

AVALIAÇÃO DE MODELOS DE PREVISÃO DOS VALORES DAS AÇÕES NO MERCADO FINANCEIRO USANDO APRENDIZADO DE MÁQUINA

André Augusto de Almeida Machado¹; Geraldo Nunes Corrêa²

Resumo

A previsão dos movimentos dos preços das ações tem sido uma área importante na pesquisa de algoritmos de aprendizado de máquina nos últimos anos devido ao seu conteúdo complexo e dinâmico. Este artigo tem como objetivo fornecer um estudo de caso através da criação e avaliação de modelos de previsão de preços de ações no mercado brasileiro. O artigo também propõe comparar a previsão dos três modelos de aprendizado de máquina conhecidos como PROPHET, LSTM e ARIMA. Observou-se que os métodos com melhores resultados foram o LSTM e o ARIMA. Menores MSE, RMSE e MAPE foram obtidos no experimento com ARIMA. Consequentemente, é possível a utilização de métodos de inteligência artificial no mercado brasileiro.

Palavras-chave: aprendizado de máquina; previsão; preços; modelos.

Abstract

Forecasting stock price movements has been an important area in machine learning algorithm research in recent years due to its complex and dynamic content. This article aims to provide a case study through the creation and evaluation of stock price prediction models in the Brazilian market. The article also proposes to compare the prediction of the three machine learning models known as PROPHET, LSTM and ARIMA. It was observed that the methods with the best results in quotation are LSTM and ARIMA. Lower MSE, RMSE and MAPE were obtained in the ARIMA experiment. Consequently, it is possible to use artificial intelligence methods in the Brazilian market.

keywords: machine learning; prediction; price; models.

1 Introdução

O mercado financeiro é um ambiente instável e imprevisível diariamente, devido a muitas variáveis que influenciam o valor de mercado no dia, assim como, sentimentos dos investidores, decisões políticas e situações econômicas. Dessa forma, o mercado financeiro gera mudanças rápidas, causando oscilações nos preços das ações. No entanto, do ponto de vista estatístico, existem padrões nos dados e propriedades recorrentes que permitem a extração de informações relevantes e específicas sobre uma atividade (ANTONIK, 2004).

O mercado financeiro é uma alternativa financeira para maiores ganhos, por outro lado também traz maiores riscos. Atualmente, utilizando recursos de Inteligência Artificial é possível realizar análises preditivas de preços com base em séries históricas de valores do

¹ Graduando em Sistemas de Informação pela Universidade do Estado de Minas Gerais-UEMG, unidade Frutal. Email: andre.1093179@discente.uemg.br.

² Doutor em Engenharia Mecânica pelo Departamento de Engenharia de Produção da Universidade de São Paulo-USP; professor da Universidade do Estado de Minas Gerais-UEMG, unidade Frutal. Email: geraldo.correa@uemg.br.

fechamento de cada atividade. Diferentes algoritmos de aprendizado de máquina podem ajudar na previsão de tendências de movimento futuro. No entanto, o mercado financeiro é especulativo e as notícias podem causar uma reversão de tendências em questão de minutos (DEFACIO; BRONZATI, 2019).

No mercado financeiro, as empresas *Blue Chips* são as empresas mais negociadas na bolsa e possuem o maior valor de mercado e são menos voláteis. Essas empresas referem-se a ativos com alto índice de qualidade, caracterizada pela liquidez e rentabilidade, conseqüentemente, são as mais procuradas pelos investidores para a formação de carteiras. As empresas de grande valor de mercado são consideradas como a melhor relação risco / recompensa, sendo adequadas para investidores de longo prazo. Para este trabalho foram utilizados os índices PETR4, ABEV3, CMIG4, ITUB4, VALE3, por serem empresas amplamente reconhecidas, ações estáveis e grande importância na sua área de atuação (DE ANDRADE et al., 2013).

