



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

Tendências e Desafios na Aplicação de Redes Neurais Artificiais para Prever o Mercado de Ações: Uma Revisão de Literatura

Gilvan Vieira Moura

Mestrando em Engenharia de Produção - Universidade Tecnológica Federal do Paraná

Hugo Valadares Siqueira

Departamento Acadêmico de Engenharia de Produção - Universidade Tecnológica Federal do Paraná

Julio Aires Azevedo Leite

Mestrando em Engenharia de Produção - Universidade Tecnológica Federal do Paraná

Jade Diane Fernandes Targino Filgueira

Doutorado em Engenharia de Produção - Universidade Tecnológica Federal do Paraná

Isaac Alves Dias

Mestrando em Engenharia de Produção - Universidade Tecnológica Federal do Paraná

Resumo: O mercado de ações possui uma grande diversidade de dados que são altamente voláteis e seguem padrões não-lineares ao longo do tempo, formando séries temporais complexas. Devido a essa grande complexidade, a previsão das flutuações do mercado torna-se um desafio significativo. Por este viés, este estudo de revisão de literatura possui como objetivo investigar o uso de Redes Neurais Artificiais (RNAs) na previsão da tendência no mercado de ações. Foi realizada uma coleta abrangente de artigos científicos nas bases de dados Scielo, Science Direct e Redalyc. Os resultados obtidos apontam que as eficazes na previsão dos retornos do mercado de ações, superando até mesmo modelos tradicionais. Estes resultados enfatizam a utilidade das RNAs na previsão de preços de ações, representando uma vantagem na tomada de decisões financeiras.

Palavras-chave: Redes Neurais Artificiais, Previsão de Mercado de Ações, Modelos de Previsão Financeira.

Trends and Challenges in the Application of Artificial Neural Networks to Predict the Stock Market: A Literature Review

Abstract: The stock market holds a wide range of data that is highly volatile and follows non-linear patterns over time, forming complex time series. Due to this high complexity, predicting market fluctuations becomes a significant challenge. From this perspective, this literature review study aims to investigate the use of Artificial Neural Networks (ANNs) in forecasting stock market trends. A comprehensive collection of scientific articles was gathered from Scielo, Science Direct, and Redalyc databases. The results obtained indicate that ANNs prove to be effective in predicting stock market returns, even outperforming traditional models. These findings underscore the utility of ANNs in stock price prediction, representing an advantage in financial decision-making.

Keywords: Artificial Neural Networks (ANNs), Stock Market Forecasting, Financial Forecasting Models.

1. Introdução

O interesse das pessoas no mercado de ações cresceu exponencialmente nas últimas décadas, levando a uma alta atividade de negociação nos mercados cotidianamente. Os dados do mercado de ações são altamente flutuantes e seguem padrões não-lineares ao longo do tempo, formando séries temporais. As séries temporais são conjuntos de dados medidos para entender o comportamento de alguma atividade (Hiransha et al., 2018).

O cenário das séries temporais financeiras são mais complexas do que outros tipos de dados estatísticos devido às tendências de longo prazo, variações cíclicas, variações sazonais e movimentos irregulares. Prever esses dados altamente voláteis e irregulares geralmente resulta em grandes erros (ROUT et al., 2017).

Os modelos estatísticos tradicionais usados para previsões financeiras apresentam algumas limitações devido à não-linearidade dos dados (ROUT et al., 2017). Além disso, tais limitações fazem com que estes funcionem bem apenas para um conjunto específico de dados temporais de uma empresa e não são facilmente generalizáveis (Hiransha et al., 2018).

Neste sentido, destaca-se que a previsão no mercado de ações é desafiadora devido à sua natureza volátil, não linear e dinâmica. Além disso, vários fatores como condições políticas, situação econômica, tendências, sazonalidade, políticas governamentais, desastres naturais, psicologia dos investidores, dentre outros, afetam seus preços (VIJH et al., 2020), (YADAV; JHA; SHARAN, 2020), (BHANDARI et al., 2022).

