

Previsão de Preços de Ações Utilizando Inteligência Artificial

Oberis S. Nascimento¹, Felipe G. Santos¹, Karl Hansmuller A. Ferreira¹

¹Departamento de Tecnologia - Instituto Federal de Educação, Ciência e Tecnologia do Piauí (IFPI) – Campus Corrente – Corrente – PI - Brasil

{oberis2010@gmail.com, felipe.santos@ifpi.edu.br, karl.allelaf@ifpi.edu.br}

Abstract. *The use of artificial intelligence can, through time series data analysis, predict the trend of stock prices and help decision making. This paper aimed to analyze and apply data analysis techniques using artificial intelligence to predict trends in stock prices and help investors about which decision to make when buying or selling. Three machine learning algorithms were used: ARIMA, PROPHET and LSTM, where all the tests were performed in Google Colab. After defining the best model, a web application called The Seer was developed using the Django framework, which allowed for easier forecasting. The models were validated based on the daily closing values of two stocks and one ETF traded on the BM&F Bovespa. Both models obtained better results for periods of up to 60 days, and the ARIMA and PROPHET models obtained better accuracy for periods of up to 30 days. The LSTM model obtained better RMSE and MAPE metrics for the 90 days observed. Finally, it can be concluded that the work achieved the proposed objective.*

Keywords: *Arima. Prophet. Lstm. machine learning.*

Resumo. *O uso da Inteligência artificial pode por meio de análise de dados de séries temporais conseguir prever a tendência dos preços das ações possibilitando ajudar na tomada de decisões. O presente artigo teve como objetivo analisar e aplicar técnicas de análise de dados utilizando inteligência artificial para prever tendências dos preços das ações e auxiliar os investidores sobre qual decisão tomar na hora de comprar ou vender. Utilizou-se três algoritmos de aprendizagem de máquina ARIMA, PROPHET e LSTM, onde todos os testes foram realizados no Google Colab e posteriormente após definir o melhor modelo foi elaborado uma aplicação web denominada The Seer com uso do framework Django o que possibilitou a realização das previsões com mais facilidade. A validação dos modelos foi realizada com base nos valores fechamento diário de duas ações e uma ETF negociadas na BM&F Bovespa. Ambos os modelos conseguiram melhor resultado para o período de até 60 dias, sendo que os modelos ARIMA e PROPHET conseguiram melhor precisão para um período de até 30 dias. O modelo LSTM obteve melhor métrica RMSE e MAPE para os 90 dias observado. Por fim pode concluir que o trabalho conseguiu atingir o objetivo proposto.*

Palavras-chave: *Arima. Prophet. Lstm. Aprendizagem de máquina.*

1. Introdução

O número de investidores na bolsa de valores brasileira tem aumentado nos últimos anos, contribuindo significativamente para a economia do país. Porém, esse tipo de investimento nem sempre consegue o resultado que o investidor espera, podendo ser frustrado devido às variações repentinas nos preços das ações (D'ÁVILA 2021). Para conseguir lucrar nesse tipo de investimento, os investidores procuram ferramentas que possam auxiliar na tomada de decisões, determinando qual o melhor momento para compra ou venda de ações (SOUZA, 2021).

Uma das maneiras de minimizar os riscos é tentar prever o mercado fazendo pesquisas em sites, analisando as oscilações dos dias anteriores para fazer estimativa futura do preço, porém o mercado de ações ainda é muito complexo e o preço destas são influenciados por

diversos fatores, tais como, valorização ou desvalorização da empresa, tendências de mercado, aumento de capital, questões políticas, entre outros. Realizar uma simples análise superficial com base em pesquisas em sites ou analisando as oscilações dos dias anteriores nem sempre possibilitará uma previsão do preço (HAYASHI, 2017).

Existem vários estudos que buscam compreender as variações nos preços das ações para poder prever o melhor momento para transação e, com avanço da tecnologia principalmente voltado para a área da Inteligência Artificial (IA), diversos modelos de previsões vêm sendo desenvolvidos e utilizados no processo de análise de dados sobre compra e venda de ações na bolsa de valores (VILELA; PENEDO; PEREIRA, 2018).

Segundo Castro e Ferrari (2016), a IA busca por meio de recursos computacionais solucionar problemas de alta complexidade, algo observado no processo de análise de dados. O uso da IA nesse processo tem como objetivo descobrir por meio de dados históricos sobre valores das ações trazer uma previsão de preços futuros. Nesse processo o uso das redes neurais tem sido bastante utilizado devido a sua capacidade de aprendizado.

A utilização da IA para previsão de preços de ações pode minimizar as perdas nas transações, assim, muitos pesquisadores e investidores buscam desenvolver sistemas que possam prever os preços das ações e assim auxiliar na tomada de decisões. Com base nessas informações o presente artigo teve como objetivo analisar e aplicar técnicas de análise de dados utilizando IA para prever tendências dos preços das ações e auxiliar os investidores sobre qual decisão tomar na hora de comprar ou vender.

