

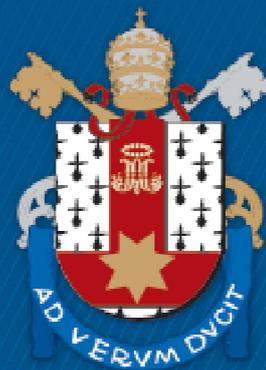
ESCOLA POLITÉCNICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO  
MESTRADO EM CIÊNCIA DA COMPUTAÇÃO

PAULO RICARDO PRASS

**PREVISÃO FINANCEIRA COM APRENDIZADO PROFUNDO E  
INTELIGÊNCIA ARTIFICIAL**

Porto Alegre  
2025

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica  
do Rio Grande do Sul

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DE COMPUTAÇÃO**

**PREVISÃO FINANCEIRA COM  
APRENDIZADO PROFUNDO E  
INTELIGÊNCIA ARTIFICIAL**

**PAULO RICARDO PRASS**

Dissertação de Mestrado apresentada à  
Pontifícia Universidade Católica do Rio  
Grande do Sul em cumprimento parcial  
aos requisitos para obtenção do grau de  
mestre em ciência da computação

Orientador: Prof. Dr. César Marcon

Porto Alegre, Brasil

Março, 2025

## Ficha Catalográfica

P911p Prass, Paulo Ricardo

Previsão financeira com aprendizado profundo e inteligência artificial / Paulo Ricardo Prass. – 2025.

98.

Dissertação (Mestrado) – Programa de Pós-Graduação em Ciência da Computação, PUCRS.

Orientador: Prof. Dr. Cesar Augusto Missio Marcon.

1. Inteligência Artificial. 2. Redes Neurais. 3. Previsão de Ações. 4. Mercado Financeiro. 5. Aprendizado de Máquina. I. Marcon, Cesar Augusto Missio. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da PUCRS  
com os dados fornecidos pelo(a) autor(a).

Bibliotecária responsável: Clarissa Jesinska Selbach CRB-10/2051

**PAULO RICARDO PRASS**

**PREVISÃO FINANCEIRA COM APRENDIZADO PROFUNDO E  
INTELIGÊNCIA ARTIFICIAL**

Esta Dissertação de Mestrado foi apresentada em cumprimento parcial aos requisitos para obtenção do grau de mestre em Ciência da Computação, do Programa de Pós-Graduação em Ciência da Computação da Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul

Sancionado em março de 2025

**MEMBROS DO COMITÊ**

Prof. Dr. César Marcon (PPGCC/PUCRS – Orientador)

Prof. Dr. Fabiano Hessel (PPGCC/PUCRS)

Prof. Dr. Jarbas Silveira (PPGETI/UFC)

## **AGRADECIMENTOS**

Agradeço, com todo carinho, à minha mãe Ângela e ao meu padrasto Leonardo, assim como ao meu pai João e aos meus irmãos Bruno e Juliana, pelo amor, conselhos, apoio e incentivo constantes ao longo da minha trajetória.

Ao meu orientador, Prof. Dr. César Marcon, expresso minha profunda gratidão pelo apoio, paciência, confiança e valiosos ensinamentos durante o desenvolvimento deste trabalho.

À minha namorada Pâmela, agradeço pelo amor, companheirismo e encorajamento em todos os momentos.

Aos meus amigos, que sempre estiveram ao meu lado, ofereço meu sincero agradecimento pela amizade e apoio.

A todos os professores e professoras que, em algum momento, contribuíram para minha formação e crescimento intelectual, meu muito obrigado.

Ao Programa de Pós-Graduação em Ciência da Computação da Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul, agradeço pela oportunidade de desenvolver esta pesquisa em um ambiente de excelência acadêmica.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal Nível Superior – Brasil (CAPES) – Código de Financiamento 001

# Previsão Financeira com Aprendizado Profundo e Inteligência Artificial

## RESUMO

O presente trabalho utiliza como base os avanços da tecnologia, explorando um dos temas mais abordados na atualidade: a inteligência artificial. O objetivo é aplicar modelos de aprendizado de máquina, especificamente redes neurais recorrentes, para realizar previsões de preços de ações do mercado financeiro brasileiro, com dados do Ibovespa. Foram conduzidos testes e treinamentos com diferentes arquiteturas de redes neurais, buscando um modelo com maior precisão. Os dados foram coletados da API do Yahoo Finance e pré-processados para o treinamento. Após a implementação das arquiteturas, as previsões foram comparadas com os valores reais. Diversos testes foram realizados com variações em parâmetros como taxa de aprendizado, número de neurônios e outros hiperparâmetros, visando identificar melhorias no desempenho dos modelos. A análise dos resultados permitiu avaliar o impacto dessas modificações e ajustar a configuração para alcançar previsões mais precisas. Os resultados finais evidenciam ganhos de desempenho com a implementação de um modelo híbrido de rede neural, que combina diferentes arquiteturas para aperfeiçoar a capacidade preditiva e de generalização. O estudo reforça o potencial das redes neurais híbridas na solução de problemas computacionais complexos e contribui para a inovação no contexto financeiro e no campo da Ciência da Computação.

**Palavras-chave:** Inteligência Artificial, Redes Neurais, Previsão de Ações, Mercado Financeiro, Aprendizado de Máquina

# Financial Forecasting with Deep Learning and Artificial Intelligence

## ABSTRACT

This study is based on technological advancements and explores one of the most prominent current topics: artificial intelligence. The objective is to apply machine learning models, specifically recurrent neural networks, to forecast stock prices in the Brazilian financial market using Ibovespa data. Tests and training were conducted with different neural network architectures in search of a more accurate model. Data were collected from the Yahoo Finance API and preprocessed for model training. After implementing the architectures, the predictions were compared with actual values. Several tests were carried out by varying parameters such as learning rate, number of neurons, and other hyperparameters to identify performance improvements. The analysis of the results allowed the evaluation of the impact of these modifications and the adjustment of configurations to achieve more accurate forecasts. The final results highlight performance gains through the implementation of a hybrid neural network model, which combines different architectures to enhance predictive power and generalization. This study reinforces the potential of hybrid neural networks in solving complex computational problems and contributes to innovation in the financial context and the field of Computer Science.

**Keywords:** Artificial Intelligence, Neural Networks, Stock Price Prediction, Financial Market, Machine Learning

## LISTA DE ABREVIATURAS E SIGLAS

|               |   |
|---------------|---|
| <b>AELSTM</b> | <b>LSTM Neural Network with Automated Encoder</b> |
| <b>ABEV3</b>  | <b>Ações da empresa Ambev</b>                     |
| <b>AI</b>     | <b>Artificial Intelligence</b>                    |
| <b>ANN</b>    | <b>Artificial Neural Network</b>                  |
| <b>BOW</b>    | <b>Bag of Words</b>                               |
| <b>DL</b>     | <b>Deep Learning</b>                              |
| <b>DLNN</b>   | <b>Deep Learning Neural Network</b>               |
| <b>DNN</b>    | <b>Deep Neural Network</b>                        |
| <b>DRNN</b>   | <b>Deep Recurrent Neural Network</b>              |
| <b>FC</b>     | <b>Fully Connected</b>                            |
| <b>GRU</b>    | <b>Gated Recurrent Unit</b>                       |
| <b>LSTM</b>   | <b>Long Short-Term Memory</b>                     |
| <b>ML</b>     | <b>Machine Learning</b>                           |
| <b>MSE</b>    | <b>Mean Squared Error</b>                         |
| <b>OHLCV</b>  | <b>Open, High, Low, Close, Volume</b>             |
| <b>PCA</b>    | <b>Principal Component Analysis</b>               |
| <b>PL</b>     | <b>Preço/Lucro</b>                                |
| <b>PP</b>     | <b>Preço/Patrimônio</b>                           |
| <b>QENN</b>   | <b>Quantum Evolutionary Neural Network</b>        |
| <b>RMSE</b>   | <b>Root Mean Squared Error</b>                    |
| <b>RNN</b>    | <b>Recurrent Neural Network</b>                   |
| <b>SVM</b>    | <b>Support Vector Machines</b>                    |
| <b>TF-IDF</b> | <b>Term Frequency-Inverse Document Frequency</b>  |