Por outro ângulo, Kumbure et al (2022) enfatizam que através de um método de previsão preciso os investidores poderiam superar constantemente os retornos de mercado. Portanto, é de grande interesse na pesquisa em problemas relativos a dados financeiros desenvolver modelos mais realistas para prever de maneira mais eficaz e precisa. Por isso, métodos de computação suave, mais eficientes e precisos, como Redes Neurais Artificiais têm sido desenvolvidos para previsões financeiras (ROUT et al., 2017).

Portanto, o objetivo deste estudo é investigar a eficácia do uso de redes neurais artificiais para prever tendências do mercado de ações. A pesquisa buscará compreender como estas ferramentas podem capturar padrões complexos em dados históricos de mercado e contribuir para previsões mais precisas. Para tanto, será realizada uma revisão sistemática da literatura e análise de conteúdo dos artigos das bases de dados Scielo, ScienceDirect e Redalyc, em que os aspectos estudados são: Citações, Fator de Impacto, Ano de Publicação, Tipo de investigação, estrutura e objetivos da análise, resultados obtidos e conclusões obtidas.

Este trabalho está dividido em cinco seções: introdução, metodologia a qual deu o norte para construção do artigo, referencial teórico (dividido em 2 subseções: Previsões no mercado de ações Redes Neurais Artificiais na Previsão do Mercado de Ações), resultados e discussões e, por fim, as considerações finais.

2. Metodologia

O presente trabalho trata-se de uma pesquisa quanti-qualitativa de natureza básica. Quanto aos objetivos é uma pesquisa exploratória em que foi realizada uma revisão sistemática da literatura sobre o uso das redes neurais para previsão de tendências no mercado de ações.

Entretanto, a seleção de materiais científicos para integração do referencial bibliográfico é uma fase dispendiosa, que demanda um considerável investimento de tempo e esforço, além de exigir a definição de critérios apropriados para inclusão e exclusão de artigos (PAGANI; KOVALESKI; RESENDE, 2015). Com o intuito de facilitar a escolha de material bibliográfico, foi utilizado a *Methodi Ordinatio*.

Inicialmente, foi estabelecido a intenção de pesquisa: construir um portfólio bibliográfico a partir de artigos científicos sobre o tema “O uso de redes neurais artificiais na previsão da tendência no mercado de ações”. Desta forma, buscou-se explorar e analisar o uso de redes neurais artificiais como ferramenta de previsão da tendência no mercado de ações, avaliando sua eficácia, metodologias empregadas e identificando padrões na literatura existente.

Em seguida, foi realizada uma pesquisa preliminar com algumas palavras chave nas bases de dados selecionadas, conforme a tabela 1 a seguir:

Tabela 1 – Definição das palavras e termos de busca

KeywordCombination	SCIELO	Science Direct	Redalycs	Total
Artificial neural networks AND Stock market	8	373	64	445
Prediction algorithms AND Stock market	1	43	1	45

Fonte: Autoria Própria (2023)

Após as buscas nas bases de dados selecionadas, foram utilizados o Mendeley e o JabRef como gerenciadores de referências para a coleta e armazenamento dos dados. O Mendeley apresentou uma maior eficiência na organização, enquanto oJabRef apresentou um melhor desempenho para exportar os dados em formato de lista para uma planilha eletrônica.

Em seguida, após serem exportadas para o JabRef, foram realizados os procedimentos de filtragem, em que foram excluídos: artigos duplicados; com títulos não relacionados ao tema; livros e capítulos; dentre outros. Após filtrados, a coleção foi exportada para uma planilha do excel, com o intuito de excluir as células mescladas. Foram removidos: volume e página, e os dados da planilha excel foram enviados para a planilha RankIn.