Tendo em vista que, existem as chamadas *Small Caps* representam empresas cujo fluxo de caixa aumenta fortemente devido à maturação de projetos antigos ou novos projetos com retornos acima da média de mercado. As *Small Caps* geralmente possuem menor liquidez e não estão correlacionadas com o Índice Ibovespa. As ações das *Small Caps* apresentam maior risco, pois são ações de empresas que não estão totalmente consolidadas. Como essas empresas estão investindo para crescer, elas têm um potencial de valorização muito maior. Nesse sentido, os ativos usados neste artigo foram TOTS3, ENEV3, MOVI3, ARZZ3 e CAML3 (DE ANDRADE et al., 2013).

Existem duas linhas principais de raciocínio ao criar uma estratégia de negociação de preços de ações: análise fundamental e probabilística. A análise fundamental assume que o valor das ações de uma empresa é determinado por fatores econômicos e pelo desempenho financeiro da empresa. A análise de probabilidade acredita que todas as informações utilizáveis já estão embutidas no preço das ações, por isso é possível usar dados passados para estimar valores futuros.

Segundo Malta e Camargos (2016), a análise fundamental é a mais tradicional e a mais longa em uso, considerada mais confiável por analistas de mercado e profissionais de mercado. Essa abordagem consiste, portanto, em dados econômicos e financeiros derivados do ambiente econômico em que a empresa atua e resultados operacionais decorrentes de suas operações.

A previsão probabilística é uma maneira de olhar para o futuro com base em dados passados. Já existe há algum tempo, mas recentemente ganhou popularidade no mundo dos negócios, porque ajuda as empresas a tomar melhores decisões mais rapidamente do que os métodos tradicionais de planejamento. A previsão probabilística envolve o uso de dados

passados para prever o nível que ocorrerá no futuro com um alto grau de certeza (BESSA, 2021).

De acordo com Teixeira (2019), o aprendizado de máquina é um ramo da inteligência artificial que usa computadores para aprender dados com base em modelos. Do mesmo modo, pode ser usado para identificar padrões em grandes dimensões de dados que podem ser usados para aprender regras explicitamente. Trabalhos recentes Martins e Napoleão (2021), abordam que o aprendizado de máquina é mais preciso do que os métodos tradicionais de previsão e é mais veloz que os métodos tradicionais. Isso ocorre porque não há necessidade de preencher o modelo programado por humanos para cada previsão. Em outras palavras, quando se usa o aprendizado de máquina não precisa de um analista que saiba codificar, apenas nutre seus dados.

Considerando o contexto apresentado, este trabalho propõe a previsão de preços do mercado de ações, assim, tornar possível uma tomada de decisão mais assertiva dos operadores financeiros em relação à compra ou venda.

A implementação do projeto envolve o uso de algoritmos de aprendizado de máquina dos modelos PROPHET, memória de curto prazo (LSTM) e ARIMA, utilizando a plataforma Google Colab e Python, as previsões utilizando séries de preço de fechamento dos índices PETR4, ABEV3, CMIG4, ITUB4, VALE3, TOTS3, ENEV3, MOVI3, ARZZ3 e CAML3. Conseqüentemente, o desempenho de cada modelo é avaliado separadamente.

A partir deste ponto, um estudo pode ser realizado no conjunto de dados históricos das empresas *Blue Chips* e *Small Caps* e verificar o melhor modelo a ser empregado no mercado de ações no auxílio da tomada de decisões de compra e venda.

2 Referencial Teórico

Segundo Silveira (2021), as séries temporais têm vários recursos importantes, como tendência, sazonalidade e ruído. Previsão é o processo de fazer previsões do futuro, com base em dados passados e presentes. Aqui neste trabalho, será realizada a análise de séries temporais nos dados históricos do preço das ações das *Blue chips* e *Small Caps*. Os preços das ações trabalhadas foram bastante voláteis e inconsistentes ao longo dos anos. É muito difícil realizar análises de séries temporais em dados tão voláteis. Mas aqui explora os diferentes modelos de previsão de séries temporais.

