

doi:10.12662/2359-618xregea.v11i2.p25-36.2022

ARTIGOS

**APLICAÇÃO DE REDES NEURAS RECORRENTES
NA PREVISÃO DE SÉRIES TEMPORAIS: UM
ESTUDO DE PREÇOS DE AÇÕES DA BOLSA DE
VALORES¹****APPLICATION OF RECURRENT NEURAL
NETWORKS IN THE PROVISION OF TIME
SERIES: A STUDY OF STOCK EXCHANGE STOCK
PRICES**

RESUMO

Gabriel Dilly Vieira Furtuoso
gabriel_dilly@hotmail.com
*Graduado em Engenharia de
Computação pelo Instituto
Militar de Engenharia
(IME). Engenheiro do Centro
Tecnológico do Exército (CTEx).
Rio de Janeiro - RJ - BR.*

Marcos dos Santos
**marcosdossantos_doutorado_uff@
yahoo.com.br**
*Doutor em Engenharia de
Produção (UFF). Professor
do MBA em Data Science e
Analytics da Universidade de
São Paulo (USP). Professor
colaborador da UFF, atuando
no Programa de Pós-graduação
em Engenharia de Produção.
Rio de Janeiro - RJ - BR.*

Renato Santiago Quintal
rsantiago79@hotmail.com
*Doutor em Ambiente e
Desenvolvimento pelo
Programa de Pós-graduação em
Ambiente e Desenvolvimento da
Universidade do Vale do Taquari
(PPGAD/Univates). Professor
do Magistério Superior e
Encarregado da Célula de
Inovação Tecnológica da Escola
Naval (CIT-EN). Rio de Janeiro
- RJ - BR.*

A predição de eventos futuros de modo assertivo tem sido o objeto de análise de diversos pesquisadores, sobretudo na área financeira. Nesse contexto, são inúmeras as possibilidades do emprego desse ferramental no processo decisório de gestores e analistas de investimentos. O objetivo deste artigo é propor um modelo de rede neural recorrente com base no estudo de séries temporais, orientado à predição e estimação do preço de ações da Bolsa de Valores brasileira. Nesse contexto, o presente estudo viabiliza a caracterização de direções de tendências financeiras e a predição dos preços por meio do treinamento da rede neural, empregando dados reais da Bolsa de Valores brasileira a partir do ano de 2010. No que concerne à metodologia, a presente pesquisa pode ser classificada como aplicada, explicativa, quanto a seus objetivos, e quantitativa quanto à forma de abordagem. Os resultados obtidos neste estudo revelam a capacidade de aprendizado de problemas complexos e, conseqüentemente, a possibilidade de aplicação em outras áreas.

Palavras-chave: *deep learning*; redes neurais recorrentes; predição de preços; bolsa de valores.

ABSTRACT

Future events prediction in an assertive way has been the object of analysis by several researchers, especially in the financial area. In this context, there are countless possibilities for using this tool in the decision-making process of investment managers

¹ Os autores agradecem aos ilustres pareceristas da Revista Gestão em Análise pelas críticas e sugestões feitas à versão original do texto.

and analysts. This article aim to propose a recurrent neural network model based on the study of time series, oriented to the prediction and estimation of the price of shares on the Brazilian stock exchange. In this context, the present study enables the characterization of directions of financial trends and the prediction of prices from the training of the neural network, using real data from the Brazilian stock exchange in the year 2010. Regarding the methodology, the present research can be classified as applied, explanatory, in terms of its objectives, and quantitative in terms of its approach. The results obtained in this study reveal the ability to learn complex problems and, consequently, the possibility of application in other areas.

Keywords: deep learning; recurrent neural networks; price prediction; stock exchange.

1 INTRODUÇÃO

Bressan (2004) aponta que distintas técnicas de previsão contribuem para a tomada de decisões por parte dos agentes envolvidos em atividades que demandam planejamento, avaliação de políticas e redução da incerteza. Nesse contexto, o autor supracitado argumenta que uma das possíveis alternativas para diminuir a incerteza no processo de tomada de decisões econômicas é o emprego de modelos de previsão de séries temporais ou univariadas. Amparados na análise unicamente da variável em si, tais modelos são elaborados por meio de processos estocásticos especiais que almejam estimar o valor futuro da variável em questão com base somente em seus valores passados.

Garcia (2017) revela que a análise de séries temporais é essencial para o apoio à tomada de decisões e para o estabelecimento de estratégias, em âmbito empresarial, financeiro, e, cada vez mais, organizações empregam previsões de séries temporais na etapa de tomada de decisões. O robusto quantitativo de infor-

mações armazenadas nas bases de dados em distintas áreas nos possibilita realizar estudos com base no passado para podermos extrapolar para o futuro. A previsão de determinados fatos favorece a tomada de decisões as quais poderão aperfeiçoar o desempenho das organizações ou, até mesmo, minimizar prejuízos.

Atualmente, as séries temporais possuem diversas aplicações em problemas do mundo real como na projeção de dados financeiros corporativos e macroeconômicos, na previsão meteorológica, na estimativa de produção de indústrias, entre outros.

Mediante técnicas de *deep learning*, é possível analisar essas séries temporais e estimar resultados futuros para um determinado evento. Segundo Leondes (2001), prever o comportamento futuro de sistemas mediante redes neurais tem sido intensamente estudado, visto que, por meio delas, é possível aprender relações não lineares entre entradas e saídas de dados desejadas.

As soluções para problemas atuais com caráter não estacionário, com incerteza e complexidade, requerem o processamento não linear de dados, sendo a abordagem por redes neurais uma das mais poderosas, visto que o aprendizado dentro dos modelos ocorre por meio de exemplos reais e há forte base teórica estatística.