2. Referencial Teórico

2.1 Mercado Financeiro

As comercializações no Brasil das ações de empresas com capital aberto são organizadas através da bolsa de valores BM&F Bovespa, conhecida como B3 (Brasil, Bolsa, Balcão). As corretoras são responsáveis por intermediar a negociação dos ativos por meio de plataforma de negociação, onde é possível realizar operações de compra e venda de ações. No mercado brasileiro existem dois tipos de ações: as ordinárias e as preferenciais. Quando um investidor adquire ações ordinárias o mesmo pode influenciar nas decisões da empresa por meio de voto, além de receber dividendos, já as ações preferenciais o investidor tem direito a alguns privilégios, como recebimento dos dividendos, porém não participa das decisões da empresa (ASSAF, 2018).

O preço de uma ação na bolsa de valores normalmente é decorrente da oferta e demanda do mercado, porém pode variar muito quando há interferência de fatores econômicos ou políticos, tornando a tarefa de previsão dos preços ainda mais difícil (MESQUITA, 2019).

2.2 Séries Temporais

Uma Série Temporal (ST) é definida como sendo uma sequência de valores ao longo do tempo e pode servir de base para realizar previsões futuras, onde a ordem dos dados importa e cada valor é dependente dos valores anteriores (VASCO, 2020). A ST pode ser estacionária ou não-estacionária, a diferença entre uma e outra é que nas ST estacionária o tempo não altera as suas propriedades, ou seja, é possível perceber uma estabilidade dos dados com média móvel constante. A ST não-estacionária é representada como sendo a correlação entre ela própria ao ser deslocada no tempo (ROMÃO *et al.*, 2020).

2.3 Inteligência Artificial

A IA é um ramo da ciência da computação que lida com processo de automação do comportamento inteligente, existindo assim diversos campos de pesquisa para esse ramo. Um desses campos está voltado para o estudo de Aprendizado de Máquina (AM), que utiliza

algoritmos e métodos capazes de aprender com os dados passados (COELHO, 2020).

A IA consegue, por meio de algoritmos, simular comportamento e inteligência humana, sendo capaz de analisar grandes volumes de dados em pouco tempo e aprender com os mesmos, podendo assim orientar na tomada de decisões. A capacidade de aprendizagem dos algoritmos por meio de análise de dados, sem a necessidade da intervenção humana, pode proporcionar soluções para problemas em fração de segundos (LOBO, 2018).

Coelho (2020), considera que o AM, consiste na capacidade que o computador tem em aprender sem necessariamente terem sido programados de forma explícita, apenas com os exemplos passados. Devido a essa capacidade que os algoritmos possuem de aprendizagem sem a intervenção humana é possível desenvolver sistemas que possam resolver problemas de maneira automática com base em informações passadas para seu aprendizado (LOBO, 2018).

2.4 Trabalhos Correlatos

Campos (2020), realizou um estudo com objetivo de comparar as principais técnicas de predição para séries temporais no mercado financeiro. As previsões foram realizadas com base em variações históricas de empresa de capital aberto, sendo considerada para validação do modelo os dados da empresa Vale (VALE3). O modelo foi treinado com base em valores históricos de maio de 2010 a julho de 2020, e os resultados mostraram que os modelos Autorregressivo (AR), Autorregressivo Integrado de Médias Móveis (ARIMA) e Autorregressivo Integrado de Médias Móveis Sazonal (SARIMA) apresentaram desempenho inferior quando comparado com os modelos de aprendizagem, Floresta Aleatória, Máquina de Vetor de Suporte (SVM) e Long Short-Term Memory (LSTM).

Vilela, Penedo e Pereira (2018), desenvolveram um modelo para prever preços de ações negociadas na BM&F Bovespa, utilizando indicadores tradicionais de rentabilidade e liquidez. O modelo foi desenvolvido através de Redes Neurais Artificiais e o modelo foi treinado com base em dados com séries trimestrais correspondentes aos anos de 2012 a 2017, totalizando 371 companhias que foram utilizadas como amostras. O modelo de rede neural artificial obteve resultado satisfatório para os casos que não tiveram altas variações na tendência de preços.

No estudo de Souza (2021), o objetivo foi aplicar técnicas de mineração de dados para prever preços de fechamento da ação da Petrobrás (PETR4), usando o software WEKA. Foi realizado levantamento dos dados históricos da PETR4, destes foi extraído dados referente ao ano de 2019. Os dados passaram por processo de seleção, pré-processamento e análise preditiva. Com a utilização das técnicas de mineração foi possível prever com acurácia considerável se o preço de uma ação vai subir ou descer. Porém para esse trabalho o uso de árvore de decisão foi ineficiente, já a utilização da rede neural artificial o resultado foi considerado eficiente.