Para a previsão foram aplicados três métodos diferentes de aprendizado de máquina, aplicando scripts Python e bibliotecas específicas, a saber: ARIMA (RYLL; SEIDENSO, 2019), PROPHET do Facebook (SHEN et al., 2020) e LSTM (YU et al., 2019).

E para analisar a acurácia de cada algoritmo de aprendizado, 3 medidas foram utilizadas: o erro absoluto médio (MAE) que mede a diferença média entre os valores reais e estimados, o erro quadrático médio (RMSE) nesta equação há o cálculo da diferença entre o valor y e \hat{y} , contudo com a elevação do resultado ao quadrático e o erro percentual absoluto médio (MAPE) é uma medida que mostra o erro percentual em relação ao valor verdadeiro (DIEBOLD, 1998).

Com o objetivo de analisar algumas das diferentes formas de fazer previsões no mercado de ações, esta seção apresenta alguns trabalhos relacionados ao tema destacando as semelhanças e diferenças em relação ao que foi desenvolvido neste trabalho e quais foram os resultados.

Os dados do mercado de ações são um exemplo de dados instáveis. Em certos momentos, pode haver tendências, ciclos, um passeio aleatório ou uma combinação dos três. É desejável que se o ano dado for cíclico o modelo pode seguir esse padrão. No entanto, os valores das ações para o ano inteiro não são isolados e existem dias de passeio aleatórios. Também é possível que os preços sejam influenciados por fatores externos, como cenários políticos e a atual situação econômica do país (CERETTA; VIEIRA 2010).

A hipótese do mercado financeiro eficiente apresentada por Mussa et al. (2010), afirma que é possível prever os preços das ações desde que as informações sejam eficientes. Vários métodos foram desenvolvidos para prever suas tendências, entre eles estão redes neurais artificiais.

Os autores Defacio e Bronzati (2019), realizaram estudos sobre dois modelos de predição para o mercado financeiro sobre o modelo PROPHET e os autores concluíram que o modelo visa capturar tendências e estações a partir de dados históricos. Embora este modelo em geral alcance resultados satisfatórios de desempenho para séries temporais. Sobre o modelo ARIMA demonstram que o principal pré-requisito é que a série analisada seja o mais estacionária possível para que uma previsão válida possa ser feita com maior certeza.

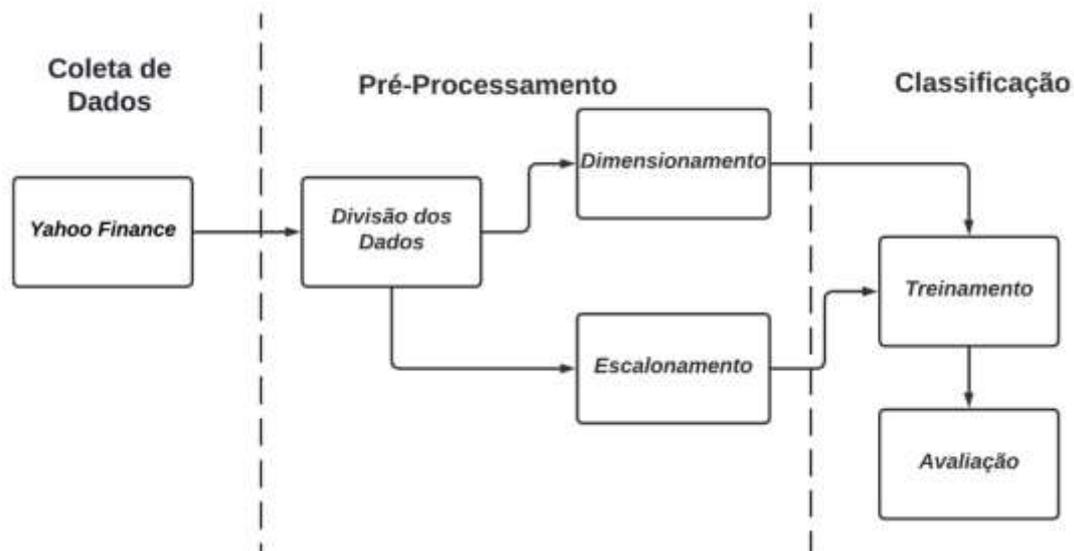
O trabalho de Ozbayoglu et al. (2020), relaciona o uso de Memória de curto prazo (LSTM) ou memória de curto prazo de longo prazo com redes neurais recorrentes. No contexto é um método de aprendizado profundo projetado especificamente para análise sequencial de dados, como séries temporais. Caracteriza-se pela capacidade de lembrar dados de curto e longo prazo.

