

Utilizando rede LSTM para Predição de Ações de Vários Setores Econômicos da Bolsa de Valores

Using the LSTM Network for Stock Prediction in Several Economic Sectors of the Stock Exchange

Taciano Lopes de Amorim¹
Gustavo Callou¹
Saulo Pereira¹
Anderson Sena dos Santos¹

¹Universidade Federal Rural de Pernambuco, Departamento de Computação,
PPGIA, Recife, PE, Brasil.

Resumo

Objetivo: Utilizar rede neural recorrente para prever os preços de fechamento das ações de 4 setores econômicos classificados na B³ e duas ações negociadas na NASDAQ assim como analisar se o modelo proposto é capaz de identificar padrões de comportamento distintos entre os setores selecionados e até de outro mercado.

Método/abordagem: Trata-se de uma pesquisa baseada na coleta dos preços reais de fechamento das ações, treinamento do modelo e predição dos preços futuros de fechamento utilizando a rede LSTM.

Contribuições teóricas/práticas/sociais: Acrescenta mais estudos utilizando a rede LSTM com o objetivo de obter predições dos preços das ações avaliadas assim como a previsão dos preços de fechamento para dias futuros. Também é apresentado um protótipo de app que exibe as informações das ações monitoradas.

Originalidade/relevância: Os resultados apresentados neste artigo são frutos da pesquisa realizada na predição dos preços futuros das ações negociadas na B³ e na NASDAQ. Este, fornecerá subsídios para trabalhos que pretendam realizar análises desses valores como objetivo de identificar o comportamento dos preços preditos para um ativo e assim poder aplicar indicadores para auxiliar em uma tomada de decisão.

Palavras-chave: Inteligência Artificial, Rede Neural Recorrente, LSTM, Ações.

Abstract

Purpose: Uses the recurrent neural network to predict the closing prices of stocks of 4 economic sectors classified on B³ and two stocks negotiated on NASDAQ and to analyze whether the proposed model can identify distinct patterns of behaviour among the selected sectors and even in another market.

Design/methodology/approach: It is a research based on the collection of real closing prices of stocks, model training and prediction of future closing prices using the LSTM network.

Research, Practical & Social implications: It adds more studies using the LSTM network with the objective of obtaining price predictions for the shares evaluated, as well as the forecast of closing prices for future days. An app prototype that displays information about monitored actions is also presented.

Originality/value: The results presented in this article are the result of research carried out in the prediction of future prices of shares traded on B³ and NASDAQ. This will provide support for works that intend to carry out analyzes of these values in order to identify the behavior of predicted prices for an asset and thus be able to apply indicators to assist in decision making.

Keywords: Artificial Intelligence, Recurrent Neural Network, LSTM, Stock market.

Introdução

Ao longo dos anos, pesquisadores e investidores têm estudado e avaliado modelos que possam identificar os padrões do comportamento dos preços dos ativos para auxiliar na tomada de decisões. Contudo, devido à natureza caótica, complexa, não linear e não estacionária torna essa tarefa bastante desafiadora. Uma vez que, o mercado de ações pode ser afetado por decisões políticas e fatores econômicos (Shah, Isah, & Zulkernine, 2019).

As variações de preços das ações constituem um fator de risco para investidores. Em geral, as incertezas não permitem determinar qual será o retorno financeiro para as negociações de compra e venda nesse mercado. Isso ocorre devido ao fato de que essas operações acontecem e estão sujeitas à lei da oferta e demanda do mercado. Uma vez que, os mesmos estão diretamente vinculados à lei da demanda e oferta de mercado. Portanto, torna-se necessário a busca por ferramentas que possam diminuir os riscos nas transações (do Nascimento, da Silva Jale, & Ferreira, 2021).

A previsão de valores das ações é uma técnica utilizada para minimizar riscos e maximizar lucros. Entretanto, a complexidade e o dinamismo de mercado tornam a previsão de comportamento dos preços uma tarefa desafiadora. Existem hipóteses divergentes sobre tentar prever o preço no mercado de ações. Segundo Dametto (2018), não é possível realizar previsões do valor de um ativo com base em informações históricas sobre ele. Porém, outros autores,

relatam que por meio de experimentos é possível supor o comportamento de um ativo até um determinado nível.

Para tentar minimizar os riscos é possível utilizar a análise técnica que possibilita a identificação de tendências baseando-se na "*Teoria de Dow*", criada por Charles Dow no começo do século XX, que visa identificar tendências significativas de alta ou de baixa no mercado. Sendo possível identificar os movimentos por trás da precificação de um ativo. É importante destacar ainda que a análise técnica utiliza as informações de preço (abertura, fechamento, maior e menor valor no dia) e volume de negociação (Pacce, 2017).