A planilha RankIn, traz consigo a equação *InOrdinatio*, que trabalha com os três fatores mais importantes em um artigo científico: o fator de impacto, o ano da publicação da pesquisa e o número de citações Este procedimento facilita consideravelmente a coleta de dados realizada nesta etapa, conforme equação 1 (PAGANI; KOVALESKI; RESENDE, 2015):

$$\text{InOrdinatio} = (\text{IF}/1000) + \alpha * \\ [10 - (\text{ResearchYear} - \text{PublishYear})] + (\sum \text{Ci})$$

Nesta equação, “*IF*” representa o fator de impacto; “ α ” é fator de ponderação (que varia de 1 a 10 a ser atribuído pelo pesquisador, conforme a atualidade do tema); “*ResearchYear*” é o ano em que a pesquisa foi desenvolvida; “*PublishYear*” é ano em que o artigo foi publicado e “ $\sum C_i$ ” é o número de vezes que o artigo foi citado.

O valor de “ α ” usado na Equação *InOrdinatio* foi “5”, considerando a atualidade dos artigos e do tema, haja vista que não necessariamente os artigos mais recentes traziam maior fator de impacto, pois, como se trata de uma revisão de literatura, buscou-se uma compreensão completa do assunto, além de avaliar os principais impactos. Em seguida, foram incluídas manualmente a quantidade de citações coletadas no Google Scholar e o ISSN de cada artigo manualmente.

Considerou-se os resultados obtidos com a aplicação da Equação *InOrdinatio* artigos que obtiveram nota ≥ 100 , totalizando 10 trabalhos.

Com o intuito de facilitar a leitura e análise dos artigos, estes foram organizados por ano, pois, apesar do *InOrdinatio* definir os trabalhos de maior relevância, é necessário realizar uma leitura cronológica para acompanhar os avanços. Durante a leitura foi preenchida uma planilha de protocolo bibliométrico com o intuito de facilitar a análise dos resultados. Foram consideradas as seguintes informações: número RankIn, Título, Ano, Objetivo, Problema, País do Estudo, Solução proposta, Sugestões para trabalhos futuros, e Resultados obtidos.

3. Referencial teórico

3.1 Previsões no mercado de ações

O mercado de ações é um dos setores financeiros mais dinâmicos e desafiadores, no qual investidores e traders buscam constantemente oportunidades para maximizar seus retornos. De acordo com Kumbure et al (2022), o interesse pelo mercado de ações cresceu exponencialmente nas últimas décadas, o que conseqüentemente leva a uma alta atividade de negociação todos os dias. Neste sentido, os autores ainda destacam que, ao prever com precisão os comportamentos do mercado, os investidores podem superar consistentemente seus retornos.

A previsão do mercado de ações desempenha um papel central nesse processo, permitindo que os participantes tomem decisões informadas sobre a compra, venda ou retenção de ativos financeiros. Entretanto, essa previsão torna-se altamente dificultosa, haja vista que os dados são altamente flutuantes e seguem padrões não-lineares ao longo do tempo, formando séries temporais (Hiransha et al., 2018).

A previsão do mercado de ações envolve a análise de diversas variáveis que podem influenciar os movimentos de preços das ações. De acordo com Kumbure et al (2022) tais variáveis podem ser agrupadas em várias categorias:

1. **Indicadores Técnicos:** Esses indicadores são derivados dos preços históricos das ações e do volume de negociação, incluindo médias móveis, Bandas de Bollinger e osciladores estocásticos. Eles são amplamente usados para identificar tendências, pontos de entrada e saída no mercado.
2. **Variáveis Macroeconômicas:** Fatores macroeconômicos, como taxas de câmbio, índices de commodities, desempenho econômico geral, taxa de juros e oferta monetária, podem impactar significativamente os preços das ações.
3. **Indicadores Fundamentais:** Essas variáveis estão relacionadas ao desempenho financeiro e à posição de mercado das empresas, incluindo métricas como o preço/lucro (P/L), *dividendyield* e índices financeiros específicos de uma empresa.
4. **Outras Variáveis:** Esta categoria engloba informações diversas, como notícias financeiras, eventos de mercado, dados de redes sociais e até mesmo sentimentos do mercado. Essas podem ser capturadas por meio da mineração de texto e análise de sentimento.