## LISTA DE FIGURAS

|   |    |
|---|----|
| FIGURA 1 – REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO (FONTE: [1]).                               | 21 |
| FIGURA 2 – EXEMPLIFICAÇÃO DE UMA REDE NEURAL DO TIPO FEED-FORWARD (FONTE: [1]).               | 22 |
| FIGURA 3–REPRESENTAÇÃO SIMPLIFICADA DE UMA RNN (FONTE: [1]).                                  | 24 |
| FIGURA 4 – EXEMPLIFICAÇÃO DA ARQUITETURA LSTM (FONTE: [15]).                                  | 24 |
| FIGURA 5 – FUNÇÕES TANH E SIGMOID (FONTE: [15]).  | 25 |
| FIGURA 6 – EXEMPLIFICAÇÃO DA ARQUITETURA GRU (FONTE: [15]).                                   | 27 |
| FIGURA 7 - REGRESSÃO LINEAR (FONTE: [15]).  | 28 |
| FIGURA 8 - COMPARATIVA REDE NEURAL COMPLETA E REDE NEURAL COM DROPOUT<br>(FONTE:[24]).        | 31 |
| FIGURA 9 - MODELO DE DEEP LEARNING (FONTE: [1]).  | 32 |
| FIGURA 10 - ARQUITETURA MODELO LSTM (FONTE: [6]).   | 35 |
| FIGURA 11 - GRÁFICO DAS PREDIÇÕES DE TODO PERÍODO, MODELO LSTM DEFAULT (FONTE:<br>AUTOR).     | 44 |
| FIGURA 12 - GRÁFICO DAS PREDIÇÕES DE 3 ANOS, MODELO LSTM DEFAULT (FONTE: AUTOR).              | 46 |
| FIGURA 13 - GRÁFICO DAS PREDIÇÕES DE 2 ANOS E 6 MESES, MODELO LSTM DEFAULT (FONTE:<br>AUTOR). | 48 |
| FIGURA 14 - GRÁFICO DAS PREDIÇÕES DE 2 ANOS, MODELO LSTM DEFAULT (FONTE: AUTOR).              | 50 |
| FIGURA 15 - GRÁFICO DAS PREDIÇÕES DE 1 ANO E 6 MESES, MODELO LSTM DEFAULT (FONTE:<br>AUTOR).  | 52 |
| FIGURA 16 - GRÁFICO DAS PREDIÇÕES DE 1 ANO, MODELO LSTM DEFAULT (FONTE: AUTOR).               | 54 |
| FIGURA 17 - GRÁFICO DAS PREDIÇÕES DOS ÚLTIMOS 6 MESES, MODELO LSTM DEFAULT (FONTE:<br>AUTOR). | 56 |
| FIGURA 18 - GRÁFICO DOS RESULTADOS DE RMSE, MODELO LSTM DEFAULT (FONTE: AUTOR).               | 57 |
| FIGURA 19 - GRÁFICO DAS PREDIÇÕES DE TODO PERÍODO, MODELO GRU DEFAULT (FONTE:<br>AUTOR).      | 59 |
| FIGURA 20 - GRÁFICO DAS PREDIÇÕES DE 3 ANOS, MODELO GRU DEFAULT (FONTE: AUTOR).               | 61 |
| FIGURA 21 - GRÁFICO DAS PREDIÇÕES DE 2 ANOS E 6 MESES, MODELO GRU DEFAULT (FONTE:<br>AUTOR).  | 62 |
| FIGURA 22 - GRÁFICO DAS PREDIÇÕES DE 2 ANOS, MODELO GRU DEFAULT (FONTE: AUTOR).               | 64 |
| FIGURA 23 – GRÁFICOS DAS PREDIÇÕES DE 1 ANO E 6 MESES, MODELO GRU DEFAULT (FONTE:<br>AUTOR).  | 65 |
| FIGURA 24 - GRÁFICO DAS PREDIÇÕES DE 1 ANO, MODELO GRU DEFAULT (FONTE: AUTOR).                | 67 |
| FIGURA 25 - GRÁFICO DAS PREDIÇÕES DE 6 MESES, MODELO GRU DEFAULT (FONTE: AUTOR).              | 69 |
| FIGURA 26 - GRÁFICO DOS RESULTADOS DE RMSE, MODELO GRU DEFAULT (FONTE: AUTOR).                | 70 |

|  |    |
|--|----|
| FIGURA 27 - GRÁFICO DAS PREDIÇÕES DE TODO PERÍODO, MODELO LSTM+GRU DEFAULT<br>(FONTE: AUTOR). .....                                  | 72 |
| FIGURA 28 - GRÁFICO DAS PREDIÇÕES DE 3 ANOS, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR).....  | 73 |
| FIGURA 29 - PREDIÇÕES DE 2 ANOS E 6 MESES, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR). .   | 75 |
| FIGURA 30 - GRÁFICO DAS PREDIÇÕES DE 2 ANOS, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR).....  | 77 |
| FIGURA 31 - PREDIÇÕES DE 1 ANO E 6 MESES, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR). ...  | 78 |
| FIGURA 32 - GRÁFICO DAS PREDIÇÕES DE 1 ANO, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR).....   | 80 |
| FIGURA 33 - GRÁFICO DAS PREDIÇÕES DE 6 MESES, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR).....   | 81 |
| FIGURA 34 - GRÁFICO DOS RESULTADOS DE RMSE, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR).....   | 83 |
| FIGURA 35 - RESULTADOS RMSE DOS MODELOS (A)LSTM, (B) GRU E (C) LSTM+GRU - TODOS<br>OS MODELOS COM DROPOUT DE 40% (FONTE: AUTOR)..... | 85 |
| FIGURA 36 - RESULTADOS RMSE DOS MODELOS (A)LSTM, (B) GRU E (C) LSTM+GRU - TODOS<br>OS MODELOS COM DROPOUT DE 60% (FONTE: AUTOR)..... | 87 |
| FIGURA 37 - RESULTADOS RMSE DOS MODELOS (A)LSTM, (B) GRU E (C) LSTM+GRU - TODOS<br>OS MODELOS COM 50 EPOCHS(FONTE: AUTOR).....       | 89 |
| FIGURA 38 - RESULTADOS RMSE DOS MODELOS (A)LSTM, (B) GRU E (C) LSTM+GRU - TODOS<br>OS MODELOS COM 200 EPOCH(FONTE: AUTOR).....       | 90 |
| FIGURA 39 - RESULTADOS RMSE DOS MODELOS (A)LSTM, (B) GRU E (C) LSTM+GRU - TODOS<br>OS MODELOS COM 20 NEURÔNIOS(FONTE: AUTOR).....    | 93 |
| FIGURA 40 - RESULTADOS RMSE DOS MODELOS (A)LSTM, (B) GRU E (C) LSTM+GRU - TODOS<br>OS MODELOS COM 80 NEURÔNIOS(FONTE: AUTOR).....    | 95 |

## LISTA DE TABELAS

|  |    |
|--|----|
| TABELA 1 - RESULTADOS EXPERIMENTAIS DO ESTUDO [3] (FONTE: [3]).....                        | 33 |
| TABELA 2 - TABELA COMPARATIVA TRABALHOS RELACIONADOS (FONTE: AUTOR).....                   | 40 |
| TABELA 3 - TABELA DE PARÂMETROS (FONTE: AUTOR).....  | 43 |
| TABELA 4 - RESULTADOS DE TODO PERÍODO, MODELO LSTM DEFAULT (FONTE: AUTOR). ....            | 45 |
| TABELA 5 - RESULTADOS DE 3 ANOS, MODELO LSTM DEFAULT (FONTE: AUTOR).....                   | 47 |
| TABELA 6 - RESULTADOS DE 2 ANOS E 6 MESES, MODELO LSTM DEFAULT (FONTE: AUTOR). ....        | 49 |
| TABELA 7 - RESULTADOS DE 2 ANOS, MODELO LSTM DEFAULT (FONTE: AUTOR).....                   | 51 |
| TABELA 8 - RESULTADOS DE 1 ANO E 6 MESES, MODELO LSTM DEFAULT (FONTE: AUTOR). ....         | 53 |
| TABELA 9 - RESULTADOS DE 1 ANO, MODELO LSTM DEFAULT (FONTE: AUTOR).....                    | 55 |
| TABELA 10 - RESULTADOS DOS ÚLTIMOS 6 MESES, MODELO LSTM DEFAULT (FONTE: AUTOR). ....       | 56 |
| TABELA 11 - RESULTADOS DE TODO PERÍODO, MODELO GRU DEFAULT (FONTE: AUTOR).....             | 60 |
| TABELA 12 - RESULTADOS DE 3 ANOS, MODELO GRU DEFAULT (FONTE: AUTOR). ....                  | 62 |
| TABELA 13 - RESULTADOS DE 2 ANOS E 6 MESES, MODELO GRU DEFAULT (FONTE: AUTOR). ....        | 63 |
| TABELA 14 - RESULTADOS DE 2 ANOS, MODELO GRU DEFAULT (FONTE: AUTOR). ....                  | 65 |
| TABELA 15 - RESULTADOS DE 1 ANO E 6 MESES, MODELO GRU DEFAULT (FONTE: AUTOR).....          | 66 |
| TABELA 16 - RESULTADOS DE 1 ANO, MODELO GRU DEFAULT (FONTE: AUTOR). ....                   | 68 |
| TABELA 17 - RESULTADOS DE 6 MESES, MODELO GRU DEFAULT (FONTE: AUTOR).....                  | 69 |
| TABELA 18 - RESULTADOS DE TODO PERÍODO, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR). ...        | 72 |
| TABELA 19 - RESULTADOS DE 3 ANOS, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR).....              | 74 |
| TABELA 20 - RESULTADOS DE 2 ANOS E 6 MESES, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR)..... | 75 |
| TABELA 21 - RESULTADOS DE 2 ANOS, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR).....              | 77 |
| TABELA 22 - RESULTADOS DE 1 ANO E 6 MESES, MODELO LSTM+GRU DEFAULT (FONTE:<br>AUTOR).....  | 79 |
| TABELA 23 - RESULTADOS DE 1 ANO, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR). ....              | 81 |
| TABELA 24 - RESULTADOS DE 6 MESES, MODELO LSTM+GRU DEFAULT (FONTE: AUTOR). ....            | 82 |
| TABELA 25 - MELHORES RESULTADOS DE RMSE (FONTE: AUTOR). ....                               | 96 |