3. Metodologia

Em relação a abordagem do problema, fez uso de pesquisa quantitativa uma vez que se utilizou a modalidade de coleta de dados e seus tratamentos. Beuren e Raupp (2006) reforçam que a abordagem quantitativa faz uso tanto da coleta de dados quanto do tratamento dos mesmos por meio de técnicas estatísticas, tais como média, correlação, análise de regressão.

Para atender ao objetivo proposto o desenvolvimento do trabalho foi dividido em passos conforme metodologia adotada por Campos (2020): passo um: implementação da aplicação web; passo dois: obtenção dos valores de fechamento dos ativos e manipulação dos mesmos; passo três: os valores foram divididos em parte para treinamento e outra para teste; passo quatro: estruturação do modelo para previsão sendo escolhido os melhores parâmetros para cada modelo. Passo cinco: com o modelo estruturado e ajustado é realizada a previsão dos valores utilizando AM; passo seis: por meio de métricas foi definido a precisão dos modelos;

3.1 Desenvolvimento do Protótipo

A ferramenta web utilizada para realizar as previsões de tendências de preço das ações foi desenvolvida utilizando o *framework* Django na versão 4, no ambiente de desenvolvimento *VsCode*, utilizando a linguagem de programação Python. Para o desenvolvimento da interface web utilizou-se a biblioteca Bootstrap v5, a linguagem de marcação HTML e a estilização foi por meio do CSS. Os gráficos foram plotados utilizando a linguagem Javascript por meio da biblioteca Plotly.

3.2 Coleta e Manipulação dos Dados

Para o desenvolvimento deste trabalho utilizou-se uma base de dados com informações sobre preço de cotação diário de ações negociadas na bolsa de valores brasileira B3 correspondente a um período de 5 anos. Conforme foi demonstrado em Santos (2020), esse intervalo de dados é considerado suficiente para o modelo de predição conseguir aprender. Os dados de cotação foram extraídos do Yahoo! Finance para os seguintes ativos: PETR4, ITUB4 e BOVA11.

Os dados da ST passaram pela etapa de pré-processamento utilizando o ambiente de programação do Google Colab, o que constituiu em eliminar possíveis valores nulos e ajustar as configurações dos dados para atender os modelos propostos.

3.3 Separação da ST em Dados de Treino e Teste

Após a etapa dos ajustes dos dados a ST foi dividida em partes, sendo uma para treinamento que foi utilizada para o modelo aprender correspondente ao período de 19/01/2017 a 16/06/2021 e outra parte para teste, período de 17/06/2021 a 19/01/2022, que foi utilizada para validar o modelo. A ST continha 1243 linhas, sendo separado 80% para treino e 20% para testar o modelo, o que corresponde respectivamente a 995 e 248 linhas conforme foi utilizado por Santos (2020).

3.4 Modelos Preditivos

Para realizar as previsões das tendências de preço das ações foram utilizados 3 modelos de predição: ARIMA, PROPHET e LSTM. O desenvolvimento dos modelos ARIMA e LSTM seguiu conforme mencionado em Campos (2020) e o modelo PROPHET recebeu as mesmas configurações citadas por Silva (2020).

A eficácia do modelo foi aferida com base na situação real dos preços de fechamento para cada ativo. A avaliação foi realizada conforme descrito por Campos (2020) através de cálculos da Raiz do Erro Quadrático Médio (RMSE) e Erro Médio Percentual Absoluto (MAPE), que são modelos estatísticos utilizados para estimar valores de erro nos modelos de regressão e foi aplicado considerando a previsão do modelo em comparação com os dados de treinamento.

4. Resultados e Discussões

Conforme foi mencionado na metodologia, para a obtenção dos resultados e validação dos modelos de previsão foram realizados testes com 1 Exchange Traded Fund (ETF) e 2 ações negociadas na B3: Petrobras (PETR4), Ibovespa (BOVA11) e Itaú (ITUB4). Em seguida serão apresentados gráficos referentes aos testes com cada ação e a previsão dos modelos de AM.

Na Tabela 1 é possível observar o MAPE e RMSE dos modelos para 30, 60 e 90 dias. Os testes foram realizados com base no valor de fechamento e o valor previsto por cada modelo, onde é possível perceber que dos 3 modelos desenvolvidos, o que apresentou menor erro foi o LSTM para todos os ativos pesquisado durante o período e o modelo PROPHET conseguiu os piores resultados considerando o intervalo de 30 dias.

Em relação ao modelo LSTM que conseguiu melhor métrica observa-se aumento no

erro conforme aumenta os dias, sendo possível conseguir melhor resultado até 60 dias de previsão.

A previsão dos preços realizados pelos modelos, levando-se em consideração os dados com valores reais de fechamento utilizados na etapa de treinamento, permitiu realizar a previsão para até 90 dias.

Tabela 1: Valores obtidos durante a validação dos modelos de previsão para 30, 60 e 90 dias.