3 Metodologia

O trabalho é uma pesquisa exploratória, cujo objetivo é examinar, compreender e aplicar técnicas de *Machine e Deep Learning* no contexto de processamento de dados financeiros, a fim de construir modelos preditivos para o valor de fechamento de ações.

A figura 1 ilustra as etapas executadas para o desenvolvimento desse projeto.

Figura 1 - Etapas do método proposto



Fonte: Elaborado pelos autores.

Observando as etapas ilustradas na Figura 1. A base de dados utilizada neste trabalho foi coletada de 2017 a 2022, por meio do site *yahoo finance*, utilizando ações de *Blue chips* e *Small Caps*. Desta forma, os dados foram obtidos diariamente com os valores índices de fechamento, abertura, alta, baixa e volume para os seguintes ativos da bolsa brasileira: PETR4, ABEV3, CMIG4, ITUB4, VALE3, TOTS3, ENEV3, MOVI3, ARZZ3 e CAML3.

No pré-processamento, os casos omissos foram imputados pelo método de interpolação linear sempre que possível. O valor mais frequente no recurso é usado para imputação. A divisão dos dados para todos os modelos de regressão foi dividida em dois conjuntos, um conjunto de treinamento e um conjunto de validação, 20% dos dados são armazenados para validação e 80% dos dados são usados para treinamento.

Para todos os modelos de categorização, o conjunto de dados é dividido linearmente em dois conjuntos para treinamento e validação. Os primeiros 80% dos dados são alocados ao conjunto de treinamento e os últimos 20% são mantidos para validação.

Para treinar o modelo LSTM foram utilizados métodos de dimensionamento eficientes, seguido pelo método de escalonamento. Com *StandardScaler*, os recursos são deslocados entre 0 e 1, preservando a magnitude relativa dos valores discrepantes. Um método não paramétrico, onde não tem dependência de parâmetros, tem dimensionamento eficiente usa o intervalo mediano e o intervalo interquartil para dimensionar os dados. Os parâmetros de metrologia foram ajustados usando o conjunto de treinamento e convertidos em conjuntos de treinamento e validação.

O treinamento dos modelos PROPHET e ARIMA estão descritos a seguir, demonstrando os métodos utilizados para a modelagem do algoritmo de aprendizado de máquinas na obtenção de previsões de valores futuros.

Para moldar o PROPHET, foram notados dados diários de alguns meses de história, além da sazonalidade, a tendência de crescimento não linear, de modo que o modelo de série temporal é decomposto em três componentes principais: tendência, sazonalidade e feriados. A criação de um modelo previsão, necessita apenas de um *dataframe* composto por duas colunas DS e Y, onde DS representa a data e Y é a medida que quer prever.

Em seguida, é realizada a construção de um novo quadro de dados agrupado por dias e no formato fornecido pelo PROPHET (com colunas DS e Y). O quadro de dados é preparado em um formato admitido. Modelo de previsão é empregado para previsões com base em um modelo treinado, criando um *dataframe* com datas futuras para o intervalo de tempo que se deseja prever.