Diante disso, o emprego da Inteligência Artificial (IA) como ferramenta possibilita a realização dessas previsões utilizando dados passados. Desta forma, podemos prever o preço futuro da ação e, com esta informação é possível identificar o melhor momento para realizar a operação com o menor risco possível (Pacce, 2017).

As redes neurais recorrentes (RNNs, do inglês de *Recurrent neural networks*) são utilizadas para realizar processamento de dados sequenciais com eficiência. Dentre elas, destacam-se as redes de memória a longo prazo (LSTM, do inglês de *Long Short-Term Memory*) que têm sido utilizadas para prever valores tomando como base uma série temporal (Souto, Capistrano, Matias, Soares, Ogasawara, & Giusti, 2021). Dessa forma, esse artigo propõe uma estratégia que faz uso do LSTM, que é uma rede neural recorrente

(RNN, do inglês de *Recurrent neural network*), para prever o preço futuro das ações e auxiliar na tomada de decisão em relação a uma estratégia de negociação ou momento apropriado para a compra/venda do ativo. Um estudo de caso aplicado foi demonstrado ao longo deste trabalho utilizando dez ações de empresas presentes na B³ (Brasil, Bolsa, Balcão) que é a bolsa de valores brasileira e NASDAQ (mercado norte-americano de ações).

O artigo segue com a seguinte estrutura. A Seção 2 apresenta o referencial teórico visando apresentar conceitos necessários a um maior entendimento deste trabalho. Seção 3 mostra os trabalhos relacionados a essa pesquisa. Na seção 4 estão descritas todas as etapas envolvidas no processo de pesquisa. Já na Seção 5 são debatidos os resultados assim como o protótipo MB[3]. E por fim, são apresentados as conclusões e os futuros direcionamentos dessa pesquisa.

Referencial teórico

A inteligência artificial refere-se ao campo de conhecimento que associa à linguagem de programação, autonomia das máquinas à inteligência, ao raciocínio, à aprendizagem e à resolução de problemas humanos. Sendo assim, existem vários campos de pesquisas onde um deles está voltado para o estudo de Aprendizado de Máquina (AM), que utiliza algoritmos para identificar padrões a partir de dados passados (Kaufman, 2019).

Rede Neural Recorrente - *Recurrent neural network* (RNN)

As redes neurais recorrentes são um conjunto de técnicas de aprendizado de máquina que apresentam neurônios recorrentes. Ou seja, incluem loops em suas estruturas base, de acordo com (Segatto & Coury, 2006) as Redes Neurais Recorrentes são um caso especial dentro dos conjuntos das redes neurais artificiais. Elas funcionam por meio do processo de realimentação de entradas, elas podem armazenar informações ao processar novas entradas. Portanto, a memória as torna ideais para tarefas de processamento de dados que utilizam séries temporais (de Carvalho, et al. 2018). Dessa forma, pode-se dizer que a rede neural recorrente é um tipo de rede neural artificial projetada para reconhecer padrões em séries numéricas (Capítulo 48, 2021).

Memória de Curto Longo Prazo - Long Short Term Memory (LSTM)

De acordo com a iniciativa (Capítulo 51, 2021), LSTM é uma arquitetura de rede neural recorrente que “lembra” valores em intervalos arbitrários. É adequada para classificar, processar e prever séries temporais com intervalos de tempo de duração desconhecida. A insensibilidade relativa ao comprimento do gap dá uma vantagem à LSTM em relação às RNNs tradicionais (também chamadas “*vanilla*”), Modelos Ocultos de Markov (MOM) e outros métodos de

aprendizado de sequências. Outros autores corroboram com esse aspecto afirmando que a LSTM, é uma RNN capaz de aprender dependências de longo prazo em problemas de previsão de sequência não linear (Karusu & Altan, 2022). Essa rede foi proposta por Hochreiter e Schmidhuber, em 1997, para resolver um problema das RNNs que não lembravam de dependências de longo prazo (Dalla Corte, Dos Santos, & Casanova, 2019).

Na estrutura do LSTM, demonstrado na Figura 1, existem as células por onde a informação é repetida e os portões onde a manipulação de memórias é feita. Os portões conhecidos como “Forget Gate” realizam o descarte das informações que não são mais úteis. Já o “Input Gate” adiciona as informações úteis ao estado da célula e o “Output Gate” extrai as informações úteis do estado atual da célula (Capítulo 51, 2021).




Figura 1. Estrutura do LSTM em cadeia.

Fonte: (Capítulo 51, 2021)

Métricas

Essa seção apresenta as métricas que adotamos para comparar a qualidade das previsões realizadas.

2.3.1 Root Mean Squared Error (RMSE)

Essa métrica penaliza grandes diferenças entre o valor previsto e o real. E, para lidar com o problema da diferença

entre unidades, é aplicada a raiz quadrática como demonstrado na Figura 2. Assim a unidade fica na mesma escala que o dado original, resultando em uma melhor interpretabilidade do resultado da métrica (Jiang, 2021).