Modelo		MAPE (%)			RMSE (R\$)		
Dias		30	60	90	30	60	90
PETR4	ARIMA	8,98	14,32	12,59	2,53	3,21	2,89
	PROPHET	9,59	12,52	9,35	6,93	8,85	6,10
	LSTM	1,92	2,47	2,75	0,54	0,69	0,77
ITUB4	ARIMA	12,30	12,33	12,26	3,49	3,42	3,18
	PROPHET	13,59	13,68	10,26	3,95	3,87	3,23
	LSTM	1,76	1,69	2,47	0,68	0,65	0,98
BOVA11	ARIMA	3,37	3,73	2,97	3,86	5,01	4,28
	PROPHET	7,60	8,07	5,67	9,43	10,02	8,21
	LSTM	1,85	1,96	2,93	2,52	2,80	4,07

4.1 Modelo ARIMA

O modelo ARIMA recebeu as configurações padrões e os valores (p, d e q) foram obtidos automaticamente conforme a ST. Na Figura 1 observa-se a previsão realizada pelo modelo ARIMA em comparação com o preço de fechamento para os ativos PETR4, ITUB4 e BOVA11.

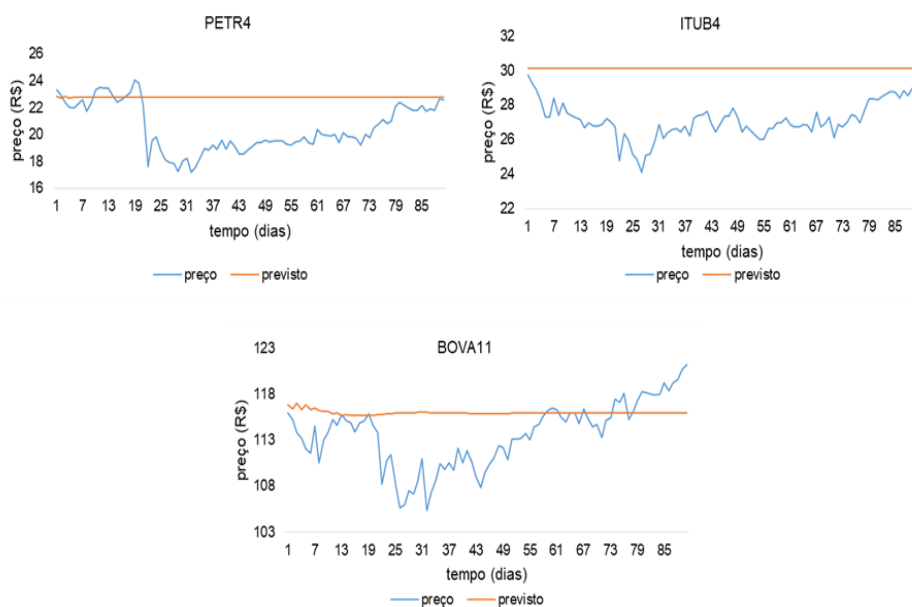


Figura 1: Valores reais e preditos das ações para o modelo ARIMA.

É possível observar que o modelo não conseguiu prever a tendência do preço dos ativos correspondente para o período de 90 dias, porém em relação aos ativos PETR4 e BOVA11 o modelo acompanhou a tendência nos primeiros 19 dias e posteriormente manteve um padrão linear.

O modelo ARIMA apresentou um padrão constante linear para o ativo ITUB4 desde o primeiro dia, e para os demais conseguiu acompanhar a tendência até o dia 19 e logo manteve uma tendência constante linear. O modelo não conseguiu identificar sazonalidade em nenhuma das STs conforme já constatado no trabalho desenvolvido por Campos (2020). Esse modelo não conseguiu adequar as STs aqui passada, assim não foi considerado ideal para realizar previsões de ST financeira, devido não conseguir prever a tendência nos preços.

4.2 Modelo PROPHET

As previsões realizadas pelo modelo PROPHET para os ativos PETR4, ITUB4 e BOVA11 podem ser observadas na Figura 2. O modelo foi desenvolvido com as configurações padrões. Em relação ao modelo PROPHET é possível observar uma sazonalidade nas previsões, não seguindo padrões linear, porém o desempenho foi semelhante ao modelo ARIMA para os primeiros dias, para o ativo PETR4, o mesmo não conseguiu prever a tendência depois do dia 20. Para os demais ativos o modelo não conseguiu prever a tendência no preço para os dias iniciais, conseguindo melhor resultado depois de 60 dias.

As previsões realizadas pelo modelo PROPHET utilizando as configurações padrões não conseguiram adaptar a diferentes ativos. Silva (2020) utilizou o modelo PROPHET com configurações padrões para realizar previsões de demanda de atendimento em hospital conseguiu resultados satisfatórios, porém a ST utilizada para treinamento era estacionária.