## LISTA DE FÓRMULAS

|  |    |
|--|----|
| FÓRMULA 1 - ERRO QUADRÁTICO MÉDIO (FONTE: [15]). .....         | 28 |
| FÓRMULA 2 - RAIZ DO ERRO QUADRÁTICO MÉDIO (FONTE: [15]). ..... | 29 |

# SUMÁRIO

|          |  |           |
|----------|--|-----------|
| <b>1</b> | <b>INTRODUÇÃO</b>                                  | <b>14</b> |
| 1.1      | MOTIVAÇÃO  | 16        |
| 1.2      | OBJETIVOS  | 18        |
| 1.3      | ORGANIZAÇÃO DO ESTUDO                              | 18        |
| <b>2</b> | <b>FUNDAMENTAÇÃO TEÓRICA</b>                       | <b>20</b> |
| 2.1      | ARTIFICIAL INTELLIGENCE (AI)                       | 20        |
| 2.2      | ARTIFICIAL NEURAL NETWORK (ANN)                    | 21        |
| 2.3      | DEEP LEARNING NEURAL NETWORKS (DLNN)               | 22        |
| 2.4      | <i>RECURRENT NEURAL NETWORK</i> (RNN)              | 23        |
| 2.5      | LONG SHORT-TERM MEMORY (LSTM)                      | 24        |
| 2.6      | GATED RECURRENT UNIT (GRU)                         | 26        |
| 2.7      | MEAN SQUARED ERROR (MSE)                           | 27        |
| 2.8      | ROOT MEAN SQUARED ERROR (RMSE)                     | 29        |
| 2.9      | DROPOUT  | 30        |
| <b>3</b> | <b>TRABALHOS RELACIONADOS</b>                      | <b>32</b> |
| <b>4</b> | <b>ANÁLISE DOS RESULTADOS EXPERIMENTAIS</b>        | <b>41</b> |
| 4.1      | MODELO LSTM DEFAULT                                | 44        |
| 4.2      | MODELO GRU DEFAULT                                 | 58        |
| 4.3      | MODELO LSTM+GRU DEFAULT                            | 71        |
| <b>5</b> | <b>EXPERIMENTOS COM MUDANÇA DE HIPERPARÂMETROS</b> | <b>84</b> |
| 5.1      | DROPOUT  | 84        |
| 5.2      | EPOCH  | 87        |
| 5.3      | NEURÔNIOS  | 91        |
| <b>6</b> | <b>CONSIDERAÇÕES FINAIS</b>                        | <b>96</b> |
| <b>7</b> | <b>REFERÊNCIAS</b>                                 | <b>98</b> |

# 1 INTRODUÇÃO

O mercado financeiro mundial está em constante transformação, impulsionado por inovações tecnológicas, alterações e dinâmicas econômicas globais. No Brasil isso não é diferente, o volume financeiro médio diário do mercado à vista da B3 no primeiro semestre de 2023 foi de R\$ 21,5 bilhões por dia [26]. Mas o que ainda é pouco conhecido sobre o mercado financeiro é sua dinâmica e complexidade, levando a investimentos com riscos e muitas vezes em perdas financeiras.

A capacidade de tentar identificar movimentos futuros dos valores das ações é de suma importância para investidores, analistas e empresas. A busca por ferramentas mais precisas e eficazes para previsão de preços de ações tem levado ao uso crescente de técnicas avançadas de Inteligência Artificial, em inglês *Artificial Intelligence* (AI), com o Aprendizado de Máquina, em inglês *Machine Learning* (ML), e redes neurais. Essas abordagens inovadoras têm demonstrado um potencial para melhorar a precisão das previsões e auxiliar na tomada de decisões informadas no ambiente altamente competitivo dos mercados financeiros.

A volatilidade e a imprevisibilidade inerentes aos mercados tornam a previsão de valores de ações um desafio complexo. No entanto, com a crescente disponibilidade de dados históricos e em tempo real, os avanços significativos em algoritmos de ML, as ferramentas tradicionais estão sendo complementadas e, em alguns casos, substituídas por métodos mais sofisticados baseados em AI. Dentre esses métodos, as redes neurais têm se destacado como uma técnica poderosa para modelar padrões complexos e capturar relações não-lineares nos dados financeiros.

A AI é um campo da ciência da computação que se concentra no desenvolvimento de sistemas e algoritmos capazes de aprender por conta própria, se referindo a raciocínio, aprendizado, percepção, compreensão da linguagem natural e tomada de decisão. A AI tem desempenhado um papel fundamental na automação de tarefas que anteriormente exigiam intervenção humana, trazendo benefícios significativos para diversos setores. Este processo consiste na capacidade das máquinas têm de interpretar dados externos, aprender e resolver tarefas específicas para atingir objetivos determinados [17].

A AI demanda que as máquinas executem tarefas complexas, simulando a inteligência humana e tomando decisões de forma autônoma. Para que isso seja possível, em muitos casos, há uma combinação de tecnologias, como ML e aprendizado profundo, conhecido também como *deep learning* em inglês [17].

O aprendizado profundo engloba algoritmos eficientes para um aprendizado autônomo, também é uma subárea da ML que se concentra no treinamento de uma Rede Neural Artificial, em inglês *Artificial Neural Network* (ANN), com múltiplas camadas para aprender representações de dados complexos, utilizando aprendizagem supervisionada ou semi-supervisionada com modelos de abstração de alto nível.

Uma ANN é composta por camadas de nodos, contendo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada nodo, ou neurônio artificial, se conecta a outro nodo e tem peso e limite associados. Se a saída de qualquer nodo individual estiver acima do valor do limite especificado, esse nodo é ativado, enviando dados para a próxima camada da rede. Caso contrário, nenhum dado é transmitido junto à próxima camada da rede [21].

O aprendizado profundo é um método de AI que ensina computadores a processar dados de uma forma inspirada pelo cérebro humano. Os modelos de aprendizado profundo conseguem reconhecer padrões complexos em imagens, texto, sons e outros dados para produzir insights e previsões precisas. É possível usar métodos de aprendizado profundo para automatizar tarefas que normalmente exigem inteligência humana, como descrever imagens ou transcrever um arquivo de som em texto [18].

Utilizando o framework TensorFlow, reconhecido por sua capacidade de lidar eficientemente com grandes volumes de dados e treinar modelos complexos de redes neurais, este estudo propõe a implementação e avaliação de diferentes arquiteturas de redes neurais, incluindo modelos baseados em Memória de Longo Prazo, em inglês *Long Short-Term Memory* (LSTM), e outros métodos de aprendizado profundo. Além disso, este trabalho enfatiza a importância da linguagem de programação Python, juntamente com a biblioteca TensorFlow, para facilitar o processo de treinamento e validação de modelos de redes neurais. A flexibilidade da combinação deste conjunto permite a exploração de diferentes abordagens de

pré-processamento de dados, algoritmos de treinamento e otimização, como também a exploração de variação entre parâmetros que alterados no modelo podem aumentar a precisão das previsões, contribuindo para o aprimoramento do desempenho preditivo dos modelos.

Por fim, esperamos que os resultados deste estudo não apenas forneçam *insights* valiosos para a comunidade acadêmica e profissional no campo da previsão financeira, mas também sirva como base para o desenvolvimento de futuros softwares e ferramentas de apoio à decisão, especialmente direcionados a investidores que buscam orientação de encontrar uma possível direção de preço no complexo mundo dos mercados financeiros.

## 1.1 Motivação

A motivação central desta dissertação é abordar as possíveis dificuldades em se trabalhar com o mercado de ações devido à sua volatilidade e complexidade, tornando a previsão de valores de ações um desafio constante. Assim, neste estudo, apresentaremos um desenvolvimento de um método capaz de fornecer previsões mais precisas e confiáveis, permitindo que investidores e tomadores de decisões melhorem suas estratégias e resultados financeiros.

As redes neurais recorrentes se tornaram uma das principais ferramentas para a previsão de séries temporais financeiras, isso se deve à capacidade da técnica de aprender características de capacidade de muitas camadas ocultas e memorizar esses padrões para usar no futuro [6].

O avanço da tecnologia e a disponibilidade de grandes conjuntos de dados históricos e em tempo real oferecem uma oportunidade única para explorar as redes neurais. A motivação reside em aproveitar esses avanços para identificar padrões sutis e complexos nos dados financeiros, melhorando assim a qualidade das previsões.

As redes neurais têm demonstrado sucesso em várias áreas, incluindo processamento de linguagem natural e visão computacional. A motivação aqui é aplicar essa capacidade de aprendizado profundo para capturar as nuances dos dados de mercado de ações, permitindo que o modelo compreenda e responda a padrões não-lineares e informações implícitas nos dados.

Os modelos serão submetidos a diferentes testes e alterações de parâmetros específicos da rede neural, da forma com que ela receba as informações durante os treinamentos, estes testes serão comparados e insights serão identificados nos resultados com o intuito do encontro de previsões mais precisas.