No modelo ARIMA, primeiro determina-se os valores de p, d e q, para ter tudo o que precisa para ajustar o modelo. O modelo é treinado no valor anterior para fazer a próxima previsão, o que pode revisar previsões e dados reais, sendo modelo paramétrico que produz estimativas com maior precisão, destaque na análise probabilística ou estocástica na série temporal.

Para avaliar os modelos de regressão utilizou métricas de amostragem de erro, em suma para analisar a diferença do valor real com o previsto, as métricas utilizadas foram: O erro absoluto médio (MAE), o erro quadrático médio (RMSE) e o erro percentual absoluto médio (MAPE).

4 Experimentos e Resultados

Os modelos citados foram treinados para gerarem as previsões. Desse modo foi possível observar o comportamento das previsões nos diferentes modelos. Os quadros 1 e 2 exibem os resultados obtidos para os modelos pesquisados.

Ao analisar os resultados obtidos, em relação às métricas de erro como ilustra a tabela 1.

Quadro 1 - Métricas de erro referente às *Blue Chips*.

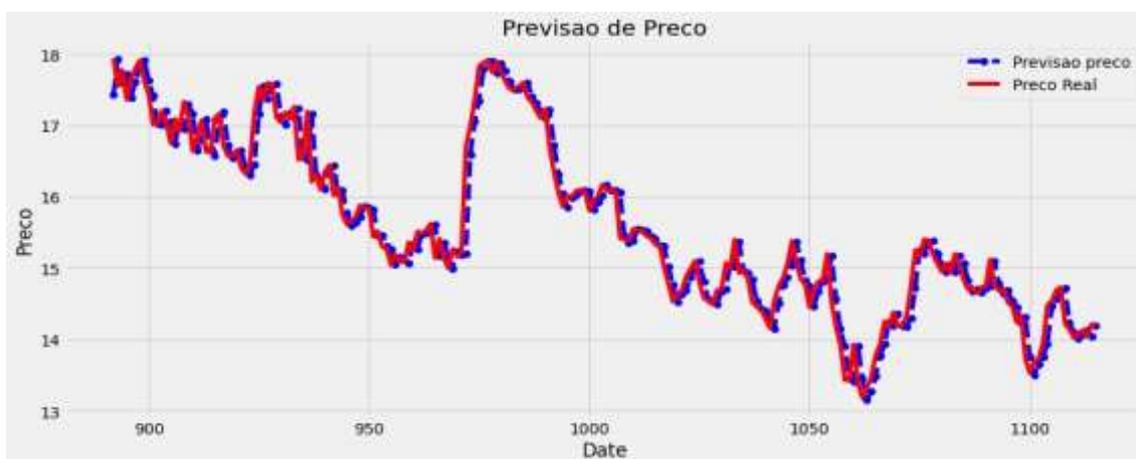
BLUE CHIPS				
Ativo	Modelo	MAE	RSME	MAPE
PETR4	PROPHET	2.641	3.128	8.786
ABEV3	PROPHET	3.439	04.06	22.871
CMIG4	PROPHET	0.92	1.144	8.998
ITUB4	PROPHET	5.642	6.62	22.931
VALE3	PROPHET	56.653	64.322	68.389
PETR4	LSTM	0.72	0.919	2.395

ABEV3	LSTM	0.286	0.376	1.838
CMIG4	LSTM	0.348	0.417	3.296
ITUB4	LSTM	0.498	0.686	1.975
VALE3	LSTM	2.763	3.667	3.232
PETR4	ARIMA	0.546	0.774	1.838
ABEV3	ARIMA	0.201	0.275	1.287
CMIG4	ARIMA	0.146	0.194	1.41
ITUB4	ARIMA	0.367	0.563	1.429
VALE3	ARIMA	1.592	2.16	1.853

Fonte: Elaborada pelos autores.