Tipirisetty (2018) argumenta que prever com precisão o valor de uma ação tem sido o objetivo de muitos investidores desde o início do mercado financeiro. Com tanto dinheiro circulando diariamente, todo *trader* deseja obter lucro em suas operações. Para o autor supracitado, investir consiste basicamente em tomar decisões mediante julgamento e análises diversas. Porém, com tantas informações e notícias, não é fácil perceber movimentos rápidos e fazer previsões assertivas. É nesse contexto que Tipirisetty (2018) revela que várias técnicas de inteligência artificial vêm sendo investigadas para prever tendências automaticamente.

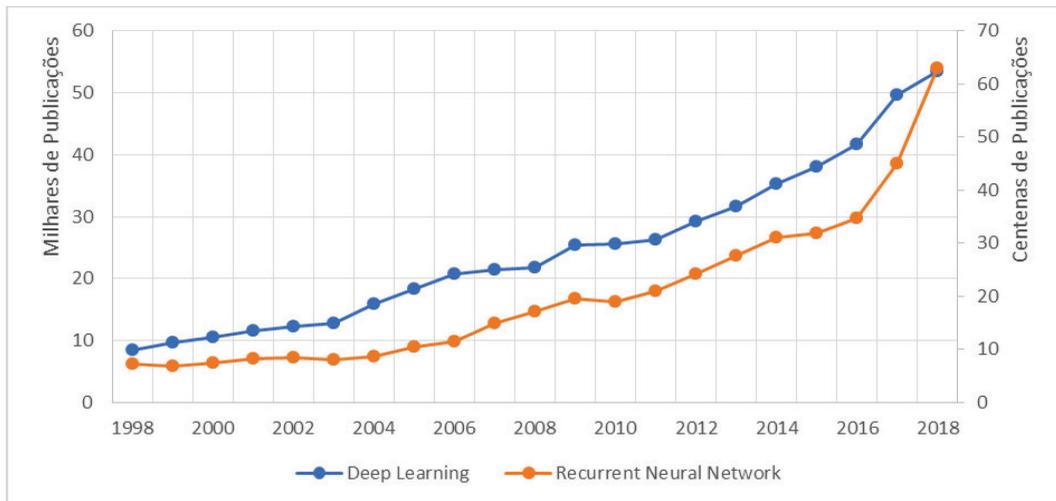
Neste artigo, é apresentada uma abordagem de predição de preços de ações da Bolsa de Valores brasileira por meio de séries temporais

e de redes neurais recorrentes LSTM (*long short-term memory*). Assim, o objetivo pretendido é avaliar o comportamento das previsões de acordo com diferentes parâmetros para a modelagem do problema, comparando os resultados previstos com os valores reais mediante uma base de dados de teste.

Nesse contexto, o objetivo deste artigo é propor um modelo de rede neural recorrente com base no estudo de séries temporais, orientado à previsão e estimação do preço de ações da Bolsa de Valores brasileira.

Para evidenciar a relevância do assunto estudado, é possível constatar o crescente número de publicações sobre *deep learning* e *recurrent neural network (RNN)* a partir da figura 1. Destaca-se que o tópico RNN apresentou um crescimento percentual maior nos últimos 20 anos relativamente. De janeiro de 2018 até a metade do mês de novembro, havia 53.441 publicações sobre o primeiro assunto e 6.301 sobre o segundo, respectivamente.

Figura 1 – Número de publicações por ano



Fonte: adaptado do portal de periódicos CAPES (PERIODICOS CAPES, 2019, online).

A próxima seção tratará da descrição do problema.

2 DESCRIÇÃO DO PROBLEMA

Predizer e projetar os preços de ações da Bolsa brasileira não é uma tarefa fácil, visto que há diversos fatores que influenciam na precificação de uma empresa pelo mercado, por exemplo: os resultados financeiros das companhias, notícias inesperadas, especulação financeira, o contexto macroeconômico do país e o contexto do setor no qual a empresa está inserida.

Os ativos negociados na Bolsa apresentam basicamente quatro números principais que resumem o comportamento durante um

dia útil de negociação: o preço de abertura, a máxima do dia, a mínima do dia e o preço de fechamento. Além desses, há também outros números como o volume negociado, a volatilidade do ativo etc.

Neste artigo, o problema fica restrito a estimar o preço de abertura e o preço de fechamento do próximo dia útil de negociação. Ou seja, por meio de um período especificado de dias com os quatro parâmetros do ativo conhecidos, deseja-se estimar a abertura e o fechamento do dia seguinte. Nesse caso, cada observação do preço das ações é diária, caracterizando uma série temporal.

Vale destacar que, de um dia para outro, pode haver grandes oscilações nos preços das

ações ocasionadas por fatores de incerteza, como notícias e divulgações de resultados financeiros. Assim, não é possível prever, com exatidão, esses dias, porém o objetivo desejado é ser capaz de identificar os movimentos de tendências e estimar, com uma faixa de erro tolerável, as cotações.

A aplicação de redes neurais surge da necessidade de criar um modelo capaz de prever os preços desejados com a menor taxa de erro possível. Perante uma base de treinamento, exemplo de como o preço se comportou no período, a rede neural será treinada e tentará identificar características que permitam prever novas ocorrências.