Na Figura 2, r representa o valor real, $\hat{r}$ o valor previsto e N o número de dias em um determinado período.

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (\hat{r}_n - r_n)^2}{N}}$$

Figura 2. Fórmula do RMSE.

Fonte: Criado pelo autor

Mean Absolute Percentage Error (MAPE)

É considerada uma métrica de fácil entendimento, pois mostra a porcentagem de erro em relação aos valores reais, ou seja, se o resultado for igual a 50% significa que o modelo utilizado faz previsões em média com 50%, tanto para mais quanto para menos, de diferença entre o valor previsto e o real. Quanto menor o valor percentual resultante, maior é a precisão da predição (Roondiwala, Patel, & Varma, 2017).

A Figura 3 mostra a fórmula utilizada para realizar o cálculo. Onde A_t é o valor real e F_t é o valor previsto e n é o número de dias em um determinado período.

Trabalhos relacionados

O uso de algoritmos para prever tendências nos preços de ações contrapõe uma regra básica em finanças intitulada por Hipótese do Mercado Eficiente (Eugene, 1970). A Hipótese alega que os preços atuais das ações refletem (dentro da perspectiva mais conservadora) totalmente todas as informações importantes. Dessa maneira, uma vantagem descoberta ao explorar dados históricos de ações resultará em benefício para todo o mercado, resultando em correção do preço do ativo. Essa é uma teoria questionável e frequentemente contestada. Ainda que geralmente seja aceita, existem muitos pesquisadores que rejeitam essa suposição usando algoritmos que podem modelar dinâmicas mais complexas do sistema financeiro (Malkiel, 2003).

Relacionados ao uso de inteligência artificial na predição de ativos no mercado financeiro. Dentre eles, o trabalho de (Vasco, 2020), realizou a comparação entre três tipos de arquitetura da área de redes neurais artificiais: o modelo de redes neurais recorrentes simples (VRNN, do inglês Vanilla Recurrent Neural Network), o LSTM e o Gated Recurrent Unit (GRU), onde ele utilizou vários tamanhos de janela e 500 épocas na configuração do treinamento. Chegando à conclusão que tanto o GRU quanto o LSTM obtiveram resultados satisfatórios com um melhor desempenho para o GRU. Para avaliar a precisão da predição foram utilizados o Mean Squared Error (MSE) e o Mean Absolute Error (MAE).

Nesse sentido, existem trabalhos como o de Bathla (2020) que realizou uma comparação na previsão dos preços de fechamento de índices de ações. A análise do experimento provou que o LSTM supera o *Support Vector Regression* (SVR) e fornece melhor precisão na previsão, para isto foram coletados 9 anos de dados históricos.

Já Roondiwala et al. (2017) utilizou o LSTM para prever os preços das ações do NIFTY 50, para tanto foram coletados 5 anos de dados históricos, possibilitando várias simulações com o modelo configurado em 250 e depois 500 épocas para as seguintes combinações de *features*: preço de abertura/preço de fechamento, maior preço/menor preço/preço de fechamento/preço de abertura e preço de fechamento/menor preço/menor preço. Onde concluiu que

a melhor configuração utilizada foi a com 4 *features* (Preço de abertura/preço

de fechamento/maior preço/menor preço) com 500 épocas.

$$M = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_t - F_t}{A_t} \right|$$

Figura 3. Fórmula do MAPE.

Fonte: Criado pelo autor

Leandro, 2021 apresenta como objetivo investigar a eficácia dos LSTMs, realizando a comparação da estratégia LSTM com a buy and hold. O resultado dos testes demonstrou que o algoritmo LSTM foi superior. Uma vez que, mesmo tendo uma taxa de precisão inferior a 61%, o lucro obtido no acerto foi maior do que o da perda no erro. Para isto, realizou várias simulações em 6 ações da bolsa de valores. Os dados históricos que foram capturados são de janeiro de 2019 até julho de 2021.

De acordo com Nascimento, Santos e Ferreira (2022), foram aferidos os melhores modelos para prever os preços de fechamento das ações para 30, 60 e 90 dias. Os autores demonstraram que o modelo LSTM em comparação aos modelos *autoregressive integrated moving average* (ARIMA) e PROPHET foi mais eficaz na previsão de tendências, também obtendo as melhores métricas baseadas no cálculo tanto do RMSE quanto do MAPE para a previsão até 60 dias.

Logo, esse trabalho visa apresentar o desempenho de um modelo otimizado com base na rede LSTM, fazendo previsões para 3 dias futuros, além de uma aplicação em *flutter* ao qual se alimenta de tais previsões, possibilitando a integração entre modelo proposto e a aplicação. Este app visa diminuir riscos nas operações realizadas pelos investidores e analistas de investimentos. A Tabela 1 apresenta uma visão geral dos trabalhos relacionados previamente explicados. Nela, pode-se perceber que apenas um dos artigos relacionados realiza a previsão para dias futuros em 3 ações, utilizando um mesmo modelo. A escolha da utilização de 4 setores econômicos da B3 (“Petróleo, Gás e Biocombustíveis”, “Materiais Básicos”, “Bens Industriais” e “Financeiro”) e duas ações da bolsa de valores NASDAQ, dar-se à necessidade de averiguar se o modelo consegue identificar padrões de comportamento distintos desses setores.