Uma previsão precisa de valores de ações auxilia os investidores swing trade a tomar decisões mais informadas e estratégicas. No *swing trade*, o *trader* mantém a ação por um período que pode variar de um dia a algumas semanas. Isso ocorre porque as mudanças no núcleo corporativo geralmente levam tempo para impactar significativamente os preços. Dessa forma, o investidor aguarda a evolução da negociação até que a valorização esperada se concretize [27]. A motivação deste trabalho é fornecer aos investidores e analistas ferramentas que permitam avaliar riscos e oportunidades de forma mais precisa, reduzindo incertezas e aumentando a confiança nas decisões financeiras.

Ao comparar a previsão baseada em redes neurais com a análise fundamentalista, que utiliza indicadores como Preço/Patrimônio (PP) e Preço/Lucro (PL). Esses indicadores são amplamente empregados para determinar se uma ação está subvalorizada ou supervalorizada, ao comparar seu preço de mercado com os fundamentos da empresa. No contexto deste estudo, a previsão de preços é vista como um complemento à análise fundamentalista, uma vez que os modelos de aprendizado de máquina mostram em números o potencial da operação, além disso, os modelos também utilizam PP e PL como variáveis de entrada. Essas métricas influenciam os pesos atribuídos aos neurônios da rede neural, ajudando a aprimorar a capacidade do investidor de identificar pontos estratégicos para compra e venda de ativos, proporcionando uma visão mais completa do ativo analisado.

Em síntese, as motivações deste trabalho giram em torno da busca por previsões mais precisas e confiáveis dos valores de ações, aproveitando os avanços em tecnologia, aprendizado de máquina e redes neurais. Além de contribuir para o campo da pesquisa financeira, esse estudo tem o potencial de impactar diretamente as estratégias de investimento e tomada de decisões no mercado de ações.

## 1.2 Objetivos

Este trabalho visa explorar e avaliar o potencial das redes neurais, em particular as arquiteturas LSTM e Unidade Recorrente Fechada, em inglês *Gated Recurrent Unit* (GRU), em previsões de valores futuros de ações. Ao utilizar a capacidade de aprendizado profundo das redes neurais, esperamos identificar padrões sutis nos dados que podem não ser facilmente percebidos por métodos tradicionais. Como também desenvolver, testar com diferentes parâmetros, avaliar e comparar os resultados de previsão de valores de ações utilizando técnicas avançadas de redes neurais, visando melhorar a precisão das previsões e fornecer *insights* valiosos para investidores e tomadores de decisão no mercado financeiro.

Durante o desenvolvimento do trabalho, será implementado um modelo híbrido que combina as vantagens das redes neurais LSTM e GRU. Esse modelo será avaliado e comparado em termos de desempenho, considerando diferentes ajustes nos parâmetros. O objetivo é explorar os benefícios e limitações de cada modificação, buscando aperfeiçoar a precisão e a eficiência das previsões.

O trabalho também busca contribuir para o campo da previsão de valores de ações ao explorar o potencial das redes neurais. Ao avançar no entendimento das capacidades dessas técnicas, esperamos aprimorar a tomada de decisões financeiras e fornecer uma visão mais clara sobre a viabilidade e eficácia dessas abordagens inovadoras em um ambiente tão desafiador e em constante evolução quanto o mercado de ações.

## 1.3 Organização do Estudo

Este trabalho está estruturado de forma a proporcionar uma compreensão clara e progressiva sobre o tema abordado, como segue:

- **Capítulo 2 - Fundamentação Teórica:** Apresenta os conceitos e princípios fundamentais necessários para compreender o estudo, abordando a problemática subjacente e explorando diferentes abordagens para a predição de valores no mercado financeiro. Além disso, contextualiza o tema e destaca aspectos relevantes para o desenvolvimento da pesquisa.
- **Capítulo 3 - Trabalhos Relacionados:** Revisa estudos e pesquisas que serviram como base para este trabalho, analisando e comparando

metodologias e resultados obtidos em abordagens anteriores envolvendo inteligência artificial e aprendizado profundo aplicados ao mercado financeiro.

- **Capítulo 4 - Análise dos Resultados Experimentais:** Apresenta os experimentos conduzidos com modelos preditivos, explorando o desempenho do modelo LSTM, GRU e uma combinação de ambos. São analisadas métricas de precisão e eficiência, permitindo avaliar a adequação das abordagens propostas.
- **Capítulo 5 - Experimentos com Mudança de Hiperparâmetros:** Explora variações nos modelos preditivos por meio da alteração de hiperparâmetros, como dropout, número de épocas (epochs) e quantidade de neurônios, investigando seu impacto na qualidade das previsões.
- **Capítulo 6 - Considerações Finais:** Resume as principais comparações do estudo, destacando os melhores desempenhos bem como os modelos que mais tiveram melhoras com as mudanças de hiperparâmetros.

Essa organização visa garantir uma leitura clara e estruturada, proporcionando um fluxo lógico desde a fundamentação teórica até a apresentação dos experimentos e referências utilizadas.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Artificial Intelligence (AI)

O termo AI se refere à capacidade de uma máquina imitar funções cognitivas humanas, como aprendizado, resolução de problemas e adaptação a novas situações. No contexto da predição de valores, a AI oferece uma abordagem revolucionária, transcendendo métodos tradicionais ao capacitar sistemas computacionais a discernir padrões sutis e aprimorar suas previsões ao longo do tempo.

Na concepção de muitas pessoas aAI surgiu no século 20, onde Alan Turing participou na montagem de máquinas físicas que permitiam a quebra de códigos secretos nazistas, conhecida como Enigma. Ele também desenvolveu a Máquina de Turing que seria um modelo abstrato de um computador, para ser mais preciso a máquina era programável através de fitas para a criação de seus algoritmos. Desde então, a AI emerge como uma força transformadora, graças à alta capacidade de processamento dos computadores atuais, delineando um horizonte tecnológico onde máquinas não apenas processam informações, mas também aprendem, raciocinam e, surpreendentemente, conseguem prever eventos futuros.

AI é uma tecnologia computacional ou um conjunto de tecnologias, algoritmos e sistemas de aprendizado cujo objetivo é imitar capacidades mentais humanas, tais como: raciocínio, percepção de ambiente e capacidade de tomada de decisão. A tecnologia é desenvolvida com o intuito de que máquinas possam resolver uma série de problemas, indo da grande complexidade da indústria ao corriqueiro cotidiano do homem moderno. Para isso, ela busca aprender com eles graças a uma sofisticada tecnologia de aprendizado, permitindo que a AI aprenda com um grande conjunto de dados e atue por conta própria [23].

No avanço da AI estão a capacidade das redes neurais recorrentes, em particular, as LSTMs e as GRUs, de desvendar padrões complexos em conjuntos de dados temporais.

As redes neurais recorrentes, especificamente LSTM e GRU, se destacam como arquiteturas avançadas capazes de lidar efetivamente com dados sequenciais. Enquanto as LSTMs incorporam mecanismos de memória de longo

prazo para capturar relações temporais, as GRUs simplificam esse processo, mantendo uma alta eficiência computacional. Ambas as abordagens oferecem uma janela para a compreensão de aprendizagem profunda de séries temporais, permitindo a modelagem de padrões não lineares e o aprimoramento da precisão nas previsões.

## 2.2 Artificial Neural Network (ANN)

Uma ANN, mais conhecida simplesmente como Rede Neural, é a representação de uma rede de neurônios do cérebro, onde um neurônio artificial é modelado para funcionar como um neurônio biológico.

A Figura 1 representa um neurônio no cérebro humano, consistindo principalmente de três componentes principais: Dendrito (Dentrite), Núcleo (Nucleus) e Axônio (Axon). As sinapses (Synapses) presentes no dendrito atuam como entrada para um neurônio. O sinal elétrico é então processado pelo núcleo e o resultado é enviado através do axônio para outro neurônio, perfazendo uma rede neural.

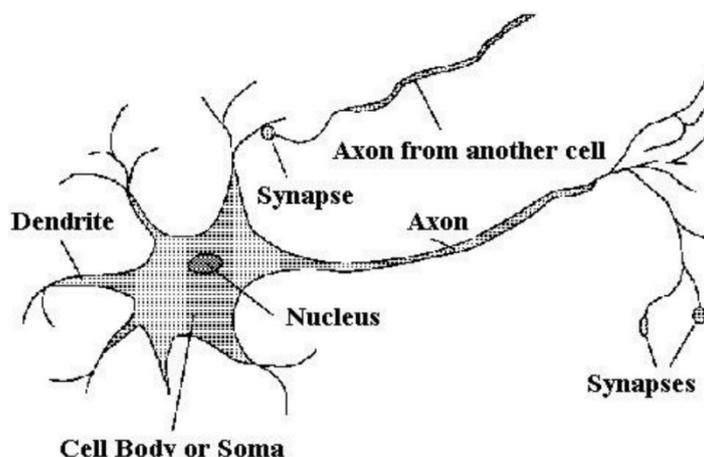


Figura 1 – Representação de um neurônio biológico (Fonte: [1]).