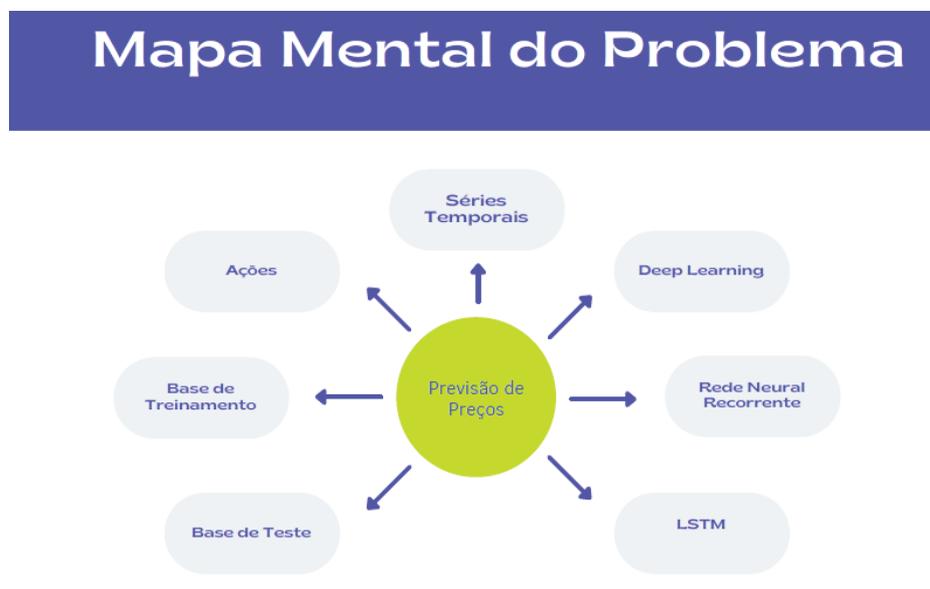
Para McNelis (2005), ao contrário das ciências exatas, como a Física ou a Engenharia, a medição e os procedimentos estatísticos de diagnósticos e previsões não são tão claramente separáveis dos objetivos dos pesquisadores, dos tomadores de decisão e atores do mercado. Este é um ponto sutil, mas importante, que precisa ser enfatizado. Quando formulamos modelos aproximados para as taxas de retorno nos mercados financeiros, estamos, na verdade, tentando prever as previsões de outros. As taxas de retorno aumentam ou diminuem em reação a mudanças nas notícias públicas ou privadas, porque os *traders* estão reagindo às notícias e comprando ou

vendendo ativos. Aproximar o modelo real significa levar em consideração que, ao formularmos nossos modelos, como os *traders* – seres humanos como nós – realmente aprendem, processam informações e tomam decisões.

As aplicações da previsão do preço de ações são inúmeras. Por meio da cotação do dia seguinte, é possível prever movimentos de alta ou de baixa, assumindo uma posição no mercado com capital de investimento. Também é possível identificar tendências de longo prazo mediante o gráfico com as projeções de preços e até monitoramento das ações de várias empresas com o objetivo de encontrar novas oportunidades de investimentos. Assim, a previsão é capaz de auxiliar investidores na tomada de decisões. Porém, ela não deve ser utilizada sem a análise crítica dos dados gerados, pois o investimento em ações possui alto risco, e os desempenhos anteriores aqui abordados não implicam necessariamente resultados futuros.

Os principais conceitos envolvidos no problema abordado estão mapeados na figura 2, em que é possível perceber a abrangência de fatores envolvidos e a possibilidade de futuros estudos, visando otimizar a utilização de cada tecnologia apresentada.

Figura 2 – Mapa mental do problema



Fonte: elaborada pelos autores, a partir de informações da pesquisa, no Portal Canva (2022, online).

A seção seguinte tratará da fundamentação teórica.

3 FUNDAMENTAÇÃO TEÓRICA

A predição de preços de ações abordada neste artigo é baseada em redes neurais recorrentes, que podem ser mais bem compreendidas mediante conceitos teóricos a seguir extraídos de diversas literaturas.

3.1 MACHINE LEARNING

Segundo Tipirisetty (2018), *machine learning* é uma área da Ciência da Computação que concede aos computadores a habilidade de aprender. Existem duas categorias principais de algoritmos de aprendizagem de máquina: o aprendizado supervisionado e o não supervisionado.

O processo de treinamento de um modelo envolve um algoritmo e os dados de modo que o modelo aprende seus parâmetros pelas informações fornecidas para treinamento.

No aprendizado supervisionado, busca-se encontrar uma função f tal que $y = f(x)$, sendo x as entradas do modelo e y o resultado final, por meio de dados conhecidos de treinamento. Para Tipirisetty (2018), esses algoritmos podem ser agrupados em regressões e classificações, que englobam variáveis finais contínuas ou discretas, respectivamente.

O aprendizado não supervisionado, segundo Tipirisetty (2018), consiste em inferir padrões mediante dados de entrada apenas, sendo divididos em algoritmos de clusterização e de associação.

3.2 DEEP LEARNING: DEFINIÇÃO

Deep learning se refere a um conjunto de métodos mais amplos de *machine learning* baseados em representações de dados em múltiplos níveis. Esses métodos

são obtidos pela composição de módulos simples, mas não lineares, em que cada módulo transforma os dados recebidos em abstrações de nível mais alto. Pela composição, funções muito complexas podem ser aprendidas, e características importantes das entradas podem ser amplificadas, permitindo a diferenciação em uma tarefa de classificação, por exemplo. Cada módulo é conhecido como camada, que é projetada por algoritmos pelo aprendizado de máquina (LECUN; BENGIO; HINTON, 2015).

3.3 REDE NEURAL RECORRENTE: CONCEITUAÇÃO

Primeiramente, redes neurais se assemelham com a estrutura neural de um cérebro, cujo aprendizado ocorre por meio da experiência (DI PERSIO; HONCHAR, 2016). Elas podem ser caracterizadas pelo padrão de conexão entre os neurônios, ou seja, suas arquiteturas, pelo método de determinação dos pesos nas conexões (algoritmo de aprendizado) e pela função de ativação (FAUSETT, 1994).