A escolha das variáveis a serem consideradas depende da abordagem de previsão e do horizonte de tempo desejado (KUMBURE et al., 2022). Neste sentido, é notório que, a natureza incerta e imprevisível do mercado de ações torna a previsão uma tarefa desafiadora, especialmente com modelos lineares. Com o intuito de enfrentar esse desafio, o uso de modelos de aprendizado profundo na previsão financeira tornou-se relevante. As redes neurais profundas, também têm sido aplicadas com sucesso nesse contexto.

3.2 Redes Neurais Artificiais (RNAs) na Previsão do Mercado de Ações

Uma Rede Neural Artificial (RNA) é um modelo computacional inspirado na estrutura e funcionamento dos neurônios biológicos. Ela é projetada para encontrar padrões complexos nos dados e generalizar a partir desses padrões. A RNA é uma ferramenta estatística não-linear, sendo capaz de aprender relações complexas entre entradas e saídas (Hiransha, 2018).

De acordo com Moghaddam, Moghaddam e Esdandyari, a RNA se baseia vagamente no funcionamento do cérebro humano. Ele consiste em unidades individuais de processamento chamadas neurônios, que estão conectadas entre si. Essas redes são usadas para resolver problemas complexos, como previsões em finanças, através da simulação de processos biológicos.

De acordo com Vijn et al. (2020), o avanço das técnicas de inteligência artificial e aprendizado de máquina tem melhorado a previsão de preços das ações, sendo que, técnicas como Máquinas de Vetores de Suporte (SVM), Floresta Aleatória (RF) e redes neurais têm apresentado resultados promissores. Neste sentido, verifica-se que de fato, as Redes neurais artificiais (ANN) são capazes de encontrar padrões ocultos em conjuntos de dados complexos.

Além disso, conforme Hiransha et al (2018), as redes neurais profundas têm características benéficas para a previsão financeira, como a boa capacidade de aproximação de funções, de modo que mesmo com conjuntos de dados complexos, as redes neurais podem compreender a relação entre entradas e saídas. Também possuem capacidade de generalização, pois mesmo quando dados de teste não vistos durante o treinamento são apresentados, podem realizar previsões razoáveis.

O uso de RNAs na previsão do mercado de ações envolve equações numéricas que processam variáveis de entrada para produzir saídas. De acordo com Chaajer, Shah e Kshirsagar (2021), estas possuem três tipos de camadas, entrada, oculta e saída, e suas estruturas complexas permitem cálculos sofisticados. Os neurônios na camada de entrada coletam os valores de entrada, os multiplicam pelos pesos associados e somam um valor de viés. Isso é passado para a camada oculta, na qual uma função de ativação é aplicada para produzir a saída final (MOGHADDAM; MOGHADDAM; ESFANDYARI, 2016).

As redes neurais recorrentes (RNNs), uma classe de RNAs, têm se mostrado particularmente eficazes na previsão de séries temporais, como os preços das ações. Isso ocorre pois as RNNs lida com sequências de dados, na qual as saídas anteriores são usadas como entradas para prever as saídas futuras. Isso a torna adequada para previsões em séries temporais. No entanto, as RNNs tradicionais têm dificuldade em lidar com sequências muito longas e não conseguem manter informações relevantes de sequências anteriores por muito tempo. Isso é conhecido como o problema do "gradiente desvanecente", que resulta em um aprendizado do modelo que se torna muito lento ou para completamente (MOGHAR; HAMICHE, 2020).

As redes *long-short term memory* (LSTMs) foram criadas na década de 1990 para resolver esse problema. LSTMs possuem memórias mais longas e podem aprender com entradas separadas por intervalos de tempo longos (YADAV; JHA; SHARAN, 2020). As LSTMs, um tipo de RNN, são especialmente adequadas para capturar dependências de longo prazo em sequências de dados (MOGHAR; HAMICHE, 2020). A estrutura de uma LSTM envolve uma célula de memória, uma porta de entrada, uma porta de saída e uma porta de esquecimento. Isso permite que as LSTMs capturem relações de longo prazo em séries temporais financeiras, o que é essencial para prever tendências de mercado que podem se desenvolver ao longo de semanas, meses ou até anos.