As redes neurais vêm sendo muito utilizadas no meio acadêmico e uma das arquiteturas de redes neural bastante usada é chamada de “feed-forward”, ou totalmente conectada, ilustrada pela Figura 2. Esta rede possui uma camada de entrada chamada de “input layer” que é responsável pela entrada dos dados e distribuição para os demais nodos. Adicionalmente, é possível ter novas camadas de nodos conectadas a camada de entrada, estas camadas ocultas são chamadas de “hidden layers”, onde os dados são memorizados e processados; após isso os

valores são enviados para uma camada de saída também chamada de “output layer”. Este processamento combinado com memória ajuda na previsão de séries temporais, sendo assim, uma boa opção para trabalhar com previsões financeiras de ações.

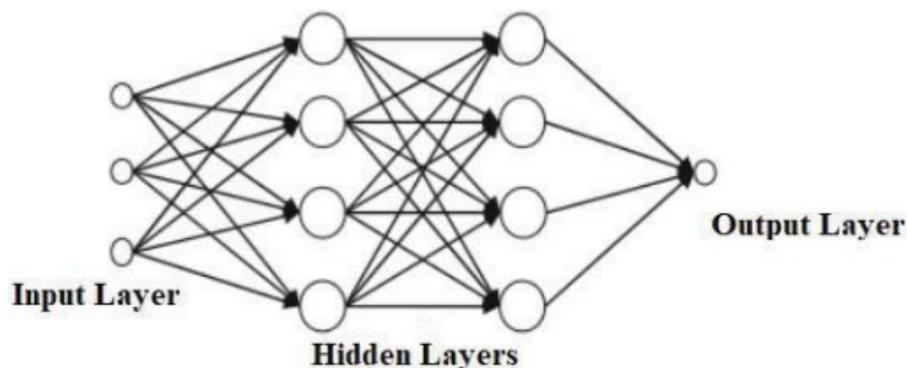


Figura 2 – Exemplificação de uma rede neural do tipo feed-forward (Fonte: [1]).

Um neurônio pode ser conectado a todos ou a um subconjunto dos neurônios na camada subsequente, com essas conexões simulando as sinapses do cérebro. Os sinais de dados ponderados que entram em um neurônio simulam a excitação elétrica de uma célula nervosa e, conseqüentemente, a transferência de informações dentro da rede ou do cérebro. Os valores de entrada para um elemento de processamento são multiplicados por um peso de conexão que simula o fortalecimento das vias neurais no cérebro. É através do ajuste das forças, ou pesos de conexão, que o aprendizado é emulado nas redes neurais artificiais.

As redes neurais são fundamentais no campo de ML, pois é possível avançar nas complexidades dos dados e desafios computacionais, daí que surgem conceitos cruciais como rede neural de aprendizado profundo, em inglês *Deep Learning Neural Network* (DLNN), Rede Neural Recorrente, em inglês *Recurrent Neural Network* (RNN) e suas variantes, como GRU e LSTM, desencadeando uma revolução na capacidade das máquinas de compreender e processar informações.

### 2.3 Deep Learning Neural Networks (DLNN)

No cerne do aprendizado profundo, encontramos as DLNNs, estruturas capazes de aprender representações hierárquicas e complexas dos dados. Assim como as redes neurais tradicionais, elas também são inspiradas no funcionamento do cérebro humano; essas redes consistem em camadas de neurônios interconectados, cada camada contribuindo para a extração de características

específicas.

À medida que a informação atravessa essas camadas, o modelo refinado emerge, capacitando as redes neurais profundas a discernir padrões complexos e realizar tarefas difíceis, como reconhecimento de imagem, processamento de linguagem natural e previsão de séries temporais.

As redes neurais profundas têm várias camadas ocultas, com milhões de neurônios artificiais interligados. Um número, conhecido como peso, representa as conexões entre dois nodos. O peso é um número positivo se um nodo excitar o outro, ou negativo se um nodo reprimir o outro. Nodos com valores de peso maiores têm mais influência nos demais. Teoricamente, as redes neurais profundas podem direcionar qualquer tipo de entrada para qualquer tipo de saída. Porém, elas precisam de muito mais treinamento do que outros métodos de ML; em geral, milhões de dados de treinamento, enquanto redes simples precisam de apenas centenas ou milhares [19].

## **2.4 Recurrent Neural Network (RNN)**

As RNNs representam um avanço significativo na capacidade de processar dados sequenciais. Ao contrário das redes neurais tradicionais, a Figura 3 mostra que as RNNs possuem conexões retroativas, permitindo que a informação seja armazenada e utilizada em etapas subsequentes. Esse design é crucial para tarefas que envolvem dependências temporais, como tradução automática e previsão de séries temporais.

Uma RNN é um modelo de aprendizado profundo treinado para processar e converter uma entrada de dados sequencial em uma saída de dados sequencial específica. Dados sequenciais são palavras, frases ou dados de séries temporais, em que componentes sequenciais se inter-relacionam com base em regras complexas de semântica e sintaxe. Uma RNN é um sistema de software que consiste em muitos componentes interconectados que imitam a forma como os humanos realizam conversões sequenciais de dados, como a tradução de texto de um idioma para outro.

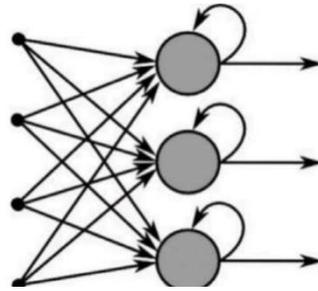


Figura 3–Representação simplificada de uma RNN (Fonte: [1]).

As RNNs estão sendo amplamente substituídas por AI baseada em transformadores e modelos de linguagem, que são muito mais eficientes no processamento sequencial de dados [20]. Adicionalmente, as RNNs tradicionais enfrentam desafios na retenção de informações de longo prazo, dando origem a evoluções como as arquiteturas LSTM e GRU.

## 2.5 Long Short-TermMemory (LSTM)

Uma LSTM representa uma resposta elegante para o desafio da “memória de curto prazo” em RNNs. Essa arquitetura incorpora unidades de memória especializadas, permitindo que informações relevantes sejam mantidas por períodos prolongados. Isso é especialmente valioso em contextos onde a compreensão de dependências temporais de longo alcance é crucial, como na análise de séries temporais financeiras ou na previsão climática.

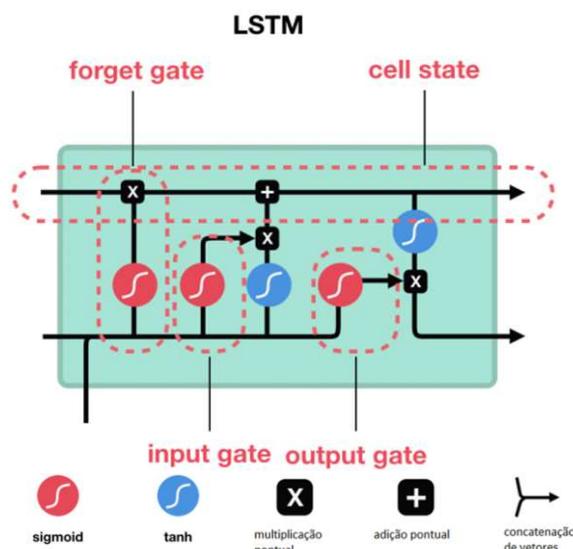
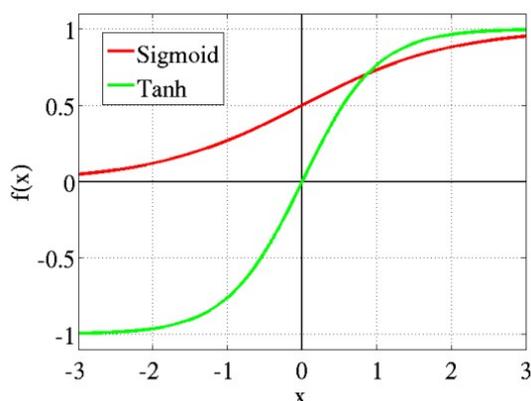


Figura 4 – Exemplificação da arquitetura LSTM (Fonte: [15]).

Em uma RNN, os vetores da sequência são processados um a um. Em uma rede LSTM, tal como ilustrado na Figura 4, o “input gate” e o “output gate” estão

ligados por um “forget gate” fazendo que o estado oculto anterior seja passado para a próxima etapa da sequência. Esse estado oculto funciona como a memória da rede neural, retendo informações sobre os dados anteriores que a rede recebeu.

Para regular a saída da rede neural, uma função tangente hiperbólica (tanh) é aplicada, garantindo que os valores permaneçam entre -1 e 1, como ilustra a Figura 5.



**Figura 5 – Funções Tahn e Sigmoid (Fonte: [15]).**

O “forget gate” é responsável por decidir quais informações devem ser descartadas ou mantidas; as informações do estado oculto anterior e as informações da entrada atual passam por uma função sigmoide, resultando em valores entre 0 e 1. Isso é útil para atualizar ou esquecer os dados, pois qualquer número multiplicado por 0 resulta em 0, fazendo com que os valores sejam “esquecidos”. Por sua vez, qualquer número multiplicado por 1 permanece igual, permitindo que esses valores sejam “mantidos”. A rede pode, então, aprender quais dados não são importantes e devem ser esquecidos, e quais são importantes e devem ser mantidos.