Trabalho	Modelo	Ação/Índice	Métrica	Período	Realiza previsão para dias futuros
Vasco (2020)	LSTM VRNN GRU	PETR4, FLRY3 e VALE3	MSE MAE	01/01/10 à 31/12/19, 90% (treinamento) e 10%(teste)	Não
Roondiwala (2017)	LSTM	NIFTY 50	RMSE	01/01/11 à 31/12/2016 totalizando 1.312 amostras. Com 1.180 (treinamento) e 132 (teste)	Não
Bathla (2020)	LSTM SVR	S&P 500, NYSE, NSE, BSE, NASDAQ e Dow Jones industrial Average	RMSE	jan/2015 à jun/2019 (treinamento) e de jul/2019 à jan/2020 (teste)	Não
Leandro (2021)	LSTM	GOLL4, CSNA3, ELET3, B3SA3, PETR4 e VALE3	Análise gráfica de lucro	jan/2019 à jul/2021. 30% (treinamento) e 70% (teste)	Não
Nascimento (2022)	LSTM PROPHET ARIMA	PETR4, ITUB4 e BOVA11	RMSE MAPE	19/01/17 à 16/06/21 (treinamento) e de 17/06/21 à 19/01/22 (teste).	Sim
Este <u>trabalho</u>	LSTM	PETR4, OSXB3, BRAP4, USIM5, AZUL4, TGMA3, SANB4, SULA4, AAPL e TSLA	RMSE MAPE	01/08/18 à 25/08/22. Ações da B3: 83.93% (treinamento), 15.77% (teste) e 0.3% (verificação da previsão futura). Ações da NASDAQ: 84.29% (treinamento), 15.41% (teste) e 0.3% (verificação da previsão futura)	Sim

Tabela 1. Avaliação dos trabalhos relacionados.

Fonte: Criado pelo autor

Metodologia

Este trabalho se caracteriza como uma pesquisa qualitativa, para (Neves, 2016), a expressão “pesquisa qualitativa”, assume diferentes significados, mas compreende um conjunto de diferentes técnicas interpretativas que visam a descrever e a decodificar os com-

ponentes de sistemas complexos, imputando significado. Para isto, foram utilizadas as seguintes ferramentas estatísticas, tais como média, correlação e análise de regressão. Isso foi feito tanto na coleta quanto no tratamento dos dados (Raupp & Beuren 2006). Endossando por sua vez as características qualitativas da pesquisa.

Nas próximas seções explicaremos os passos que utilizamos.

Escolha dos ativos

As ações utilizadas neste trabalho são negociadas na B³, que é uma das principais companhias de infraestrutura de mercado financeiro no mundo. Formada pelos índices Ibovespa, IBrX-50 e IBrX, entre outras (B3, 2022). Além disso, também foram utilizadas duas ações negociadas na NASDAQ, bolsa existente no mercado financeiro norte-

americano. A Tabela 2 mostra as ações que foram escolhidas aleatoriamente de cada setor econômico da B³ e duas ações que fazem parte do mercado financeiro americano. A ideia da utilização de duas ações de cada setor é verificar o comportamento do modelo LSTM nesses grupos. Assim como, também no mercado norte americano.

As ações AAPL e TSLA foram utilizadas para avaliar a qualidade da previsão para ações de outro mercado financeiro.

Bolsa	Setor econômico	Ação
B[3]	Petróleo, Gás e Biocombustíveis	Petróleo Brasileiro SA (PETR4)
B[3]	Materiais Básicos	OSX Brasil S.A (OSXB3)
B[3]	Bens Industriais	Bradespar SA (BRAP4)
B[3]	Financeiro	Usinas Siderurgicas de Minas Gerais (USIM5)
NASDAQ	Geral	Azul SA (AZUL4)
		Tegma Gestão Logística(TGMA3)
		Banco Santander (Brasil) SA (SANB4)
		Sul America (SULA4)
		Apple, inc. (AAPL)
		Tesla, inc. (TSLA)

Tabela 2. Agrupamento das ações.
Fonte: Criado pelo autor

Etapas

Após a escolha das ações, seguem-se as etapas mencionadas na Figura 4 para chegar ao resultado da previsão. A seguir, cada etapa será detalhada.

Configuração da máquina

Todo o processo de desenvolvimento foi realizado em uma máquina

com a seguinte configuração: Processador Intel Core i5 da 11a Geração, 16 GB RAM, SSD 256 GB NVMe e Linux Ubuntu 22.04.1 LTS.