Analisando a quadro 1 é possível observar que o modelo PROPHET apresentou o pior desempenho para as Blue chips. De uma forma geral, LSTM e ARIMA foram os modelos que apresentaram os melhores resultados, sendo o ativo ABEV3 que apresentou melhores resultados na avaliação das 3 métricas, como mostra a Figura 2.

Figura 2 - Modelo ARIMA referente ao ativo ABEV3.



Fonte: Elaborada pelos autores.

Verificando a figura 2 é demonstrado uma acurácia de 94,82% de coeficiente de determinação. De outro lado, o modelo ARIMA obteve menor erro (CMIG4). No entanto, o índice VALE3 apresentou as maiores métricas de erro dos três modelos.

Segundo [Souto, 2021] era esperado que o experimento utilizando LSTM fornecesse melhores resultados, dado que é considerado o melhor modelo para o trabalho com séries temporais. Porém o modelo ARIMA obteve melhores resultados entre os três modelos avaliados.

Os resultados métricos observados referente às ações das *Small Caps*, como mostra o quadro 2.

Quadro 2 - Métricas de erro das *Small Caps*

SMALL CAPS				
Ativo	Modelo	MAE	RSME	MAPE
TOTS3	PROPHET	4.433	5.472	14.524
ENEV3	PROPHET	5.7	6.659	40.677

MOVI3	PROPHET	4.183	4.951	25.556
ARZZ3	PROPHET	19.616	22.644	24.612
CAML3	PROPHET	2.001	2.397	21.158
TOTS3	LSTM	0.915	1.15	2.83
ENEV3	LSTM	0.379	0.491	2.599
MOVI3	LSTM	0.513	0.643	3.001
ARZZ3	LSTM	2.705	3.364	3.322
CAML3	LSTM	0.206	0.292	2.153
TOTS3	ARIMA	0.67	0.863	2.074
ENEV3	ARIMA	0.261	0.328	1.793
MOVI3	ARIMA	0.38	0.475	2.217
ARZZ3	ARIMA	1.492	1.912	1.836
CAML3	ARIMA	0.157	0.221	1.648

Fonte: Elaborada pelos autores.

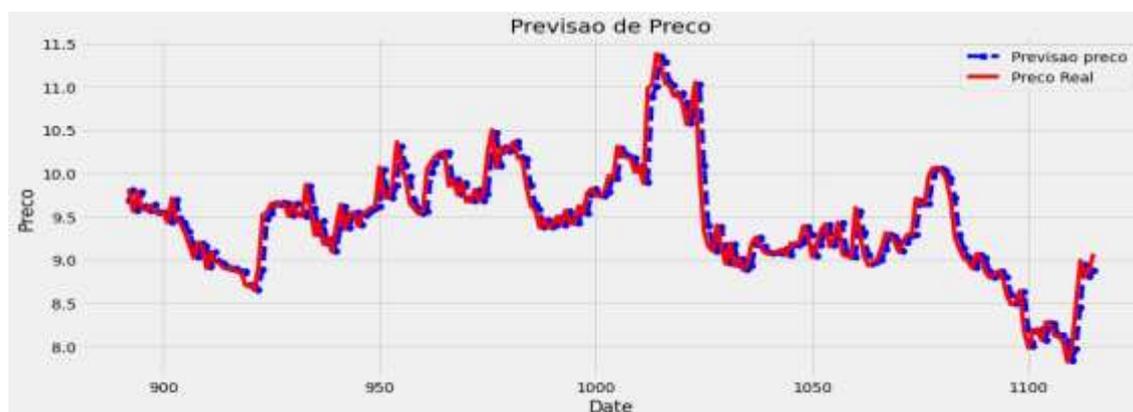
O modelo PROPHET para os ativos TOTS3, ENEV3, MOVI3, ARZZ3 e CAML3 são expostas na Tabela 2. O modelo foi desenvolvido com parâmetros padrão. Em relação ao modelo PROPHET o desempenho ficou abaixo do modelo ARIMA nos primeiros dias, para o componente ARZZ3 não foi capaz de prever a tendência. outros ativos, o modelo foi capaz de prever a tendência dos preços com menor erro.