As LSTMs são utilizadas em tradução automática, reconhecimento de fala, entre outros, devido às suas características favoráveis para solucionar problemas complexos desse tipo. No contexto da previsão de preços de ações, as LSTMs podem armazenar informações passadas, o que é relevante, uma vez que os preços anteriores desempenham um papel significativo na previsão dos preços futuros das ações.

Em suma, a utilização de LSTMs na previsão de preços de ações tem se mostrado eficaz em diversos estudos. No entanto, é importante considerar a qualidade dos dados de treinamento e ajustar os parâmetros do modelo para obter resultados confiáveis e precisos. (CHAAJER; SHAH; KSHIRSAGAR, 2021).

Em comparação com técnicas tradicionais, como modelos lineares, incluindo o Modelo Autorregressivo Integrado de Médias Móveis (ARIMA), as RNAs, especialmente as LSTMs, têm demonstrado vantagens na previsão de preços de ações devido à sua capacidade de lidar com padrões complexos e não lineares nos dados (HIRANSHA et al., 2018). Essa flexibilidade em capturar relações não lineares é particularmente relevante em mercados financeiros, nos quais as tendências podem ser altamente irregulares e influenciadas por uma ampla gama de variáveis.

A previsão do mercado de ações é uma tarefa complexa que requer uma compreensão profunda de uma variedade de variáveis e uma escolha adequada de técnicas de previsão. No entanto, é importante ressaltar que a previsão do mercado de ações continua sendo um desafio em evolução devido à volatilidade dos mercados e à influência de eventos imprevisíveis. Portanto, a pesquisa contínua e a combinação de abordagens avançadas com uma compreensão sólida dos fundamentos financeiros são essenciais para obter previsões consistentemente precisas no mercado de ações.

4. Resultados e discussões

As redes neurais artificiais (RNAs) tornaram-se ferramentas importantes na análise e previsão do mercado de ações, pois, ao passo que as operações financeiras tornam-se mais complexas e interligadas, a capacidade de prever tendências e flutuações do mercado é essencial para investidores e profissionais do setor. Assim, ao revisar diversos artigos relevantes e suas descobertas, será evidenciado como tais ferramentas estão moldando e aprimorando as estratégias de investimento.

A análise do primeiro artigo, intitulado "*Stock market index prediction using artificial neural network*", verificou que o trabalho tem como objetivo avaliar a capacidade RNAs em prever variações no índice Nasdaq, importante indicador do mercado de ações. Conforme Moghadam, Moghadam, e Esfandiari (2016), a questão da investigação surge devido à dificuldade em prever com precisão as mudanças futuras num mercado complexo e não linear. Os resultados obtidos mostram que a utilização de redes neurais artificiais combinadas com informações históricas de dias anteriores é uma forma eficaz de prever o comportamento do índice.

O segundo artigo, intitulado "*Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market*" objetivou aplicar RNAs para prever os retornos do índice Nikkei 225 no Japão. A pesquisa também comparou diferentes métodos de treinamento e otimização de RNAs para aprimorar a precisão das previsões (QIU; SONG; AKAGI, 2016). O estudo sugeriu a necessidade de pesquisas futuras para lidar com problemas de multicolinearidade e explorar a previsão da direção do mercado usando outras técnicas e modelos. Os pesquisadores recomendam investigar a previsão da direção do mercado com abordagens diferentes das utilizadas no estudo. Em resumo, o estudo demonstrou que a utilização de uma abordagem híbrida de otimização pode melhorar significativamente a precisão das previsões de retornos do mercado de ações

por meio de Redes Neurais Artificiais. Isso tem implicações importantes para a tomada de decisões financeiras e estratégias de investimento.

