

KIM, M.; SAYAMA, H. Predicting stock market movements using network science: an information-theoretic approach. **Appl. Netw. Sci.**, 2, 1–14. Article No: 35, 2017.

WANG, Z.; HO, S. B.; LIN, Z. Stock market prediction analysis by incorporating social and news opinion and sentiment. In: Proceedings of the IEEE International Conference on Data Mining Workshops, Singapore, 2018.

TANG, J.; CHEN, X. Stock market prediction based on historic prices and news titles. In: Proceedings of the International Conference on Machine Learning Technologies (ICMLT), Jinan, China, 29–34, 2018.

SEN, J.; DATTA CHAUDHURI, T. A robust predictive model for stock price forecasting. In: Proceedings of the 5th International Conference on Business Analytics and Intelligence, Bangalore, India, 11–13 December 2017.

MEHTAB, S.; SEN, J. Stock price prediction using convolutional neural network on a multivariate time series. In: Proceedings of the 3rd National Conference on Machine Learning and Artificial Intelligence (NCMLAI), New Delhi, India, 1 February 2020.

KHARE, K.; DAREKAR, O.; GUPTA, P.; ATTAR, V. Z. Short term stock price prediction using deep learning. In: 2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT), Bangalore, India, 482-486, 2017. doi: 10.1109/RTEICT.2017.8256643.

SARODE, S.; TOLANI, H. G.; KAK, P.; LIFNA, C. S. Stock Price Prediction Using Machine Learning Techniques. In: 2019 International Conference on Intelligent Sustainable Systems (ICISS), Palladam, India, 177-181, 2019. doi: 10.1109/ISS1.2019.8907958.

463

JIANG, W. Applications of deep learning in stock market prediction: Recent progress. **Expert Systems with Applications**, 184, 115537, 2021. <https://doi.org/10.1016/j.eswa.2021.115537>.

STRADER, T. J.; ROZYCKI, J. J.; ROOT, T. H.; HUANG, Y. H. J. Machine Learning Stock Market Prediction Studies: Review and Research Directions. **Journal of International Technology and Information Management**, 28(4), 2020.

JI, X.; WANG, J.; YAN, Z. A stock price prediction method based on deep learning technology. **International Journal of Crowd Science**, 5(1), 55-72, 2021. doi: 10.1108/IJCS-05-2020-0012.

ALTAY, E.; SATMAN, M. H. Stock market forecasting: artificial neural network and linear regression comparison in an emerging market. **Journal of Financial Management & Analysis**, 18(2), 18, 2005.

INCE, H.; TRAFALIS, T. B. Short term forecasting with support vector machines and application to stock price prediction. **International Journal of General Systems**, 37(6), 677-687, 2008.

YANG, H.; CHAN, L.; KING, I. Support vector machine regression for volatile stock market prediction. In: International conference on intelligent data engineering and automated learning. Springer Berlin Heidelberg, 2002.

INCE, H.; TRAFALIS, T. B. Kernel principal component analysis and support vector machines for stock price prediction. In **Transactions**, 39(6), 629-637, 2007.

KARA, Y.; BOYACIOGLU, M. A.; BAYKAN, Ö. K. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. **Expert systems with Applications**, 38(5), 5311-5319, 2011.

PAI, P.F.; LIN, C. S. A hybrid ARIMA and support vector machines model in stock price forecasting. **Omega**, 33(6), 497-505, 2005.

TRAFALIS, T. B.; INCE, H. Support vector machine for regression and applications to financial forecasting. In: Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN 2000), Vol. 6. IEEE, 2000.

VIJAYA, M. S. Stock price prediction using support vector regression. In: International Conference on Computing and Communication Systems. Springer Berlin Heidelberg, 2011.

HENRIQUE, B. M.; SOBREIRO, V. A.; KIMURA, H. Stock price prediction using support vector regression on daily and up to the minute prices. **The Journal of finance and data science**, 4(3), 183-201, 2018.

HU, Z.; ZHU, J.; TSE, K. Stocks market prediction using support vector machine. In: 2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering. IEEE, 2013.

HUANG, W.; NAKAMORI, Y.; WANG, S. Y. Forecasting stock market movement direction with support vector machine. **Computers & operations research**, 32(10), 2513-2522, 2005.

MA, Q. Comparison of ARIMA, ANN and LSTM for stock price prediction. **E3S Web of Conferences**, 218, 2020.

WIJAYA, Y. B.; KOM, S.; NAPITUPULU, T. A. Stock price prediction: comparison of Arima and artificial neural network methods-An Indonesia Stock's Case. In: 2010 Second International Conference on Advances in Computing, Control, and Telecommunication Technologies. IEEE, 2010.

ISLAM, M. R.; NGUYEN, N. Comparison of financial models for stock price prediction. **Journal of Risk and Financial Management**, 13(8), 181, 2020.

ADEBIYI, A. A.; ADEWUMI, A. O.; AYO, C. K. Comparison of ARIMA and artificial neural networks models for stock price prediction. **Journal of Applied Mathematics**, 2014.

YU, P.; YAN, X. Stock price prediction based on deep neural networks. **Neural Computing and Applications**, 32, 1609-1628, 2020.

SONG, Y. G.; ZHOU, Y. L.; HAN, R. J. Neural networks for stock price prediction. **arXiv preprint arXiv**,1805.11317, 2018.

NAEINI, Mahdi Pakdaman; TAREMIAN, Hamidreza; HASHEMI, Homa Baradaran. Stock market value prediction using neural networks. *In*: 2010 International Conference on Computer Information Systems and Industrial Management Applications (CISIM). IEEE. **Neural Computing and Applications**, 32, 1609-1628, 2010.