O “input gate” é encarregado de atualizar o “cell state”. Primeiramente, o estado oculto anterior é combinado com a entrada atual e passado por uma função sigmoide, determinando quais valores serão atualizados. O “cell state” é calculado multiplicando o “forget gate” pelo “cell state” anterior, permitindo descartar valores na “cell state” se forem multiplicados por valores próximos de 0. Em seguida, a saída do “input gate” realiza uma adição pontual, atualizando a “cell state” com novos valores considerados relevantes pela rede neural.

O “output gate” determina o próximo estado oculto, que contém informações sobre entradas anteriores e é utilizado para previsões. Primeiramente, o estado

oculto anterior e a entrada atual passam por uma função sigmoide. Em seguida, a “cell state” recém modificada é submetida à função tanh, cujo resultado é multiplicado pela saída da função sigmoide para determinar quais informações o estado oculto deve transportar. A saída final é o novo estado oculto, enquanto a nova “cell state” e o novo estado oculto são transferidos para a próxima etapa de tempo.

## 2.6 Gated Recurrent Unit (GRU)

As GRUs surgem como uma alternativa eficiente às LSTMs, simplificando a arquitetura sem comprometer a capacidade de modelagem temporal. Introduzindo *gates* para controlar o fluxo de informações, as GRUs conseguem capturar dependências temporais significativas, mantendo uma eficiência computacional. Esse equilíbrio entre desempenho e simplicidade torna as GRUs uma escolha atraente em diversas aplicações de ML.

A estrutura da GRU é projetada para capturar adaptativamente as dependências em grandes sequências de dados sem perder informações de partes anteriores da sequência. Seus *gates* são treinados para filtrar informações consideradas desnecessárias, retendo apenas o que é útil para o aprimoramento do modelo. Esses *gates* são representados como vetores com valores variando entre 0 e 1. Se um dos valores desses vetores for 0, tanto na entrada quanto no estado oculto anterior, a informação correspondente será descartada. Por outro lado, se o valor for 1, os dados correspondentes são considerados importantes e serão utilizados.

A Figura 6 ilustra os *gates* que regulam o fluxo de informações da arquitetura GRU. A rede neural processa os vetores da sequência um por um, passando o estado oculto anterior para a próxima etapa da sequência. Esse estado oculto funciona como a memória da rede, contendo informações sobre dados anteriores que foram preservados.

Similarmente à LSTM, a GRU utiliza a função tanh para garantir que os valores permaneçam entre -1 e 1, e a função de ativação sigmoide para garantir que os valores estejam no intervalo de 0 a 1. Essas funções são cruciais para atualizar, esquecer ou manter informações importantes. O “*update gate*” decide quais

informações devem ser descartadas e quais novas informações devem ser adicionadas, enquanto o “reset gate” é usado para determinar quanto da informação anterior deve ser esquecida.

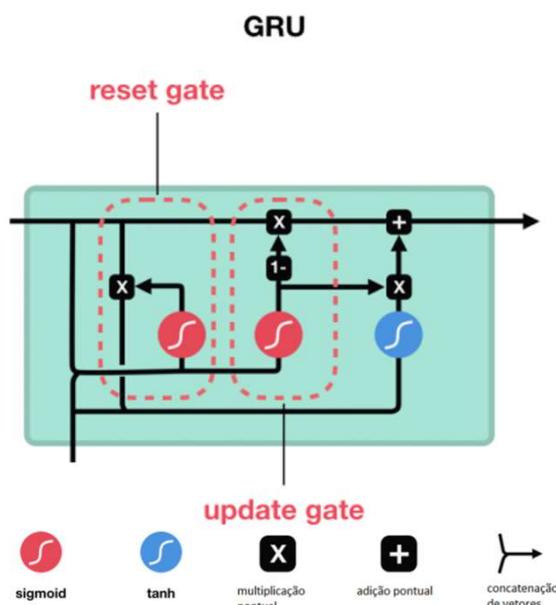


Figura 6 – Exemplificação da arquitetura GRU (Fonte: [15]).

As arquiteturas LSTM e GRU ajudam no contexto onde as máquinas não apenas processam dados, mas também compreendem dados temporais e padrões complexos. As camadas das redes neurais não apenas realizam um processamento tecnológico, mas também ajudam na busca pela criação de sistemas mais inteligentes e adaptáveis, que desempenham um papel vital em inúmeras aplicações práticas e na compreensão aprofundada de dados complexos.

## 2.7 Mean Squared Error (MSE)

O erro quadrático médio, conhecido pela sigla MSE (do inglês Mean Squared Error), é uma das métricas mais utilizadas para avaliar o desempenho de modelos de regressão. Ele mede a proximidade entre os valores previstos pelo modelo e os valores reais, isso permite quantificar a precisão da predição. O MSE é calculado considerando a diferença entre os valores reais e os valores previstos, elevando essa diferença ao quadrado e, em seguida, obtendo a média desses valores ao longo de todas as observações. Esse processo garante que os erros negativos não cancelem os positivos, proporcionando uma medida sempre positiva da magnitude do erro.

A quadratura dos erros torna a métrica mais sensível a valores discrepantes (outliers), pois erros maiores terão um impacto desproporcionalmente alto no valor final do MSE. Assim, quanto menor o erro quadrático médio, melhor será o ajuste do modelo aos dados, indicando previsões mais precisas. No entanto, devido a essa sensibilidade, o MSE pode ser influenciado por valores extremos no conjunto de dados, o que deve ser considerado ao analisar os resultados.

A unidade do MSE está ao quadrado da unidade dos valores que estão sendo preditos, o que pode dificultar a interpretação direta dos resultados. Por esse motivo, em muitas aplicações, utiliza-se a raiz quadrada do MSE, conhecida como Root Mean Squared Error (RMSE), que mantém a unidade original dos dados e facilita a análise do erro em termos mais intuitivos.

A Figura 7 apresenta um exemplo gráfico de uma regressão linear, ilustrando como o erro é representado pela diferença entre os valores observados e os valores ajustados pela linha de regressão. Essa visualização ajuda a compreender como as discrepâncias individuais contribuem para o cálculo do MSE. A fórmula do MSE é representada pela Fórmula 1.

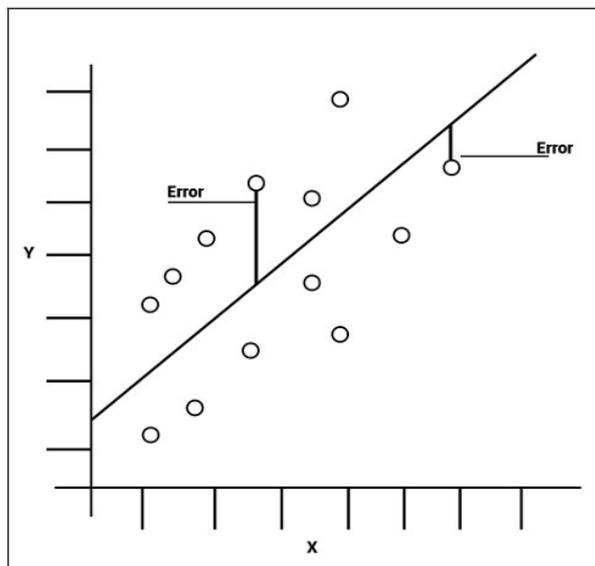


Figura 7 - Regressão linear (Fonte: [15]).

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Fórmula 1 - Erro quadrático médio (Fonte: [15]).

Onde “n” representa o número de registros, “ $\Sigma$ ” representa notação de soma, “Y”, representa o valor observado e “ $\hat{Y}$ ” representa o valor da regressão.

O erro quadrático médio é amplamente utilizado em diversos tipos de problemas de regressão, sendo especialmente útil quando há a necessidade de penalizar erros maiores de forma mais significativa. Por ser uma métrica que mede a dispersão dos erros, sua aplicação é essencial para comparar diferentes modelos e identificar aquele que melhor se ajusta ao conjunto de dados analisado.

## 2.8 Root Mean Squared Error(RMSE)

O Root Mean Squared Error (RMSE) é uma métrica amplamente utilizada para avaliar e comparar o desempenho de diferentes modelos preditivos. Sua principal característica é penalizar erros maiores com mais intensidade, pois eleva ao quadrado as diferenças entre os valores previstos e os valores reais antes de calcular a média e extrair a raiz quadrada. Quanto menor o valor do RMSE, melhor é o desempenho do modelo, pois indica que as previsões estão mais próximas dos valores reais.

Após todas as etapas de treinamento, teste e validação dos modelos, ou seja, após a conclusão de todo o processo de aprendizado supervisionado, o RMSE é calculado com base no Mean Squared Error (MSE) de cada modelo. O RMSE é simplesmente a raiz quadrada do MSE, permitindo que o erro retorne à mesma unidade de medida do problema em questão, tornando sua interpretação mais intuitiva. A Fórmula 2 apresenta o cálculo do RMSE.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$$

**Fórmula 2 - Raiz do erro quadrático médio (Fonte: [15]).**

Onde “n” representa o número de registros, “ $\Sigma$ ” representa notação de soma, “Y” representa o valor observado e “ $\hat{Y}$ ” representa o valor da regressão.

Uma característica importante do RMSE é que os erros individuais são elevados ao quadrado antes de calcular a média, o que amplifica a influência de erros maiores. Isso significa que valores de erro elevados terão um impacto desproporcional no cálculo final do RMSE, tornando a métrica particularmente sensível a outliers – valores extremos que diferem significativamente da maioria dos

dados.