O terceiro artigo, intitulado "*Forecasting financial time series using a lowcomplexityrecurrent neural network andevolutionarylearning approach*", buscou explorar o uso de Functional Link Artificial Neural Networks (FLANNs) combinadas com métodos evolucionários para prever os preços das ações. O foco era determinar qual combinação de FLANN e método evolucionário resultaria em melhores previsões de preços de ações, comparando seu desempenho com outros métodos tradicionais de previsão (ROUT et al., 2017). O estudo não obteve um resultado conclusivo, mas mencionou a necessidade de futuras pesquisas para abordar problemas como multicolinearidade e explorar a previsão da direção do mercado usando outras técnicas e modelos. Isso indica que os pesquisadores sugeriram investigar tais questões nas variáveis selecionadas e também explorar a previsão da direção do mercado com abordagens diferentes além das utilizadas no estudo. Essas sugestões indicam possíveis direções para estudos futuros na mesma área.

O quarto artigo intitulado "*NSE Stock Market PredictionUsingDeep-Learning Models*" desenvolveu um modelo de previsão de preços de ações usando técnicas de redes neurais, especificamente quatro arquiteturas: *MultilayerPerceptron* (MLP), Redes Neurais Recorrentes (RNN), Memória de Curto Prazo de Longa Duração (LSTM) e Rede Neural Convolutiva (CNN). O foco era prever os preços das ações com base em seus históricos de preços, comparando o desempenho dessas redes neurais com modelos lineares (AR, MA, ARIMA, ARMA) e modelos não-lineares (ARCH, GARCH e Redes Neurais), com ênfase na avaliação da eficácia das redes neurais em comparação com o modelo ARIMA, amplamente utilizado na previsão.

Os resultados do estudo demonstraram que a Rede Neural Convolutiva (CNN) foi a arquitetura mais eficaz na previsão de preços das ações em comparação com outras arquiteturas de redes neurais e modelos lineares tradicionais, como o ARIMA. Além disso, a capacidade de transferência de aprendizado da CNN entre mercados (NSE e NYSE) sugere a existência de características semelhantes nos mercados de ações. Isso ressalta a eficácia das redes neurais profundas na previsão de preços de ações e a sua capacidade de capturar padrões complexos e não-lineares nos dados financeiros.

O quinto artigo analisado foi o "*Stock Market PredictionUsing LSTM Recurrent Neural Network*" construiu um modelo de previsão usando uma RNN baseada na arquitetura de LSTM. O modelo tinha como finalidade prever os valores futuros do mercado de ações para os ativos GOOGL e NKE, listados na Bolsa de Valores de Nova York (NYSE). O objetivo era verificar a precisão desse modelo de previsão em relação aos preços de abertura diários desses ativos ao longo de um determinado período de tempo (MOGHAR; HAMICHE, 2020).

Dado que os mercados financeiros são complexos e voláteis, o problema era encontrar uma abordagem que pudesse capturar padrões e tendências nos dados históricos para realizar previsões confiáveis. Os resultados do estudo indicaram que o modelo proposto, teve resultados promissores na tarefa de prever os valores futuros dos preços de abertura das ações GOOGL e NKE. Este foi capaz de acompanhar a evolução dos preços de abertura para ambos os ativos, conforme demonstrado pelos gráficos de comparação entre os valores reais de mercado e as previsões feitas pelo modelo.

O sexto artigo "*Stock ClosingPricePredictionusingMachine Learning Techniques*" desenvolveu e avaliou modelos de previsão para os preços de fechamento das ações no mercado financeiro. A pesquisa buscou analisar e comparar a eficácia de duas técnicas de previsão, a Rede Neural Artificial (RNA) e a Floresta Aleatória (RF), para prever os preços de fechamento das ações no dia seguinte. Além disso, a pesquisa também

procurou criar novas variáveis com base nas informações disponíveis, a fim de aumentar a precisão das previsões (VIJH et al., 2020).