A previsão feita pelo modelo LSTM, onde se percebe que ele foi capaz de afinar as flutuações de erro e por isso foi possível prever a tendência de alta ou baixa para os ativos TOTS3, ENEV3, MOVI3, ARZZ3 e CAML3. Este modelo apresentou um resultado satisfatório com menor MAE, MAPE e RMSE.

Previsão do modelo ARIMA utilizando os ativos TOTS3, ENEV3, MOVI3, ARZZ3 e CAML3. Pode-se concluir que o modelo foi capaz de prever o desenvolvimento correspondente dos preços dos ativos. Este modelo foi capaz de afinar séries temporais, por isso foi considerado ideal para fazer previsões financeiras de séries temporais, pois pode prever a tendência de preços com menor erro.

Finalmente com o último modelo a ser avaliado, observa-se que o modelo ARIMA o índice CAML3 obteve menor valor de MAE, RSME e MAPE, Figura 3 ilustra.

Figura 3 - Modelo ARIMA referente ao ativo CAML3.



Fonte: Elaborada pelos autores.

Observando a figura 2 é verificado uma acurácia de 87.60% de coeficiente de determinação. Ao analisar os resultados e comparar com os valores obtidos em experimentos anteriores, verificou-se que a assertividade do modelo ARIMA teve um resultado consideravelmente melhor, superior ao LSTM e PROPHET. Isso ocorre porque os mercados financeiros são altamente imprevisíveis e complexos. Algoritmos baseados em linearidade são, portanto, inconsistentes na previsão. Os padrões têm melhor confirmação em mercados de consolidação, onde o ativo não sofre altas ou baixas abruptas de período para período.

Comparando os resultados obtidos durante os experimentos usando os algoritmos LSTM e ARIMA, pôde-se observar níveis de confiança semelhantes. Quanto ao PROPHET, a previsão pode ser considerada insatisfatória ao contexto do mercado financeiro, com valores muito altos ou muito baixos.

No entanto, apesar dos modelos ARIMA e o LSTM terem alcançado melhores desempenhos para a maioria das previsões, anomalias de mercado podem resultar de pessimismo inexplicável ou otimismo infundado e, assim, grandes oscilações de preços implicam diretamente nos resultados das previsões realizadas em tais modelos. Desta forma, os parâmetros técnicos especificados para a avaliação não foram capazes de detectar tais anomalias.

5 Conclusões

Conforme a análise realizada na seção anterior, pode-se observar que, apesar da volatilidade do mercado, existe uma aderência mais adequada de um modelo a uma categoria de ativos no mercado financeiro. Nos últimos anos, as técnicas de aprendizado de máquina provaram ser eficazes na previsão dessas ações.

Este artigo comparou três modelos comumente usados hoje: PROPHET, LSTM e ARIMA. A partir deste estudo, métodos como LSTM e ARIMA podem ser considerados como eficazes na previsão de preços de ações. Dessa forma, esses dois modelos, podem ser considerados como suporte por tomadores de decisão no mercado financeiro.

O modelo PROPHET mostrou pouca capacidade de alcançar a precisão dos demais algoritmos mencionados. Ao analisar os resultados do modelo PROPHET nos parâmetros técnicos selecionados, pode-se ver uma confirmação ineficiente no processo de previsão.

Por fim, o modelo ARIMA apresentou os melhores resultados na previsão de preços tanto para ativos considerados *Blue Chips* como *Small Caps*. No entanto, cabe ressaltar que, cada ativo possui um comportamento, onde um modelo deve ser considerado mais apropriado para cada tipo de ativo.