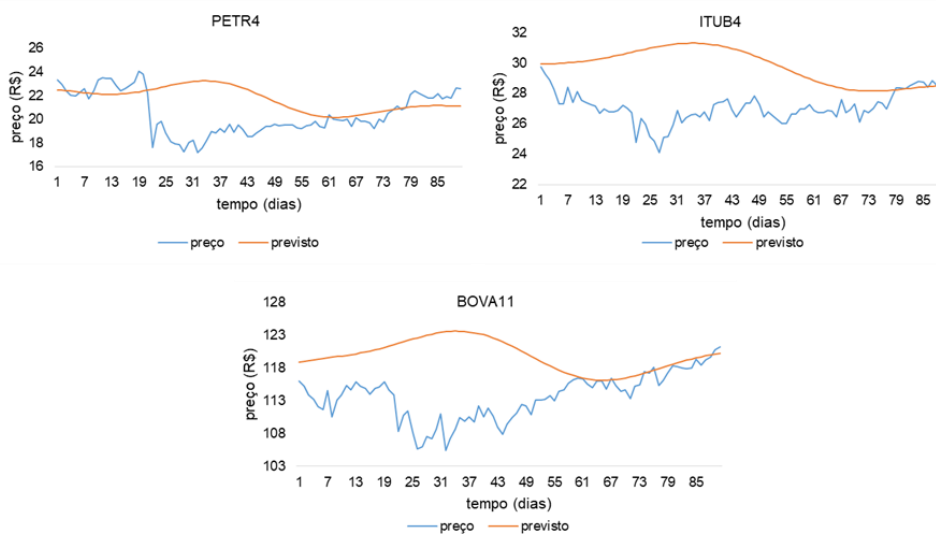


Figura 2: Valores reais e preditos das ações para o modelo PROPHET

4.3 Modelo LSTM

O Modelo LSTM foi treinado utilizando lotes de 100 linhas e 100 épocas, além de definir 35 neurônios para a camada de entrada, a função de ativação foi deixada a padrão. Por se tratar de um modelo de múltipla camada pode apresentar problema de *overfitting*, assim foi definido um *dropout* de 0,2 (CAMPOS, 2020).

A Figura 3 mostra a previsão realizada pelo modelo LSTM, onde percebe que o mesmo conseguiu ajustar as variações dos preços e assim foi possível prever a tendência de alta ou baixa para os ativos PETR4, ITUB4 e BOVA11.

Esse modelo apresentou resultado satisfatório com menor MAPE e RMSE e conseguiu prever a tendência nos preços dos ativos analisados. Campos (2020) conseguiu ótimos resultados utilizando o modelo LSTM ao realizar previsões para o ativo VALE3.

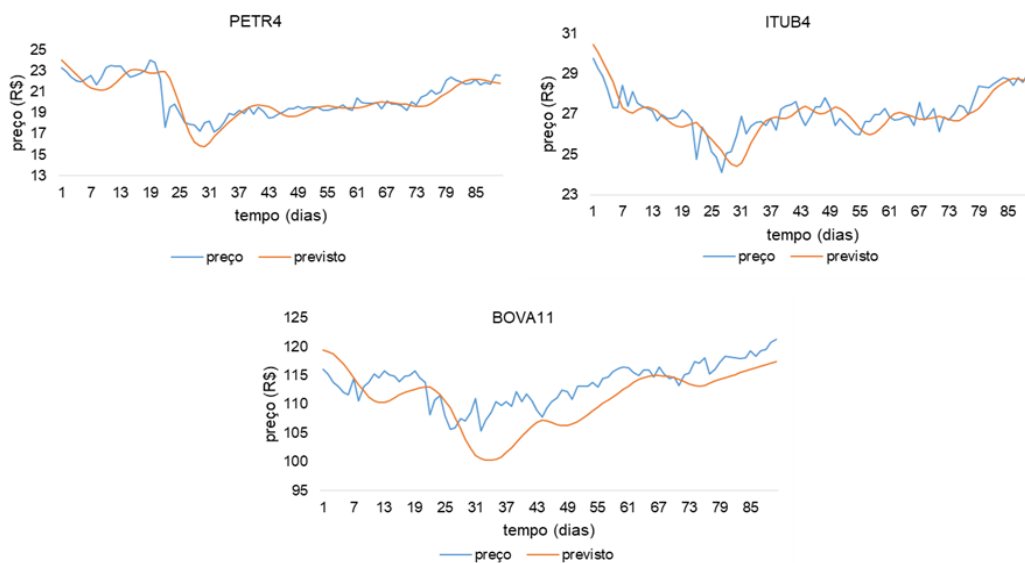


Figura 3: Valores reais e preditos das ações para o modelo LSTM.

4.4 Protótipo (THE SEER)

A Figura 4 mostra o funcionamento da ferramenta web utilizada para realizar as previsões, sendo possível perceber o fluxo dos dados quando o usuário faz uma requisição ao passar o código do ativo que pretende verificar o preço futuro.