Os modelos computacionais ou nós da rede são conectados por meio de pesos que são adaptados durante o processo de melhora de performance. A ideia principal é atingir uma boa performance pela interconexão densa de elementos computacionais simples. Cada modelo de rede neural é especificado de acordo com a topologia da rede, as características dos nós, a quantidade de camadas e as regras de treinamento e aprendizado. Pela perspectiva de padrões de conexão, as redes podem ser divididas em duas categorias: *feedforward networks*, nas quais os grafos não possuem loops, e *recurrent networks*, que possuem loop (MANDIC; CHAMBERS, 2001).

Assim, uma rede neural recorrente consiste em múltiplas camadas recorrentes bidirecionais, seguidas por uma ou mais camadas totalmente conectadas, permitindo que a rede acesse estados ocultos das etapas anteriores e posteriores, melhorando sua capacidade de

entender cada característica dentro de um contexto, ou seja, a rede é capaz de memorizar, temporariamente, informações de estados anteriores, vantagem útil no estudo de séries temporais (CHOW, 2017).

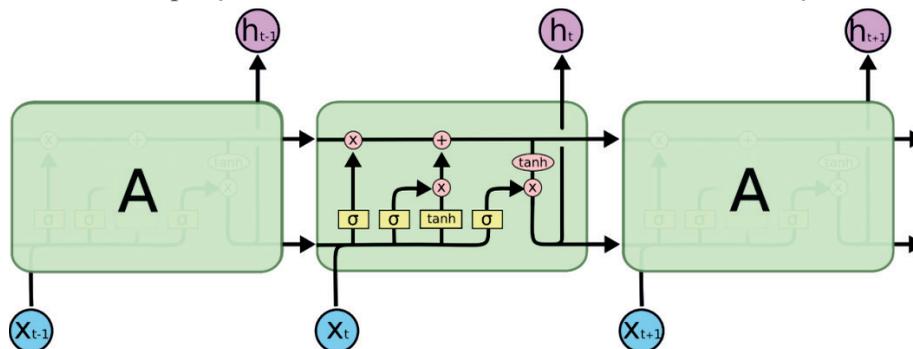
3.4 LSTM: CONCEITO E FUNCIONAMENTO

Em uma rede neural recorrente tradicional, a memória dos neurônios é curta, e existem os problemas de *vanish gradient* e *exploding gradient*, que podem ocorrer em estudos em que uma memorização em longo prazo é necessária (SAGHEER; KOTBB, 2019). Visando resolver esse problema, introduz-se o conceito de *long short term memory* (LSTM) por meio do qual células de memória capazes de aprender dependências em longo prazo são inseridas na rede. Essas células podem adicionar ou remo-

ver informações em seus estados pelas portas, que são entradas opcionais de dados.

Modelos LSTM possuem a mesma estrutura em cadeia de redes neurais recorrentes tradicionais, porém o módulo de repetição possui quatro camadas, que interagem de forma bem específica, apresentadas na figura 3, em vez de apenas uma camada presente no modelo tradicional. A parte principal dessa estrutura é a linha horizontal superior que corresponde ao estado da célula, o qual percorre toda a cadeia sofrendo apenas algumas interações lineares. A habilidade de adicionar e remover informações do estado da célula é regulada por estruturas chamadas de portas. A primeira camada é responsável por decidir o que será apagado da memória, a segunda e a terceira decidem o que será armazenado. Após o estado antigo ser atualizado, a quarta camada decide qual será a saída da célula.

Figura 3 – Módulo de repetição em uma rede LSTM com 4 camadas de interação



Fonte: (OLAH, 2015, *online*).

4 METODOLOGIA DA PESQUISA

De acordo com Rodrigues (2007), o presente estudo pode ser classificado como uma pesquisa aplicada, que tem por propósito investigar, comprovar ou rejeitar hipóteses sugeridas pelos modelos teóricos. De acordo com Rodrigues (2007), pesquisa em tela pode ser categorizada como explicativa quanto a seus objetivos, uma vez que almeja a identificação de fatores determinantes para a ocorrência de um fenômeno. Por fim, conforme Rodrigues (2007), quanto à abordagem, a pesquisa em questão pode ser classificada como quantitativa.

O modelo proposto para prever preços de ações da Bolsa de Valores brasileira é baseado em redes neurais recorrentes LSTM. Por meio de uma base de dados com preços reais, formou-se uma base de treinamento para o aprendizado supervisionado da rede e uma base de teste para a avaliação do comportamento das previsões.

Em todos os casos de teste, foram adotados, como período de treinamento, os dias úteis desde 1º de janeiro de 2010 até 30 de junho de 2018 e, como período de teste, os dias úteis desde 1º de julho de 2018 até 15 de novembro de 2018.

Todos os dados com as cotações das ações foram obtidos pela plataforma *MetaTrader 5* (METATRADER5, 2022), que permitiu a exportação dos 4 números desejados no estudo (o preço de abertura, a máxima do dia, a mínima do dia e o preço de fechamento) para o período desejado no formato *.csv*.

Para este estudo, escolheram-se algumas ações de maior relevância na bolsa, analisando o volume negociado no último ano e a volatilidade. As ações selecionadas no estudo estão relacionadas no quadro 1, sendo as informações referentes ao último ano (nov/17 a nov/18).