Referências

DE ANDRADE, G. C; SANCHES, A. L. Otimização de Blue Chips com Small Caps na Formação de Carteiras Utilizando a Teoria de Markowitz e o Modelo Capm. **X SEGeT., Brasília**, p. 1-16, 2013.

ANTONIK, L. R. Análise de projetos de investimento sob condições de risco. **Revista da FAE**, v. 7, n. 1, 2004.

BESSA, J. C. M. Otimização de estratégias de oferta em mercado usando previsão probabilística de produção renovável. 2021.

CERETTA, P.S; VIEIRA, K.M. Efeito Dia-Da-Semana no Mercado Brasileiro: Uma Análise Sob a Ótica Da Liquidez, do Retorno e da Volatilidade. **REAd-Revista Eletrônica de Administração**, v. 16, n. 3, p. 544-563, 2010.

DEFACIO, F.S; BRONZATI, Vitor Ribeiro. **Mercado de ações: estudo da previsibilidade utilizando séries temporais aplicadas em machine learning**. 2019. 18f. Trabalho de Conclusão de Curso (Escola de Engenharia Mackenzie) Universidade Mackenzie, São Paulo, 2019.

DIEBOLD, F. X. **Elementos de previsão**. Cincinnati, OH, EUA: South-Western College Pub., 1998.

MUSSA, A. et al. Hipótese de mercados eficientes e finanças comportamentais: as discussões persistem. **FACEF Pesquisa-Desenvolvimento e Gestão**, v. 11, n. 1, 2010.

MALTA, T.L; DE CAMARGOS, M.A. Variáveis da análise fundamentalista e dinâmica e o retorno acionário de empresas brasileiras entre 2007 e 2014. **REGE-Revista de Gestão**, v. 23, n. 1, p. 52-62, 2016.

MARTINS, E; NAPOLEÃO V. G. Uma Análise Comparativa Entre Os Métodos Tradicionais e Algoritmos de Aprendizagem de Máquinas Para Previsão de Vendas No Segmento Varejista. **XVI Simpósio dos Programas de Mestrado Profissional Unidade de Pós-Graduação, Extensão e Pesquisa**. Centro Paula Souza, São Paulo. p. 831- 849, 2021

OZBAYOGLU, A.M; GUDELEK, M.U; SEZER, O. B. Aprendizado profundo para aplicações financeiras: uma pesquisa. **Computação Soft Aplicada**, v. 93, p. 106384, 2020.

RYLL, L.; SEIDENS, S. Avaliando o desempenho de algoritmos de aprendizado de máquina na previsão do mercado financeiro: uma pesquisa abrangente. **arXiv preprint arXiv:1906.07786**, 2019.

SHEN, J.; VALAGOLAM, D.; MCCALLA, S. Modelo de previsão do profeta: uma abordagem de aprendizado de máquina para prever a concentração de poluentes atmosféricos (PM2. 5, PM10, O3, NO2, SO2, CO) em Seul, Coreia do Sul. **PeerJ**, v. 8, p. e9961, 2020.

SOUTO, G. et al. Avaliação dos diferentes tipos de redes LSTM para predição de ações na bolsa de valores. In: **Anais da IV Escola Regional de Informática do Rio de Janeiro**. SBC, 2021. p. 65-71.

SILVEIRA, R. B. Avaliação de modelos preditivos para o mercado de ações utilizando machine e deep learning. 2021 18f. Trabalho de Conclusão de Curso (Ciência da Computação) Centro de Ciências Exatas e Engenharias - Universidade de Caxias do Sul-UCS, Caxias do Sul, 2021.

TEIXEIRA, João. **O que é inteligência artificial**. E-Galáxia, 2019.

YU, Y. Uma revisão de redes neurais recorrentes: células LSTM e arquiteturas de rede. **Computação neural**, v. 31, n. 7, pág. 1235-1270, 2019.