Setup da Rede Neural

A rede neural foi criada utilizando a biblioteca Keras e a sua configuração foi realizada de forma experimental (empírica). Mostrada na Figura 5.




Figura 4. Etapas envolvidas até a previsão do valor de fechamento.
Fonte: Criado pelo auto

O treinamento foi configurado com no máximo 500 épocas. Onde foi passado no método `model.fit` um callback para monitoramento. No callback foram configurados o `EarlyStopping` e o `ReduceLROnPlateau`, ambos com o parâmetro `patience=50` e `monitor='val_loss'`.

Coleta de dados

Nesta etapa, coletamos as séries históricas dos preços das cotações diárias dos ativos envolvidos utilizando a API do Yahoo Finance (Yfinance, 2021)

no período de 01/08/2018 à 25/08/2022, totalizando 1008 registros para as ações da B³ e 1025 registros para as ações da NASDAQ. Mesmo utilizando um período semelhante, verificamos que os números de dados coletados nas bolsas são diferentes devido a quantidade de pregões realizados nesse intervalo em cada mercado financeiro.

Os dados coletados foram utilizados no treinamento, validação e previsão realizados pela IA. Baseando-se nos preços de fechamento das ações envolvidas.

```

model.add(LSTM(200, input_shape=(look_back, 1)))
model.add(Dropout(0.3))
model.add(Dense(units = 1, activation = 'linear'))
model.add(Activation('linear'))
model.compile(optimizer='RMSProp', loss='mse', \
              metrics=[RootMeanSquaredError(), MeanAbsolutePercentageError()])
  
```

Figura 5. Configuração do modelo.
Fonte: Criado pelo autor

Pré-processamento

Esta etapa é a responsável pela realização do tratamento das informações coletadas. Sendo dividida em:

- Extração: Foi utilizado apenas o índice, que representa a data do evento, e a coluna Close, que representa o valor de fechamento da ação.
- Transformação: Normalização.

Depois da coleta, realizou-se a extração dos dados de interesse e a normalização dos valores existentes na coluna *Close*. Para isto, foi utilizada a API

`sklearn.preprocessing.StandardScaler` que realiza o cálculo baseado na equação exibida na Figura 6.

$$Z = \frac{(X-U)}{S}$$

Figura 6. Fórmula que normaliza os valores.

Fonte: Criado pelo autor

Onde X é a pontuação padrão, U é a média das amostras utilizadas no treinamento e S é o desvio padrão das amostras (StandardScaler, 2021).

Separação de dados

Nessa etapa, a massa de dados foi dividida da seguinte maneira:

- a) Ações da B3: 83.93% registros para treinamento, 15.77% registros para validação e 0.3% registros para verificação da previsão futura.
- b) Ações da NASDAQ: 84.29% registros para treinamento, 15.41% registros para validação e 0.3% registros para verificação da previsão futura.

Os dados separados para validação são utilizados para verificar a qualidade da predição do treinamento realizado. Já os separados para verificação futura foram utilizados apenas para comparação entre o valor real para o dia e o valor previsto.

Treinamento e validação

Após separação, o conjunto de dados é apresentado ao algoritmo para a realização do treinamento. Ao final do

treinamento são apresentados os valores separados para a validação. Estes são utilizados para validar a previsão do modelo. Onde para aferição da qualidade da predição foram utilizados o RMSE e o MAPE. Essas métricas são coletadas tanto nas previsões realizadas no treinamento, quanto na fase de validação.

Desenvolvimento do Protótipo

Durante a fase de pesquisa foi iniciado o desenvolvimento da ferramenta MB[3] com o intuito de fornecer informações necessárias para a tomada de decisão. A ferramenta está sendo desenvolvida em *Flutter* na arquitetura para dispositivos móveis utilizado API *rest* desenvolvida em *python*.

Resultados

Conforme foi mencionado na metodologia, a série coletada foi tratada, separada e normalizada. Para obter as previsões foram realizados testes com as seguintes ações: PETR4, OSXB3, BRAP4, USIM5, AZUL4, TGMA3, SANB4, SULA4, AAPL e TSLA. A seguir, será exibido o resultado das validações realizadas no modelo treinado.

Gráfico de validação da fase de treinamento

Essa seção apresenta os resultados obtidos durante a validação do modelo com os dados separados para os testes do modelo. Observando os gráficos exibidos nas Figuras 7, 8, 9, 10 e 11 é possível verificar que o valor previsto ficou próximo ao valor real disponibilizado para o teste. A seguir, será descrito mais

informações de cada setor financeiro envolvido.

Setor econômico "Petróleo, Gás e Biocombustíveis"

Na Figura 7 podemos visualizar as previsões realizadas na validação do modelo para as ações PETR4 e OSXB3. Para treinar o modelo foram utilizados aproximadamente 120 e 170 épocas, respectivamente.