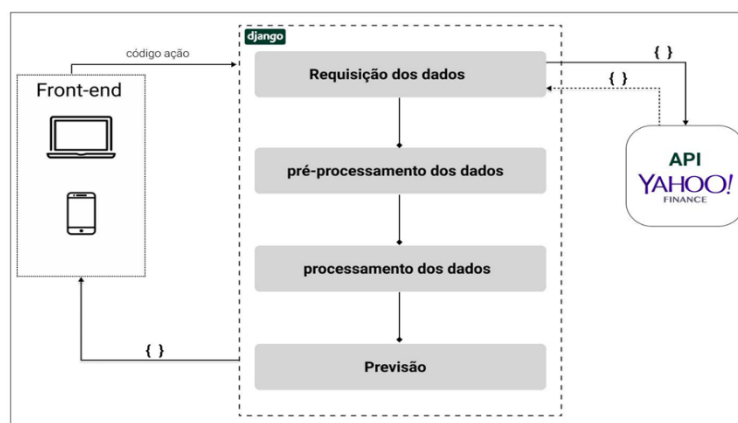


Figura 4: Arquitetura do protótipo (the seer)

As previsões foram realizadas para 30, 60 e 90 dias, desenvolvidas apenas utilizando o modelo LSTM. Esse modelo apresentou menor erro, isso significa que o mesmo consegue realizar com maior precisão a tendência dos preços para os ativos pesquisados.

As previsões dos ativos podem ser realizadas através da ferramenta web *The Seer*, informando apenas o ativo no campo de busca. Na Figura 5 é possível observar a busca e a comparação entre o preço real e o preço previsto para o ativo BBDC4.

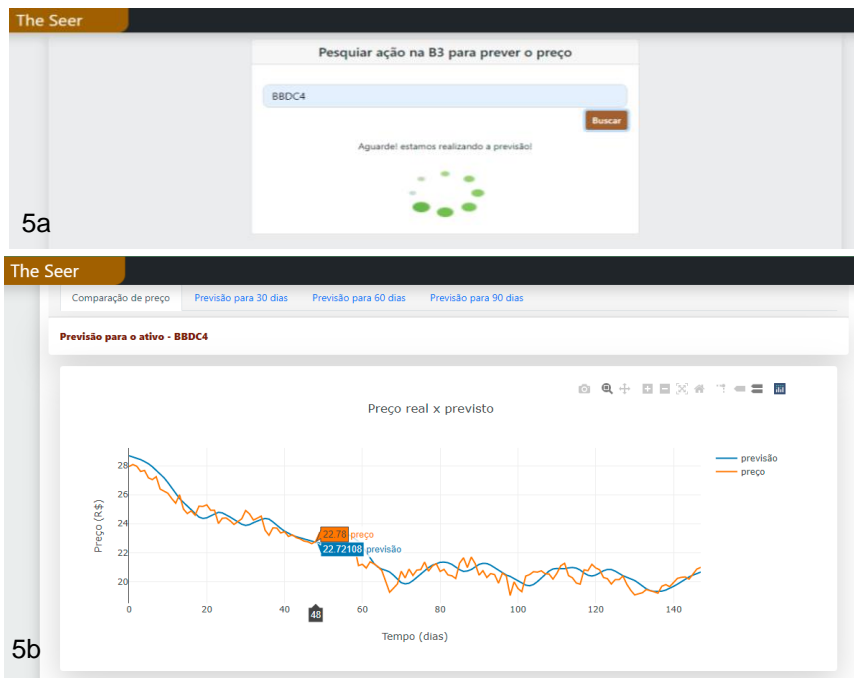


Figura 5: Campo de busca do ativo (5a). Visualização do preço real x preço previsto (5b)

A Figura 6 mostra a previsão do ativo BBDC4 para 30, 60 e 90 dias no futuro, onde é possível perceber que logo no primeiro dia de previsão o modelo já identificou que o preço de fechamento estaria em queda, passando de R\$ 20,99 para R\$ 20,62, passando por leves oscilações para os próximos 30 dias, sendo registrado o menor e maior valor respectivamente de R\$ 20,29 e R\$ 20,68. A tendência para os próximos 60 e 90 dias não passou por muitas alterações, permanecendo quase linear.