Se houver outliers no conjunto de dados, esses pontos terão um peso maior no cálculo do RMSE, podendo inflacionar significativamente o valor da métrica e, conseqüentemente, prejudicar a avaliação do modelo. Portanto, é essencial realizar uma análise exploratória dos dados antes de treinar os modelos, a fim de identificar e tratar possíveis outliers, garantindo que a avaliação do desempenho do modelo seja mais precisa e representativa.

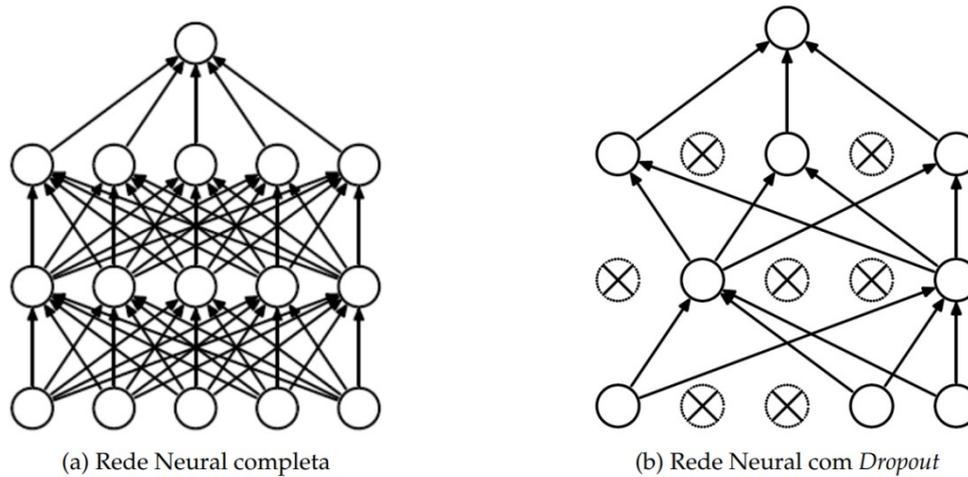
A Raiz Quadrada do Erro Quadrático Médio, ou simplesmente RMSE em inglês, é uma excelente métrica para modelos de regressão, além de ser muito fácil de interpretar. Nada mais é que a diferença entre o valor que foi previsto pelo seu modelo e o valor real que foi observado, por exemplo, imagine que você está construindo um modelo para prever preço de casas. Esse modelo deveria ter previsto o valor de R\$ 100 mil para um exemplo no seu conjunto, mas ele previu R\$ 99 mil: esse -R\$ 1 mil de diferença é o erro do seu modelo. Agora é só repetir esse processo para todo seu conjunto de treino ou teste, elevar o erro ao quadrado, tirar a média de todos os valores do conjunto e, por fim, calcular a raiz quadrada [28].

O RMSE é uma métrica poderosa e amplamente utilizada para avaliar modelos preditivos, especialmente aqueles baseados em aprendizado de máquina. Além de ser fácil de interpretar, ela quantifica a diferença entre os valores previstos pelo modelo e os valores reais observados. Neste trabalho, o RMSE será utilizado como principal métrica para avaliar o desempenho dos modelos, permitindo a comparação entre os valores previstos e os valores reais. Sua capacidade de fornecer uma medida intuitiva do erro médio, mantendo a unidade original dos dados, torna-o uma escolha adequada para analisar a precisão das predições.

## 2.9 Dropout

O dropout pode ser aplicado em qualquer uma ou em todas as camadas ocultas da rede e é interpretado como uma forma de regularizar a rede neural, adicionando ruído às suas unidades ocultas [24].

No dropout é introduzido um novo hiperparâmetro que especifica a probabilidade de eliminação das saídas da camada ou, inversamente, a probabilidade de retenção das saídas da camada.



**Figura 8 - Comparativa Rede Neural completa e Rede Neural com Dropout (Fonte:[24]).**

Dropout é um método de regularização que remove aleatoriamente neurônios da rede neural durante o treinamento para evitar coadaptação entre neurônios vizinhos [24]. É possível observar na Figura 8 como é feita a remoção aleatória de neurônios durante o treinamento, comparado com a rede neural completa.

### 3 TRABALHOS RELACIONADOS

Este capítulo revisa a literatura e os estudos existentes que contribuem para a compreensão da análise de sentimentos nos mercados financeiros, um campo que investiga as emoções, opiniões e percepções dos investidores a partir de fontes como notícias, redes sociais e relatórios financeiros. Além disso, discute o impacto das divulgações corporativas nas oscilações do mercado de ações.

Vários estudos exploraram a análise de sentimento no contexto dos mercados financeiros, com o objetivo de compreender o papel do sentimento do investidor na formação da dinâmica do mercado. Por exemplo, [1] realizaram uma análise aprofundada do sentimento extraído de notícias financeiras e redes sociais, demonstrando a sua influência nos preços das ações.

Os autores criaram um modelo de aprendizado profundo que combina técnicas de redução de dimensionalidade (PCA - Principal Component Analysis) com redes neurais profundas (DNN- Deep Neural Network) para prever o preço de fechamento das ações com base em dados históricos do mercado financeiro, o modelo pode ser observado na Figura 9 abaixo.

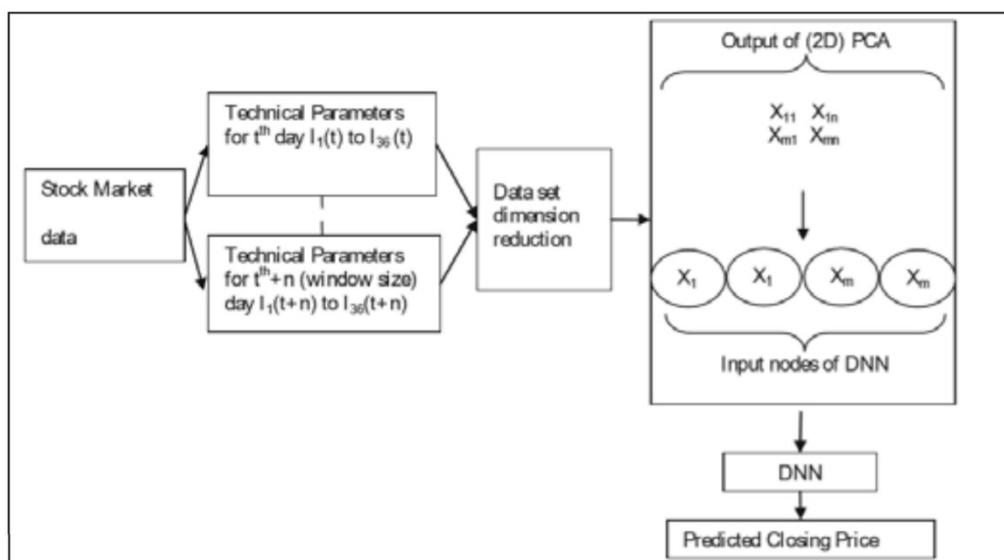


Figura 9 - Modelo de Deep Learning (Fonte: [1]).

O processo começa com a entrada de dados do mercado financeiro, especificamente parâmetros técnicos extraídos dos preços das ações em diferentes períodos. Esses parâmetros incluem informações sobre um único dia, representadas como "Technical Parameters for t<sup>th</sup> day", e informações sobre uma

janela de dias consecutivos, indicadas como "Technical Parameters for  $t^{\text{th}}$  n (window size) day". Esses parâmetros podem incluir métricas como preço de abertura, fechamento, volume negociado e outros indicadores financeiros relevantes.

Após a coleta dos dados, ocorre uma etapa de redução de dimensionalidade, que visa minimizar a complexidade do conjunto de dados sem perder informações relevantes. Para isso, o modelo utiliza a técnica de Análise de Componentes Principais (PCA - Principal Component Analysis), especificamente uma versão bidimensional denominada "(2D) PCA". Essa técnica permite transformar os dados originais em um conjunto reduzido de variáveis derivadas, preservando a máxima variabilidade possível e eliminando redundâncias.

Os dados transformados pela PCA são então utilizados como entrada para um modelo de Deep Neural Network (DNN). As saídas da PCA são representadas no diagrama como um conjunto de nós de entrada do DNN ("Input nodes of DNN"), que correspondem às variáveis reduzidas derivadas da análise de componentes principais.

Por fim, os dados processados pela rede neural passam por diferentes camadas de aprendizado profundo, e o modelo gera uma previsão do preço de fechamento das ações ("Predicted Closing Price"). Esse resultado pode ser utilizado para auxiliar na tomada de decisões financeiras, como estratégias de investimento e negociações no mercado de ações.

Da mesma forma, [3] utilizaram modelos de ML para prever tendências do mercado de ações com base no sentimento extraído de diversas fontes textuais realizando diferentes experimentos alterando os parâmetros da rede neural dos modelos, abaixo na Tabela 1 é possível observar a os experimentos realizados no estudo.