Figura 7. Validação do treinamento do modelo.

Fonte: Criado pelo autor.





Figura 8. Validação do treinamento do modelo.

Fonte: Criado pelo autor.

Previsão de teste AZUL4




Previsão de teste TGMA3



Figura 9. Validação do treinamento do modelo.

Fonte: Criado pelo autor.

Previsão de teste SULA4



Previsão de teste SANB4




Figura 10. Validação do treinamento do modelo.

Fonte: Criado pelo autor.

Previsão de teste AAPL



Previsão de teste TSLA




Figura 11. Validação do treinamento do modelo.

Fonte: Criado pelo autor.

O resultado obtido para o RMSE na validação foi de 0,44 para a PETR4 e 0,27 para a OSXB3.

Setor econômico "Bens Industriais"

A Figura 9 mostra as previsões realizadas na validação do modelo para as ações AZUL4 e TGMA3. Para treinar o

modelo foram utilizados aproximadamente 200 e 190 épocas, respectivamente.

O resultado obtido para o RMSE na validação foi de 0,12 para a AZUL4 e 0,35 para a TGMA3.

Setor econômico "Financeiro"

A Figura 10 mostra as previsões realizadas na validação do modelo para as ações SULA4 e SANB4. Para treinar o modelo foram utilizados aproximadamente 175 e 160 épocas, respectivamente.

O resultado obtido para o RMSE na validação foi de 0,19 para a SULA4 e 0,21 para a SANB4.

Ações negociadas na NASDAQ

A Figura 11 mostra as previsões realizadas na validação do modelo para as ações AAPL e TSLA. Para treinar o modelo foram utilizados aproximadamente 400 e 400 épocas, respectivamente.

O resultado obtido para o RMSE na validação foi de 0,27 para a AAPL e 0,28 para a TSLA.

Avaliação dos resultados

Com a ajuda da Tabela 3 podemos observar os valores reais e as previsões relacionadas para os 3 dias posteriores ao dia 22/08/2022. Para isto, foi passado ao algoritmo os 60 valores anteriores ao

dia 23/08/2022. Observando os resultados foi possível verificar que ele previu corretamente o valor da ação AAPL no 2 dia.

Na Tabela 4 são exibidos os resultados obtidos na validação das previsões futuras para os dias 1, 2 e 3. Para avaliar a precisão das previsões dos modelos foram utilizados o MAPE e o RMSE.

Banik et al. (2022), em seus estudos, considerou um resultado para o MAPE abaixo de 6%, um valor muito bom. Desta forma, podemos inferir que apenas as ações AZUL4 e USIM5 ficaram fora do percentual adotado como referência. Nesse sentido, 80% dos casos ficaram dentro da margem de aceitabilidade. Com base nos resultados das métricas coletadas, podemos averiguar que o modelo proposto conseguiu identificar os padrões de comportamento das ações selecionadas em diversos setores econômicos da B3 e até do mercado norte americano.

Protótipo MB[3]

Após a validação do modelo, foi aplicado ao protótipo MB[3] que está sendo desenvolvido utilizando *flutter* que é um kit de desenvolvimento de interface de usuário, de código aberto, criado pela empresa Google. Na Figura 12 podemos observar uma visão geral de como funciona o app.

		Valor real da ação				Previsão para dias futuro		
		dia base (22/08/2022)	1 dia (23/08/2022)	2 dia (24/08/2022)	3 dia (25/08/2022)	1 dia (23/08/2022)	2 dia (24/08/2022)	3 dia (25/08/2022)
Petróleo, Gás e Biocombustíveis	PETR4	R\$ 32,41	R\$ 33,43	R\$ 33,63	R\$ 33,27	R\$ 31,91	R\$ 31,58	R\$ 31,20
	OSXB3	R\$ 5,10	R\$ 5,15	R\$ 4,93	R\$ 4,87	R\$ 4,90	R\$ 4,86	R\$ 4,80
Materiais Básicos	BRAP4	R\$ 22,44	R\$ 23,65	R\$ 23,07	R\$ 23,51	R\$ 22,56	R\$ 22,60	R\$ 22,65
	USIM5	R\$ 8,85	R\$ 9,71	R\$ 9,36	R\$ 9,29	R\$ 8,87	R\$ 8,84	R\$ 8,82
Bens Industriais	AZUL4	R\$ 15,70	R\$ 16,91	R\$ 17,26	R\$ 18,23	R\$ 15,68	R\$ 15,72	R\$ 15,82
	TGMA3	R\$ 16,03	R\$ 16,28	R\$ 16,85	R\$ 17,03	R\$ 15,98	R\$ 15,94	R\$ 15,89
Financeiro	SANB4	R\$ 15,55	R\$ 15,64	R\$ 15,67	R\$ 15,89	R\$ 15,49	R\$ 15,41	R\$ 15,35
	SULA4	R\$ 8,36	R\$ 8,38	R\$ 8,38	R\$ 8,40	R\$ 8,40	R\$ 8,42	R\$ 8,41
NASDAQ	AAPL	\$167,57	\$167,22	\$167,52	\$170,02	\$167,61	\$167,52	\$167,65
	TSLA	\$289,91	\$296,45	\$297,09	\$296,07	\$290,79	\$290,07	\$290,17

Tabela 3. Valores previstos para as ações.