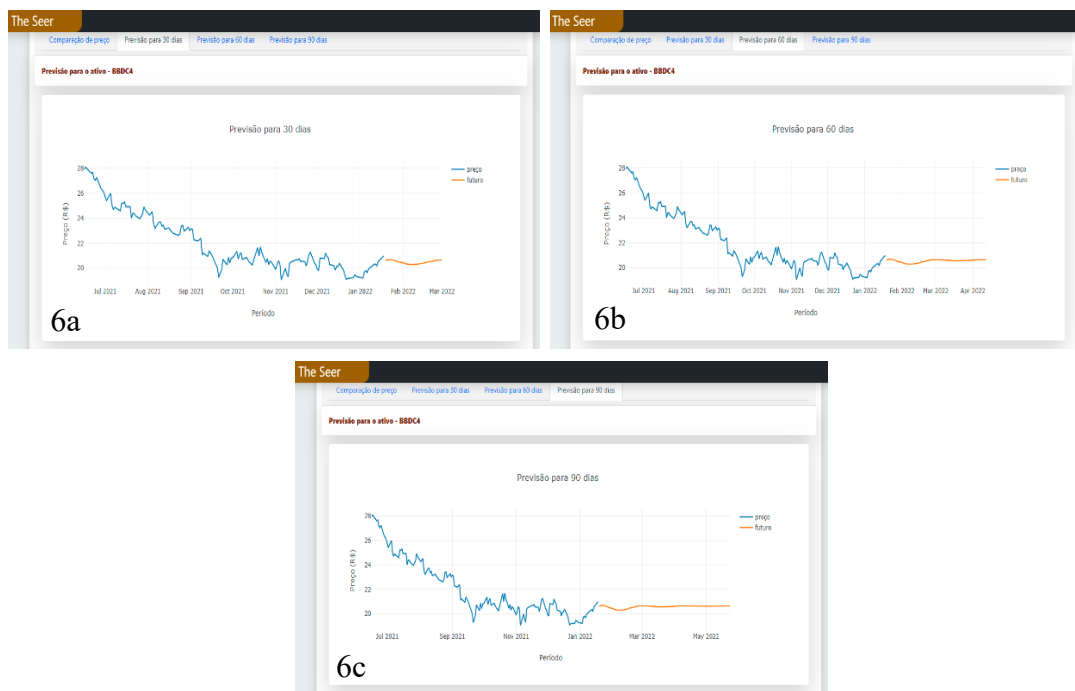


Figura 6: Previsão para os 30 (6a), 60 (6b) e 90 (6c) dias futuro - BBDC4.

O modelo realizou a previsão para os próximos 90 dias, porém deve levar em consideração a margem de erro já observado na etapa de validação antes de comprar ou vender uma ação.

5. Considerações Finais

O trabalho alcançou o objetivo proposto, pois conseguiu por meio da IA realizar a previsão da tendência de preço de fechamento de ativos negociados na B3 e assim auxiliar os investidores na hora de comprar ou vender ativos. Dos três modelos propostos para predição o LSTM foi o que conseguiu melhores resultados para os três ativos verificados, e assim a ferramenta The Seer foi desenvolvida utilizando apenas esse modelo de predição.

Tanto o modelo ARIMA quanto o PROPHET não conseguiram bons resultados na previsão de longo período e obtiveram melhores resultados nos primeiros 30 dias de predição, porém não conseguiram prever a tendência para um futuro mais distante, o resultado inferior foi devido a ST utilizada para predição não apresentar comportamento estacionário, conforme também foi observado por Campos (2020). Ao contrário dos modelos anteriores, o modelo LSTM, além de prever a tendência, teve melhor métrica tanto RMSE quanto MAPE.

Para todos os modelos foi utilizado basicamente as configurações padrões com exceção do modelo LSTM que foi definido alguns parâmetros para ajustar e assim conseguir melhor resultado. O estudo em questão apresentou apenas as configurações que obteve melhor resultado, porém foi realizado diversos testes, levando em consideração outras configurações com intuito de minimizar os erros, além de uma ST com mais dados.

No decorrer da execução do trabalho foi verificada a oportunidade de desenvolvimento de possíveis trabalhos futuros, dos quais pode-se considerar a possibilidade de utilizar mais atributos, não somente a cotação diária, além da utilização de outro modelo de AM, exemplo, Floresta Aleatória.

Referências

ASSAF N. A. Mercado financeiro. 14. ed. São Paulo: Atlas, 2018.

BEUREN, Ilse Maria; RAUPP, Fabiano Maury. Como elaborar trabalhos monográficos em contabilidade: teoria e prática. São Paulo: Atlas, 2006. Disponível em: https://scholar.google.com.br/citations?view_op=view_citation&hl=pt-BR&user=oNAzruYAAAAJ&citation_for_view=oNAzruYAAAAJ:u-x6o8ySG0sC

CAMPOS, B. A. R. M. Análise Comparativa De Técnicas Para A Previsão De Séries Temporais No Contexto De Mercados Financeiros. 2020. 75 f. TCC (Graduação) - Curso de Sistemas de Informação, Universidade Federal de Santa Catarina, Florianópolis, 2020. Disponível em: <https://repositorio.ufsc.br/handle/123456789/223843>. Acesso em: jul. 2021.

CASTRO, L. N.; FERRARI, D. G. Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações. São Paulo: Saraiva, 2016.

COELHO, F. F. Machine learning e análise técnica como ferramentas para construção de portfólios de renda variável no mercado brasileiro. 2020. 89 f. Dissertação (Mestrado) - Curso de Economia, Fundação Getúlio Vargas, Rio de Janeiro, 2020. Disponível em: <https://hdl.handle.net/10438/30275>. Acesso em: jul. 2021.