Quadro 1 – Ações selecionadas para o estudo do modelo

| Ativo | Nome | Volatilidade | Volume Médio |
|-------|------------------|--------------|--------------|
| IBOV | Ibovespa | 22,24% | 387M |
| PETR4 | Petrobras PN | 52,14% | 62M |
| ABEV3 | Ambev S/A ON | 21,34% | 16M |
| ITUB4 | Itaú Unibanco PN | 29,49% | 13M |
| BBDC4 | Bradesco PN | 31,91% | 13M |
| NATU3 | Natura ON | 38,34% | 2M |

Fonte: adaptado do portal Bovespa²

Para o processamento dos dados e treinamento dos modelos, foi utilizada a linguagem *Python* junto com as bibliotecas *Keras* e *Tensorflow*, seguindo as implementações de redes neurais recorrentes LSTM propostas por Gulli e Pal (2017), utilizando os conceitos de normalização dos dados de entrada e saída da rede.

Como caso inicial de teste, foi projetada uma rede neural com quatro camadas: uma camada LSTM com cem neurônios, duas camadas LSTM com cinquenta neurônios e uma camada densa com cinquenta neurônios utilizando a função de ativação linear. Todas as

quatro camadas tiveram o parâmetro *dropout* setado em 0,3. O número de lotes para o treinamento considerado foi trinta e dois, e o período de treinamento foi de cem épocas.

Em todos os casos de teste, utilizou-se a função *loss* do erro quadrático médio para a otimização do modelo e dos resultados de teste; além disso, foi considerado como algoritmo otimizador de gradiente descendente o RMSProp.

Para cada ativo, dois tipos de modelo foram treinados: um modelo para prever o preço de abertura do dia seguinte, tendo como entradas apenas os preços de abertura dos dias anteriores, e outro modelo para prever o preço de fechamento do dia seguinte, tendo como entradas apenas os preços de fechamento dos dias anteriores.

Não foi incluída neste estudo a abordagem de redes neurais com mais de um tipo de variável como entrada, por exemplo, com os quatro números característicos de dia de negociação de ações citados anteriormente, sendo uma possibilidade de pesquisa futura e aprofundamento no tema.

Como período de memória das células LSTM, foram considerados inicialmente noventa dias de movimentações, ou seja, considerou-se que os últimos noventa dias de uma ação são suficientes para prever o preço do dia seguinte.

Buscando obter melhores resultados, foram feitas pequenas variações dos parâmetros da rede neural, gerando novos modelos, com o objetivo de comparar as soluções ótimas para cada ativo selecionado.

Os principais parâmetros que foram testados com variações foram a quantidade de camadas LSTM da rede, o período de memória da rede, o tamanho do lote para o treinamento e a função de ativação da camada densa do modelo.

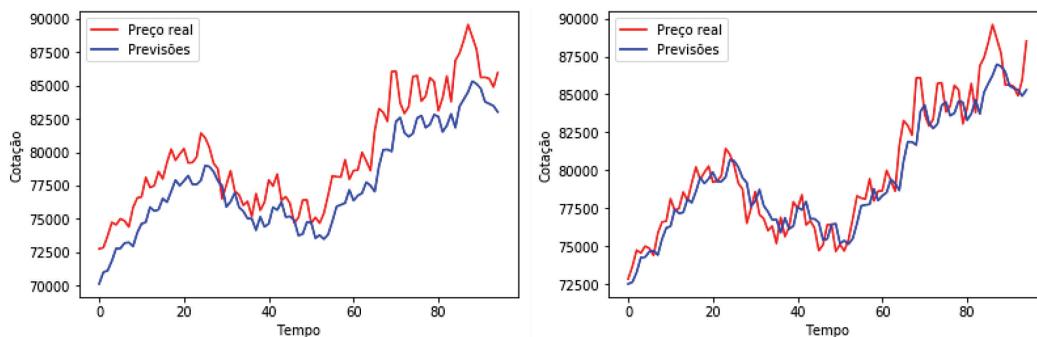
2 Portal Bovespa. Disponível em: http://www.b3.com.br/pt_br/. Acesso em: 10 jan. 2019

5 RESULTADOS

Com base nos casos de teste propostos, foram gerados os resultados a seguir para a predição dos preços de abertura e de fechamento para os ativos da Bolsa de Valores brasileira propostos. Todos os períodos de tempo considerados foram em dias. Os valores para o índice Ibovespa estão na escala de pontos, e os valores para as demais ações estão em reais.

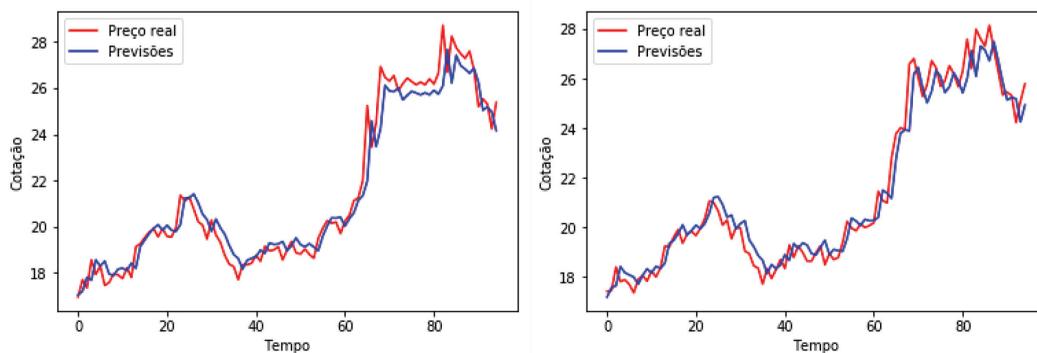
Para o caso inicial descrito no modelo proposto, foram gerados os seguintes resultados:

Figura 4 – Previsão IBOV dos preços de abertura e de fechamento, respectivamente



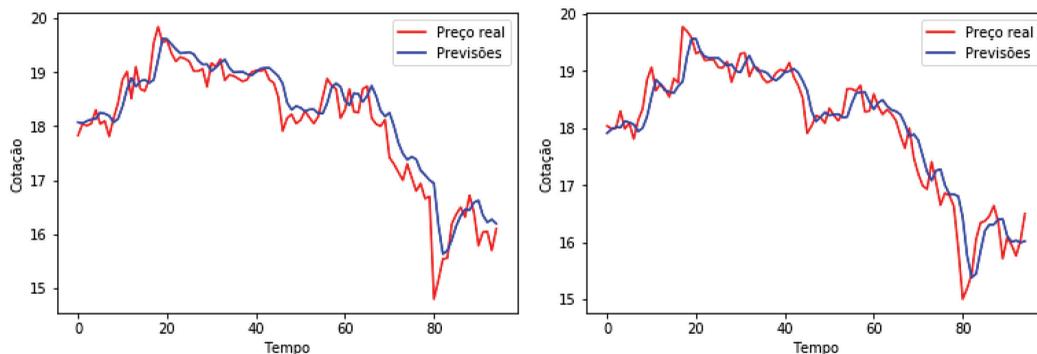
Fonte: dados da pesquisa.

Figura 5 – Previsão PETR4 dos preços de abertura e de fechamento, respectivamente



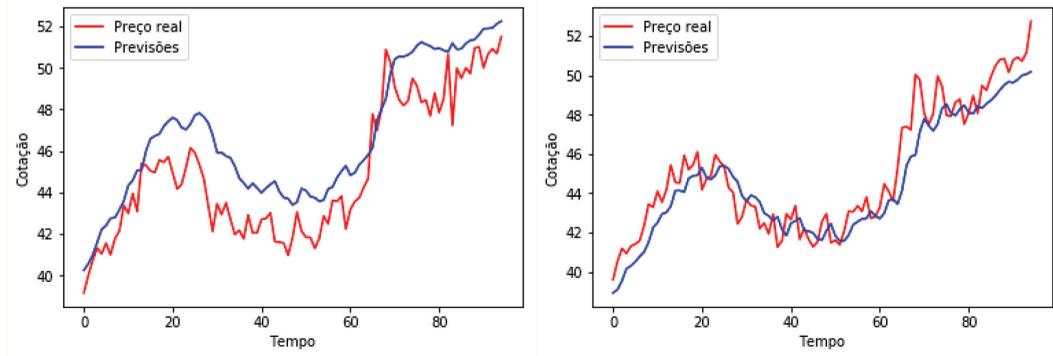
Fonte: dados da pesquisa.

Figura 6 – Previsão ABEV3 dos preços de abertura e de fechamento, respectivamente



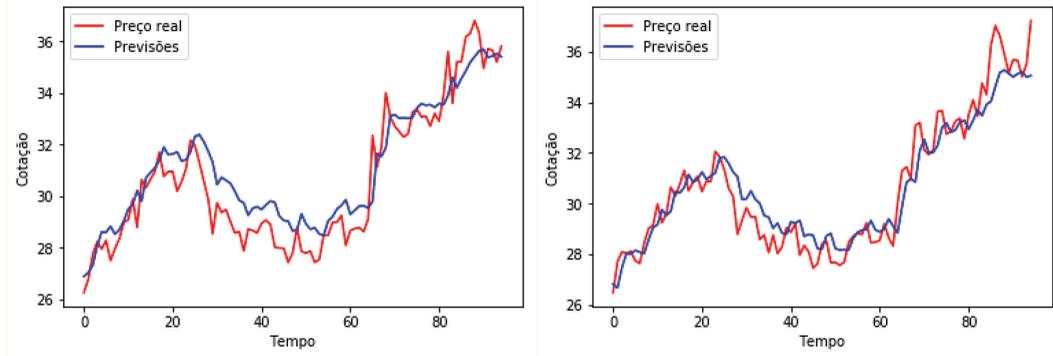
Fonte: dados da pesquisa.

Figura 7 – Previsão ITUB4 dos preços de abertura e de fechamento, respectivamente



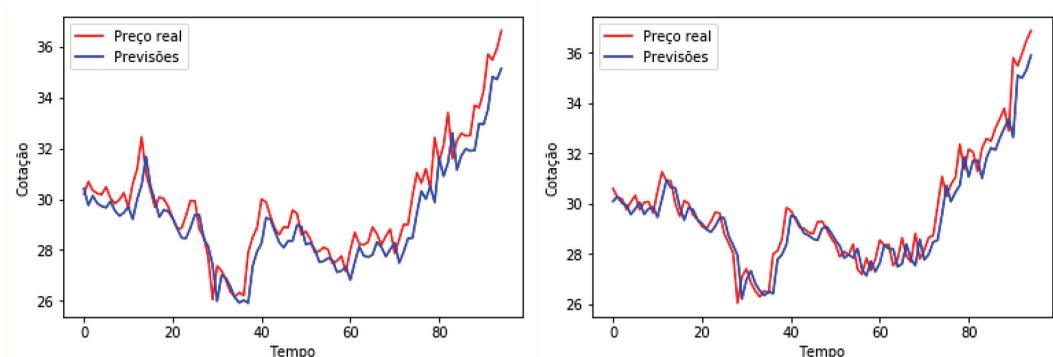
Fonte: dados da pesquisa.

Figura 8 – Previsão BBDC4 dos preços de abertura e de fechamento, respectivamente



Fonte: dados da pesquisa.