A análise foi realizada em cinco empresas diferentes. A análise comparativa das métricas indicou que a Rede Neural Artificial (RNA) apresentou um desempenho superior em relação à Floresta Aleatória (RF), com valores mais baixos de RMSE, MAPE e MBE, indicando maior precisão nas previsões de preços de fechamento. No entanto, os resultados específicos variaram para cada empresa. Em resumo, a pesquisa concluiu que a RNA forneceu previsões mais precisas para os preços de fechamento das ações na maioria das empresas estudadas.

O sétimo artigo, intitulado "*Optimizing LSTM for time series prediction in Indian stock market*" analisou o desempenho de modelos de Aprendizado Profundo, a LSTM, na previsão de preços de ações. O estudo se concentra em duas áreas principais: a comparação entre LSTMs com estado (*stateful*) e sem estado (*stateless*) e a exploração do impacto do número de camadas ocultas em modelos LSTM na previsão de preços de ações. O objetivo foi identificar qual configuração de modelo LSTM e hiperparâmetros é mais eficaz na previsão de preços de ações em séries temporais (YADAV; JHA; SHARAN, 2020).

Os resultados do estudo indicam que os modelos LSTM sem estado são mais estáveis para previsão em séries temporais de preços de ações e que, em geral, uma única camada oculta é recomendada para a maioria dos problemas devido à maior precisão e menor risco de overfitting.

O oitavo artigo, intitulado "*Machine learning techniques and data for stock market forecasting: A literature review*," realizou uma revisão detalhada da literatura relacionada ao uso de técnicas de aprendizado de máquina na previsão de mercados de ações. Essa revisão abrangeu artigos publicados entre os anos 2000 e 2019 e explorou diversos aspectos, como os métodos de aprendizado de máquina utilizados, as variáveis dependentes e independentes dos conjuntos de dados financeiros, as tendências recentes e os avanços em técnicas de aprendizado profundo (KUMBURE et al., 2022).

Além disso, Kumbure et al. (2022) apontaram que revisões anteriores forneceram visões gerais, mas não se aprofundaram nesses aspectos. Portanto, o artigo visa preencher essa lacuna ao realizar uma análise minuciosa das técnicas de aprendizado de máquina, variáveis de entrada e dados em estudos revisados. Os resultados da revisão sistemática e análise dos artigos revelaram tendências de pesquisa, modelos de previsão mais utilizados, variáveis de entrada exploradas, mercados e índices estudados e o aumento no uso de análises de sentimentos em dados de fontes como notícias financeiras e mídias sociais. O artigo também discute suas próprias limitações, como o foco exclusivo em artigos de revistas e a exclusão de métodos estatísticos tradicionais.

O nono artigo, intitulado "*Predicting stock market index using LSTM*," avaliou modelos de previsão para os preços de ações do índice S&P 500, utilizando redes neurais recorrentes LSTM. O objetivo central foi criar modelos de previsão precisos capazes de lidar com a complexidade e volatilidade dos dados de preços de ações do índice S&P 500, além de comparar o desempenho de diferentes arquiteturas de modelos LSTM (BHANDARI et al., 2022).

Os resultados do estudo indicam que a LSTM com uma única camada oculta e cerca de 150 neurônios foi capaz de fornecer previsões superiores em comparação com modelos de múltiplas camadas. A avaliação foi baseada em métricas de desempenho, como RMSE, MAPE e R. Os resultados também foram apoiados por análises estatísticas que demonstraram que a proposta superou significativamente os modelos de múltiplas camadas em termos de previsão do preço de fechamento do índice S&P 500.

O décimo artigo, intitulado "*The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction*" buscou compreender como esses modelos de aprendizado de máquina podem ser aplicados para prever movimentos futuros de preços de ações no mercado de ações. Além disso, o estudo visa analisar o desempenho desses modelos em diferentes cenários e conjuntos de dados e determinar qual deles é mais eficaz para essa finalidade. O trabalho também discute desafios e oportunidades futuras relacionadas à utilização de aprendizado de máquina na previsão do mercado de ações (CHAAJER; SHAH; KSHIRSAGAR, 2022).