D'ÁVILA, M. Z. Bolsa conquista 1,5 milhão de novos investidores em 2020, um aumento de 92% no ano. 2021. Disponível em: <https://www.infomoney.com.br/onde-investir/bolsa-conquista-15-milhao-de-novosinvestidores-em-2020-um-aumento-de-92-no-ano/>. Acesso em: jul. 2021.

- HAYASHI, A. H. Processo para predição de preços das ações no mercado financeiro com uso de Big Data. 2017. 90 f. Dissertação (Mestrado) - Curso de Engenharia de Computação: Redes de Computadores, Instituto de Pesquisas Tecnológicas do Estado de São Paulo, São Paulo, 2017. Disponível em: https://www.ipt.br/pos_graduacao_ipt/solucoes/dissertacoes/960-processo_para_predicao_de_precos_das_acoes_no_mercado_financeiro_com_uso_de_big_data.htm. Acesso em: jul. 2021.
- LOBO, L. C. Inteligência artificial, o Futuro da Medicina e a Educação Médica. Revista Brasileira de Educação Médica, [S.L.], v. 42, n. 3, p. 3-8, set. 2018. Disponível em: <https://doi.org/10.1590/1981-52712015v42n3RB20180115EDITORIAL1>. Acesso em: jul. 2021.
- MESQUITA, Caio Mário Henriques Silva da Rocha. Ciência de dados e aprendizado de máquina para predição em séries temporais financeiras. 2019. 107 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, 2019. Disponível em: <https://repositorio.ufmg.br/bitstream/1843/30444/1/CaioMarioHenriquesSilvaRochaMesquita.pdf>. Acesso em: jan. 2022.
- ROMÃO, Estevão Luiz *et al.* Estudo Comparativo entre Modelos Autoregressivos Integrados de Médias Móveis e Redes Neurais Artificiais na Modelagem e Previsão de Séries Econômicas. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, Não use números Romanos ou letras, use somente números Arábicos., 2020, Foz do Iguaçu. Anais [...]. Foz do Iguaçu: Enegep, 2020. p. 1-11. Disponível em: <https://pedro.unifei.edu.br/Artigos%20em%20Congressos/2020%20ENEGEP%20Estudo.pdf>. Acesso em: jan. 2022.
- SANTOS, Gustavo Carvalho. Algoritmos de Machine Learning Para Previsão de Ações da B3. 2020. 80 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2020. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/29897/7/AlgoritmosMachineLearning.pdf>. Acesso em: nov. 2021.
- SILVA, Jhosefer da. Modelos para Previsão de Demanda de Atendimento em Hospital. 2020. 7 f. Monografia (Especialização) - Curso de Data Science e Big Data, Ciências Exatas, Universidade Federal do Paraná, Curitiba, 2020. Disponível em: <https://www.acervodigital.ufpr.br/bitstream/handle/1884/71066/R%20-%20E%20-%20JHOSEFER%20DA%20SILVA.pdf?sequence=1&isAllowed=y>. Acesso em: jan. 2022.
- SOUZA, Carlos Henrique Neves. Modelo ARIMA para previsão e análise de receita de uma Startup no contexto do COVID-19. 2020. 29 f. TCC (Doutorado) - Curso de Engenharia de Produção, Universidade Federal de Ouro Preto, João Monlevade, 2020. Disponível em: https://www.monografias.ufop.br/bitstream/35400000/2657/6/Monografia_ModeloARIMAPrevis%C3%A3o.pdf. Acesso em: jan. 2022.
- SOUZA, W. B. C. Mineração De Dados Aplicada A Previsão De Preços De Ações Utilizando Weka. 2021. 68 f. TCC (Graduação) - Curso de Bacharel em Ciência da Computação, Universidade Católica de Goiás, Goiânia, 2021. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/1616>. Acesso em: jul. 2021.
- VASCO, Lucas Pimenta. Um Estudo de Redes Neurais Recorrentes no Contexto de Previsões no Mercado Financeiro. 2020. 48 f. TCC (Graduação) - Curso de Engenharia de Computação, Computação, Universidade Federal de São Carlos – Ufscar, São Carlos, 2020. Disponível em:

https://repositorio.ufscar.br/bitstream/handle/ufscar/13730/Trabalho_de_Conclusao_de_Curso_Lucas_Vasco.pdf?sequence=2&isAllowed=y. Acesso em: jan. 2022.

VILELA, E. H. P.; PENEDO, A. S. T.; PEREIRA, V. S. Aplicação De Redes Neurais Artificiais Na Predição De Preços De Ações Por Indicadores Financeiros. *Desafio Online, Campo Grande*, v. 6, n. 2, p. 323-244, ago. 2018. Quadrimestral. Disponível em: <https://desafioonline.ufms.br/index.php/deson/article/view/5504>. Acesso em: jul. 2021.