Fonte: Criado pelo autor.

Na Figura 13 são exibidas as telas do protótipo MB[3] que inicialmente possibilitará ao usuário visualizar a previsão do valor de fechamento para o próximo dia da ação, assim como outras informações complementares do ativo acompanhado.

Considerações finais

A pesquisa conseguiu através do modelo LSTM realizar previsões dos

preços de fechamento de 8 ações existentes em 4 setores econômicos da B³ (“Petróleo, Gás e Biocombustíveis”, “Materiais Básicos”, “Bens Industriais” e “Financeiro”) e duas ações da bolsa de valores NASDAQ. Verificamos que apenas 20% dos MAPEs calculados ficaram acima do valor de 6%. Onde foram enquadrados nessas previsões consideradas ruins as ações AZUL4 e USIM5.

		Métricas					
		RMSE			MAPE(%)		
		1 dia	2 dia	3 dia	1 dia	2 dia	3 dia
Petróleo, Gás e Biocombustíveis	PETR4	0.04547	0.05321	0.05621	4,55	5,32	5,62
	OSXB3	0.04854	0.03137	0.02571	4,85	3,14	2,57
Materiais Básicos	BRAP4	0.04609	0.03323	0.03435	4,61	3,32	3,43
	USIM5	0.08651	0.07103	0.06422	8,65	7,1	6,42
Bens Industriais	AZUL4	0.07274	0.08098	0.09805	7,27	8,1	9,81
	TGMA3	0.01843	0.03622	0.04646	1,84	3,62	4,65
Financeiro	SANB4	0.00959	0.01309	0.02006	0,96	1,31	2,01
	SULA4	0.00239	0.00358	0.00762	0,24	0,36	0,76
NASDAQ	AAPL	0.00233	0.00117	0.00465	0,23	0,12	0,46
	TSLA	0.01909	0.02136	0.02088	1,91	2,14	2,09

Tabela 4. Métricas obtidas na validação da predição de valores futuros.

Fonte: Criado pelo autor.




Figura 12. Visão geral do protótipo.

Fonte: Criado pelo autor.

Foi possível observar também que apenas com a utilização do preço de fechamento o modelo conseguiu realizar boas previsões. Sendo verificado também que o modelo proposto conseguiu identificar os padrões de comportamento das ações de diversos setores selecionados e até de outro mercado de ações. No geral, os resultados foram aceitáveis, baseando-se nos estudos realizados por (Banik et al., 2022), e o modelo proposto poderá ser integrado ao protótipo.

Como trabalho futuro iremos adicionar mais features ao modelo, tais como: preço de abertura, maior e menor valor para a ação no dia e o volume. Desta forma, espera-se que a precisão na previsão seja melhorada. Outro ponto que podemos trabalhar também é o aumento da quantidade de dias previstos, para tentar identificar o movimento de tendência no preço de fechamento da ação e avaliação de diversos dias diferentes para cada ação desta forma poderemos obter uma maior precisão estatística.




Figura 13. Telas exibidas no aplicativo.

Fonte: Criado pelo autor.

Referências

B3. (2022, Agosto). Uma das principais empresas de infraestrutura de mercado financeiro do mundo. https://www.b3.com.br/pt_br/b3/institucional/quem-somos

Badri, A. K., Heikal, J., Terah, Y. A., & Nurjaman, D. R. (2022). Decision-making techniques using lstm on antam mining shares before and during the covid-19 pandemic in indonesia. *AP-TISI Transactions on Management (ATM)*, 6(2), 167-180.

Banik, S., Sharma, N., Mangla, M., Mohanty, S. N., & Shitharth, S. (2022). LSTM based decision support system for swing trading in stock market.

Knowledge-Based Systems, 239, 107994.

Bathla, G. (2020, November). Stock Price prediction using LSTM and SVR. In 2020 Sixth International Conference on Parallel, Distributed and Grid Computing (PDGC) (pp. 211-214). IEEE.

Capítulo 48 – Redes Neurais Recorrentes (2021, Julho). Deep learning. Disponível em: <https://www.deeplearningbook.com.br/redes-neurais-recorrentes/>

Capítulo 51 – Arquitetura de Redes Neurais Long Short Term Memory (LSTM) (2021, Agosto). Deep learning. <https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory>

Coqueret, G. (2021). Machine Learning in Finance: From Theory to Practice: by Matthew F. Dixon, Igor Halperin, and Paul Bilokon, Springer (2020). ISBN 978-3-030-41067-4. Paperback.