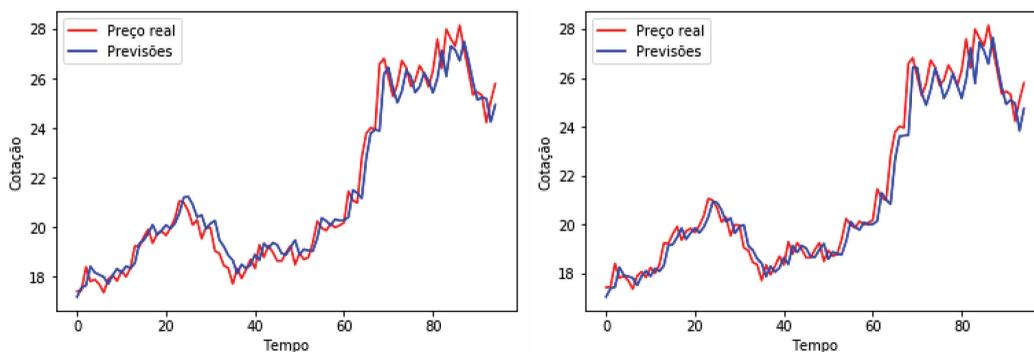
Figura 9 – Previsão NATU3 dos preços de abertura e de fechamento, respectivamente



Fonte: dados da pesquisa.

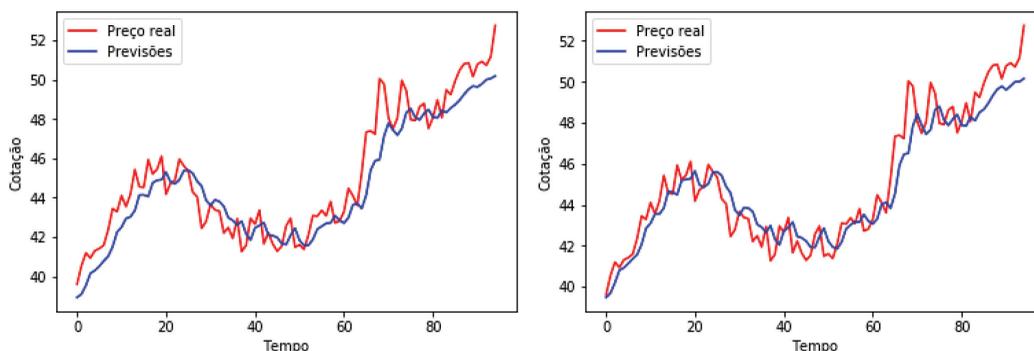
Uma das variações testadas foi a remoção de uma camada LSTM de cinquenta neurônios, totalizando três camadas para a rede neural. Esse teste foi feito para o preço de fechamento das ações da Petrobrás, do Itaú e do Bradesco, cujos gráficos comparando o modelo de quatro camadas com o de três camadas estão nas figuras 10, 11 e 12.

Figura 10 – Comparação do modelo de quatro camadas com o modelo de três camadas PETR4



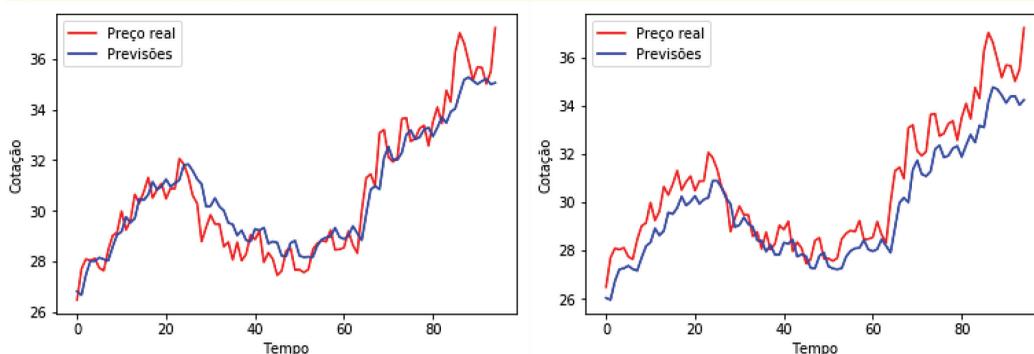
Fonte: dados da pesquisa.

Figura 11 – Comparação do modelo de quatro camadas com o modelo de três camadas ITUB4



Fonte: dados da pesquisa.

Figura 12 – Comparação do modelo de quatro camadas com o modelo de três camadas BBDC4



Fonte: dados da pesquisa.

Além da remoção da quantidade de camadas, testou-se, também, a substituição da função de ativação linear para *sigmoid*, a adição de uma camada LSTM de cinquenta neurônios, a variação do período de memória das células LSTM para cinquenta e cento e cinquenta dias e o aumento da quantidade de neurônios da primeira camada do caso inicial de teste para cento e cinquenta. Porém, não foram obtidos resultados superiores às previsões apresentadas anteriormente.

6 DISCUSSÃO

Observando as figuras 4, 5, 6, 7, 8, e 9, é possível perceber a diferença do comportamento das predições de preços de abertura e de fechamento. Nota-se que a rede neural foi capaz de prever melhor o preço de fechamento dos ativos. Uma possível explicação para isso pode ser o fato de que a abertura do mercado está sujeita a maiores variações devido a notícias inesperadas, que podem surgir de um dia para o outro, e ao leilão do início do pregão, enquanto o fechamento do mercado já engloba as correções e reações dos investidores durante o dia.

Nos casos de teste com a remoção de uma camada da rede neural recorrente, perceberam-se comportamentos diferentes para as ações da Petrobrás, Itaú e Bradesco. Enquanto as duas primeiras apresentaram melhoras nas predições, evidentes nas figuras 10 e 11, a previsão do preço de fechamento das ações do Bradesco apresentou maior erro com a remoção de uma camada. Com base nessa observação, pode-se inferir que, para cada ativo diferente, existe uma modelagem que se adapta melhor ao perfil daquela companhia ou índice, sendo assim necessário avaliar, separadamente, cada ação.