Esses modelos foram capazes de processar dados históricos e gerar previsões promissoras para os movimentos de preços no mercado de ações, sendo que, conforme Chaaier, Shah e Kshirsagar (2022), esses processam rapidamente dados históricos, tendências e gráficos, fornecendo orientações para o futuro.

Assim, é evidente que as RNAs, mais especificamente as RNNs como a LSTM, são frequentemente escolhidas como uma das técnicas mais eficazes na previsão de séries temporais de preços de ações. Sua capacidade de capturar dependências temporais complexas se mostra valiosa em um ambiente volátil como o mercado de ações.

5. Considerações Finais

O presente estudo realizou uma revisão de literatura sobre a previsão de mercado de ações através das Redes Neurais Artificiais. Através dessa análise abrangente concluiu-se que existe uma grande diversidade de abordagens e técnicas empregadas nesse campo, desde Redes Neurais Artificiais (ANN) até Máquinas de Vetor de Suporte (SVM) e Memória de Longo e Curto Prazo (LSTM).

No entanto, foi possível evidenciar que, apesar da grande diversidade de ferramentas disponíveis para a previsão de preços de ações, as redes neurais recorrentes, especialmente os modelos LSTM, destacaram-se como escolhas populares devido à sua capacidade de capturar dependências temporais complexas.

Além disso, a otimização de parâmetros, incluindo o número de camadas ocultas, neurônios e épocas de treinamento, demonstra ser uma área de pesquisa significativa. A escolha adequada desses parâmetros pode resultar em previsões mais precisas e robustas. A pesquisa também destaca a importância da comparação entre diferentes modelos de aprendizado de máquina. Através de tais comparações, os pesquisadores podem identificar quais algoritmos são mais eficazes para tarefas específicas de previsão.

Por este viés, através das análises, foi possível verificar que, esse campo de pesquisa continua a evoluir, com desafios e oportunidades futuras, haja vista que, os mercados financeiros são notoriamente voláteis e complexos, o que exige constantemente abordagens adaptativas e inovadoras. Portanto, a pesquisa futura pode se concentrar em incorporar análises de dados mais sofisticadas, considerar mercados e regiões adicionais e explorar modelos híbridos mais avançados.

Referências

BHANDARI, H. N. et al. Predicting stock market index using LSTM. *Machine Learning with Applications*, n. 2666-8270, p. 100320, mai. 2022.

CHAAJER, P.; SHAH, M.; KSHIRSAGAR, A. The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction. *Decision Analytics Journal*, p. 100015, nov. 2021.

- HIRANSHA, M. et al. NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science*, v. 132, n. 1877-0509, p. 1351–1362, 2018.
- KUMBURE, M. M. et al. Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, v. 197, p. 116659, jul. 2022.
- MOGHADDAM, A. H.; MOGHADDAM, M. H.; ESFANDYARI, M. Stock market index prediction using artificial neural network. *Journal of Economics, Finance and Administrative Science*, v. 21, n. 41, p. 89–93, dez. 2016.
- MOGHAR, A.; HAMICHE, M. Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science*, v. 170, p. 1168–1173, 2020.
- PAGANI, R. N.; KOVALESKI, J. L.; RESENDE, L. M. MethodiOrdinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. *Scientometrics*, v. 105, n. 3, p. 2109–2135, 2015.
- QIU, M.; SONG, Y.; AKAGI, F. Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market. *Chaos, Solitons & Fractals*, v. 85, n. 0960-0779, p. 1–7, abr. 2016.
- ROUT, A. K. et al. Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach. *Journal of King Saud University - Computer and Information Sciences*, v. 29, n. 4, p. 536–552, out. 2017.
- VIJH, M. et al. Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, v. 167, n. 167, p. 599–606, 2020.
- YADAV, A.; JHA, C. K.; SHARAN, A. Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, v. 167, n. 1877-0509, p. 2091–2100, 2020.