Dalla Corte, V., Dos Santos, V. K., & Casanova, D. (2019). Chatbot baseado em rede neural Long Short-Term Memory (LSTM): um estudo de caso baseado no livro William Shakespeare. Anais do Computer on the Beach, 484-492.

Dametto, R. C. (2018). Estudo da aplicação de redes neurais artificiais para previsão de séries temporais financeiras.

de Carvalho, H. V., Carvalho, E. C., Arruda, H., Imperatriz-Fonseca, V., de Souza, P., & Pessin, G. (2018, June). Detecção de anomalias em comportamento de abelhas utilizando redes neurais recorrentes. In Anais do IX Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais. SBC.

do Nascimento, K. K. F., da Silva Jale, J., & Ferreira, T. A. E. (2021). Simulação de mercado financeiro com compra e venda otimizadas por Enxame de Partículas. Ciência e Natura, 43, e21-e21.

Eugene, F. (1970). Efficient capital markets: A review of theory and empirical work. Journal of finance, 25, 383-417.

Jiang, W. (2021). Applications of deep learning in stock market prediction: recent progress. Expert Systems with Applications, 184, 115537.

Karasu, S., & Altan, A. (2022). Crude oil time series prediction model based on

LSTM network with chaotic Henry gas solubility optimization. Energy, 242, 122964.

Kaufman, D. (2019). A inteligência artificial mediando a comunicação: impactos da automação. Pós-verdade e Fake news. Reflexões sobre a guerra de narrativas. São Paulo: Cobogó.

Leandro, J. C. (2021). Aplicação de redes neurais LSTM para previsão de séries temporais financeiras.

Malkiel, B. G. (2003). The efficient market hypothesis and its critics. Journal of economic perspectives, 17(1), 59-82.

Nascimento, O. D. S., Santos, Felipe G., & Ferreira, Karl Hansimuller A. (2022). Previsão de preços de ações utilizando inteligência artificial.

Neves, J. L. (1996). Pesquisa qualitativa: características, usos e possibilidades. Caderno de pesquisas em administração, São Paulo, 1(3), 1-5.

Pacce, T. A. (2017). Estratégia de negociação baseada em Inteligência Artificial para atuação em mercados de capitais.

Raupp, F. M., & Beuren, I. M. (2006). Metodologia da pesquisa aplicável às ciências. Como elaborar trabalhos monográficos em contabilidade: teoria e prática. São Paulo: Atlas, 76-97.

Roondiwala, M., Patel, H., & Varma, S. (2017). Predicting stock prices using LSTM. International Journal of Science and Research (IJSR), 6(4), 1754-1756.

StandardScaler. (2022, Julho). Scikit-learn. <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>

Segatto, Ê. C., & Coury, D. V. (2006). Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. Sba: Controle & Automação Sociedade Brasileira de Automatica, 17, 424-436.

Souto, G., Capistrano, B., Matias, M., Soares, J., Ogasawara, E., & Giusti, L. (2021, November). 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 (pp. 65-71). SBC.

Shah, D., Isah, H., & Zulkernine, F. (2019). Stock market analysis: A review and taxonomy of prediction techniques. International Journal of Financial Studies, 7(2), 26.

Vasco, L. P. (2020). Um estudo de redes neurais recorrentes no contexto de previsões no mercado financeiro.

Wang, W., & Lu, Y. (2018, March). Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model. In IOP conference series: materials science and engineering (Vol. 324, p. 012049). IOP Publishing.

Yfinance. (2022, Maio). Project description. <https://pypi.org/project/yfinance>

Os autores gostariam de agradecer à FACEPE e ao CNPq pelo suporte para a realização deste trabalho

Taciano Amorim (taciano.amorim@ufrpe.br)* trabalhou na realização da pesquisa e escrita do artigo.

Gustavo Callou (gustavo.callou@ufrpe.br) trabalhou na orientação da pesquisa.

Saulo Pereira (saulo.eduardo@ufrpe.br) trabalhou nas revisões e na pesquisa do referencial teórico.

Anderson dos Santos (anderson.sena@ufrpe.br) trabalhou nas revisões e na pesquisa do referencial teórico.

*Autor-correspondente.

Data de Submissão: 08/12/2022 Data de Aprovação: 01/06/2023

Editor-Chefe: André Luiz Maranhão de Souza-Leão.

Editor Adjunto: Bruno Melo Moura.

Editores da submissão: Denis Silva da Silveira e Jairo Simião Dornelas.

Esta obra está licenciada sob uma Licença Creative Commons Atribuição 4.0 Internacional (CC BY NC 4.0). Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do trabalho, para fins não comerciais, desde que lhe atribuam o devido crédito pela criação original. Texto da licença: https://creativecommons.org/licenses/by-nc/4.0/deed.pt_BR.