Destaca-se, também, que várias das previsões apresentaram um *delay* entre o preço real e a previsão. Isso decorre da incerteza de predição de eventos aleatórios e pode variar de acordo com o modelo adotado. Assim, constata-se que a predição de preços de ações por meio de séries temporais pode ser mais bem empregada na determinação de tendências e movimentos do mercado, mas não é capaz de determinar, precisamente, o preço futuro de um ativo, estando de acordo com Bekiros e Georgoutsos (2008).

7 CONCLUSÕES

Com base neste estudo, foi possível perceber a aplicação de redes neurais recorrentes LSTM na predição de séries temporais com o foco na bolsa de valores brasileira.

Por meio dos resultados obtidos neste artigo, os autores da pesquisa vislumbram a pos-

sibilidade da aplicação desse conhecimento em outras áreas de conhecimento, especialmente pela capacidade de aprendizado de problemas complexos proveniente dos métodos de *deep learning*.

Com o método adotado, foi possível estimar os preços de abertura e fechamento de ações da Bolsa, levando em consideração que cada ativo possui uma configuração da arquitetura da rede neural que permite obter melhores predições. Assim, destaca-se a oportunidade de estudar o comportamento de outras ações, com períodos diferentes para o treinamento e o teste do modelo, visando encontrar soluções ainda mais precisas para o mercado financeiro.

Além disso, com uma metodologia semelhante, é possível estender essa abordagem para estimar outras grandezas utilizando séries temporais como já citado anteriormente: estimativa de variáveis climáticas com base em dados meteorológicos, estimativa do número mensal de passageiros que viajam de avião e estimativa do lucro mensal de uma companhia etc.

REFERÊNCIAS

- BEKIROU, Stelios D.; GEORGOUTSOS, Dimitris A. Direction-of-change forecasting using a volatility-based recurrent neural network. **Journal of Forecasting**, v. 27, no. 5 p. 407-417, 2008. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/for.1063>. Acesso em: 27 mar. 2022.
- BRESSAN, Aureliano Angel. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE eletrônica**, v. 3, n. 1, 2004. Disponível em: <https://www.scielo.br/pdf/raeel/v3n1/v3n1a04.pdf>. Acesso em: 27 mar. 2022.
- CANVA. **Elaboração de templates online de mapas mentais**. Disponível em: https://www.canva.com/design/DAE85T4QTJc/Idou36H9jtOGQw_tqKlb9w/view?utm_content=DAE85T4QTJc&utm_campaign=designshare&utm_medium=link2&utm_source=sharebutton. Acesso em: 27 mar. 2022.

- CHOW, Vinci. **Predicting Auction Price of Vehicle License Plate with Deep Recurrent Neural Network**. [S.l.]: The Chinese University of Hong Kong, 2017.
- DI PERSIO, Luca; HONCHAR, Oleksandr. Artificial neural networks architectures for stock price prediction: Comparisons and applications. **International journal of circuits, systems and signal processing**, v. 10, n. 2016, p. 403-413, 2016. Disponível em: <https://iris.univr.it/retrieve/handle/11562/955101/60620/>. Acesso em: 27 mar. 2022.
- FAUSETT, Laurene. **Fundamentals of neural networks: architectures, algorithms, and applications**. Upper Saddle River: Prentice-Hall, Inc., 1994.
- GARCIA, Elsa Maria Alves. **Previsão de séries temporais financeiras: o caso PSI 20**. 2017. Dissertação (Mestrado em Matemática Financeira) - Faculdade de Ciências, Universidade de Lisboa, Lisboa, 2017. Disponível em: <http://hdl.handle.net/10451/30762>. Acesso em: 27 mar. 2022.
- GULLI, Antonio; PAL, Sujit. **Deep Learning with Keras**. Birmingham: [s.n.], 2017.
- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, v. 521, n. 7553, 2015. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 27 mar. 2022.
- LEONDES, Cornelius T. **Expert Systems: the technology of knowledge management and decision making for the 21st Century**. [S.l.]: Academic Press, 2001.
- MANDIC, Danilo P.; CHAMBERS, Jonathon. **Recurrent neural networks for prediction: learning algorithms, architectures and stability**. New York: John Wiley & Sons, Inc., 2001.
- MCNELIS, Paul D. **Neural networks in finance: gaining predictive edge in the Market**. Burlington: Elsevier Academic Press, 2005.
- METATRADER5. **Plataforma poderosa para Forex e mercado de ações**. Disponível em: <https://www.metatrader5.com/pt>. Acesso em: 27 mar. 2022.
- OLAH, Christopher. **Understanding lstm networks**. 2015. Disponível em: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>. Acesso em: 27 mar. 2022.
- PERIODICOS CAPES. **Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior**. Disponível em: <https://www.periodicos.capes.gov.br/>. Acesso em: 10 jan. 2019.
- RODRIGUES, William Costa. **Metodologia científica**. Paracambi: Faetec/IST, 2007.
- SAGHEER, Alaa; KOTB, Mostafa. Time series forecasting of petroleum production using deep LSTM recurrent networks. **Neurocomputing**, v. 323, p. 203-213, 2019. Disponível em: <https://doi.org/10.1016/j.neucom.2018.09.082>. Acesso em: 27 mar. 2022.
- TIPIRISETTY, Abhinav. **Stock Price Prediction using Deep Learning**. Projetos de Mestrado. San Jose State University, 2018.