Experimental results.

| Neural Networks                 | BSE     | NASDAQ  | HSI     | SSE     | Russell 2000 | TAIEX   |
|---------------------------------|---------|---------|---------|---------|--------------|---------|
| 3-layer ENN, 10 hidden neurons  | 0.42828 | 0.52346 | 0.4312  | 0.4357  | 0.32455      | 0.32319 |
| 3-layer ENN, 20 hidden neurons  | 0.46543 | 0.57674 | 0.37841 | 0.45441 | 0.33697      | 0.44116 |
| 3-layer ENN, 40 hidden neurons  | 0.37341 | 0.60265 | 0.38527 | 0.45301 | 0.27028      | 0.38458 |
| 3-layer ENN, 70 hidden neurons  | 0.37489 | 0.56848 | 0.37749 | 0.37575 | 0.35211      | 0.49232 |
| 3-layer ENN, 100 hidden neurons | 0.35443 | 0.58197 | 0.37209 | 0.51843 | 0.45973      | 0.3964  |
| QENN, 5 hidden neurons          | 0.23782 | 0.2183  | 0.29263 | 0.22984 | 0.25729      | 0.10163 |

Tabela 1 - Resultados experimentais do estudo [3] (Fonte: [3]).

A Tabela 1 apresenta os resultados experimentais de diferentes arquiteturas de redes neurais para prever seis índices de mercado financeiro: BSE, NASDAQ, HSI, SSE, Russell 2000 e TAIEX. Os experimentos utilizaram redes neurais com três camadas ocultas e variações no número de neurônios ocultos, testando redes com 10, 20, 40, 70 e 100 neurônios ocultos. Além disso, um modelo baseado em redes neurais evolutivas quânticas, denominado QENN (Quantum Evolutionary Neural Network) ou em português Rede Neural Evolutiva Quântica, também foi avaliado, utilizando cinco neurônios ocultos. Os valores na Tabela 1 representam métricas de desempenho para cada índice de mercado e indicam que redes neurais com maior número de neurônios ocultos geralmente apresentam melhor desempenho, mas não existe um padrão absoluto, pois cada índice responde de maneira diferente à configuração da rede.

Os resultados mostram que a inclusão da QENN não obteve os melhores desempenhos quando comparada às redes neurais convencionais, o que pode indicar limitações na abordagem utilizada ou a necessidade de ajustes nos parâmetros para melhorar sua eficácia. A pesquisa demonstra que a escolha da arquitetura da rede neural tem um impacto significativo na previsão dos mercados financeiros, e que diferentes configurações podem ser mais ou menos eficazes dependendo do índice analisado. O estudo também sugere que, embora técnicas baseadas em computação quântica sejam promissoras, sua aplicação em redes neurais ainda exige refinamento para competir com modelos tradicionais bem ajustados.

Outro trabalho interessante pesquisou os avanços recentes na aprendizagem profunda chamando a atenção pela sua eficácia no tratamento de dados financeiros complexos. [6] investigaram a aplicação de RNNs na previsão de movimentos do mercado de ações, revelando desempenho superior em comparação aos métodos tradicionais de ML, no artigo foram explorados a previsão de preços no mercado financeiro por meio de redes neurais do tipo LSTM (Long Short-Term Memory) e a implementação de um sistema automatizado de trading. O estudo baseia-se no uso de indicadores técnicos (TIs) e dados históricos de preços, conhecidos como OHLCV (Open, High, Low, Close, Volume). Para isso, são considerados 108 indicadores técnicos, amplamente utilizados na análise técnica, que abrangem diferentes períodos e ajudam a capturar oscilações de curto e longo prazo, um dos

modelos criados pelos autores pode ser observado na Figura 10.

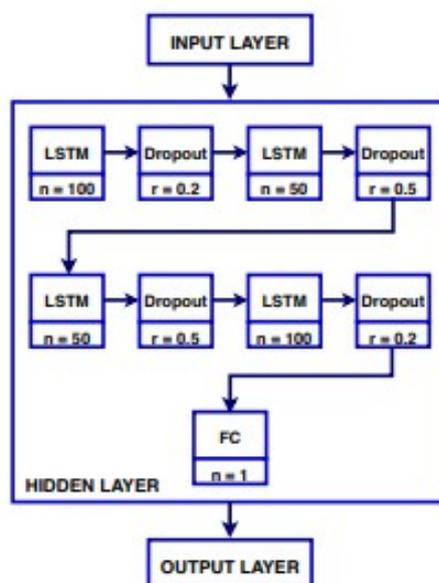


Figura 10 - Arquitetura modelo LSTM (Fonte: [6]).

A imagem apresenta a arquitetura do modelo de rede neural LSTM utilizada para previsão de preços no mercado financeiro. O diagrama ilustra as diferentes camadas do modelo, organizadas em uma estrutura hierárquica composta por camadas de entrada, ocultas e de saída. A rede começa com a camada de entrada (Input Layer), que recebe os dados históricos do mercado, incluindo preços e indicadores técnicos.

Na sequência, a informação passa por quatro camadas LSTM intercaladas com camadas de dropout, que têm a função de evitar o overfitting, reduzindo a dependência excessiva do modelo em padrões específicos dos dados de treinamento. A primeira camada LSTM possui 100 neurônios e está conectada a uma camada dropout com taxa de 20% ( $r = 0.2$ ). A segunda camada LSTM tem 50 neurônios e está associada a uma camada dropout de 50% ( $r = 0.5$ ). Esse padrão se repete na segunda parte da rede, onde outra camada LSTM de 50 neurônios é conectada a uma camada dropout de 50%, seguida de uma última camada LSTM com 100 neurônios associada a um dropout de 20%.

Após essa sequência de camadas recorrentes, a informação é processada por uma camada totalmente conectada (Fully Connected - FC), que possui apenas um neurônio de saída ( $n = 1$ ). Essa camada é responsável por consolidar os dados processados pelas camadas anteriores e gerar a previsão final do modelo. Por fim,

a informação é enviada para a camada de saída (Output Layer), que apresenta o resultado da previsão, indicando a tendência esperada para o mercado financeiro. O diagrama demonstra como a rede neural está estruturada para capturar padrões temporais nos dados e minimizar erros através da regularização com dropout. Essa organização permite que o modelo identifique padrões complexos nas séries temporais de preços e forneça previsões mais robustas para a tomada de decisão no mercado financeiro.

Outra contribuição notável é o trabalho realizado por [5], que introduziu as redes LSTM no domínio financeiro, evidenciando sua capacidade de capturar padrões complexos em séries temporais financeiras. Diferente das redes neurais recorrentes tradicionais (RNNs), que enfrentam dificuldades com o problema do gradiente em sequências longas, as LSTMs utilizam mecanismos de portas recorrentes que permitem a retenção de informações por períodos mais longos. Essa característica as torna especialmente adequadas para modelagem de dados financeiros, onde a identificação de tendências e a correlação entre eventos passados e futuros desempenham um papel fundamental. O estudo demonstrou que as LSTMs superam modelos convencionais ao prever movimentos de mercado, destacando-se pela capacidade de lidar com oscilações voláteis e padrões não lineares presentes nos dados financeiros.

Estudos comparativos entre modelos tradicionais de ML e arquiteturas de aprendizado profundo têm sido fundamentais para a compreensão de seus respectivos pontos fortes. [11] comparou a precisão preditiva de Naïve Bayes e Support Vector Machines com modelos de aprendizagem profunda, revelando o desempenho superior da aprendizagem profunda na previsão de tendências de mercado. O algoritmo Naïve Bayes, baseado no Teorema de Bayes, é amplamente utilizado para classificação de texto devido à sua simplicidade e eficiência, especialmente em cenários com grandes volumes de dados textuais. No estudo, a acurácia do Naïve Bayes foi avaliada utilizando diferentes abordagens de pré-processamento, como Bag of Words (BOW) e Term Frequency-Inverse Document Frequency (TF-IDF), além de técnicas de stemming e validação cruzada k-fold. Os resultados mostraram que o algoritmo teve um desempenho robusto na classificação de notícias financeiras, alcançando uma acurácia de 75,36% com a aplicação de stemming e frequência mínima de termos igual a 10. O F1-score

também foi expressivo, atingindo 84,02%, evidenciando a capacidade do modelo de distinguir corretamente sentimentos positivos e negativos em textos financeiros.

Por outro lado, o Support Vector Machines (SVM), um modelo baseado em hiperplanos para separação de classes, demonstrou ser uma abordagem mais robusta em alguns cenários, especialmente quando utilizado com representações vetoriais mais refinadas dos textos. O SVM se destaca por sua habilidade em lidar com dados de alta dimensionalidade e encontrar margens ótimas de separação entre classes, o que é essencial em problemas de análise de sentimentos e previsão de movimentos do mercado financeiro.

Apesar do bom desempenho de ambos os modelos tradicionais de ML, o estudo confirmou que técnicas de aprendizado profundo, como redes neurais recorrentes (RNN) e redes de memória de longo prazo (LSTM), alcançaram maior precisão na previsão das tendências de mercado. As redes neurais foram particularmente eficazes quando alimentadas com dados pré-processados por técnicas como stemming e otimização de hiperparâmetros.

A relação entre divulgações corporativas e o desempenho do mercado de ações tem sido amplamente estudada na pesquisa financeira, dada sua importância para investidores e analistas. [4] analisaram o impacto das surpresas nos lucros sobre os preços das ações, destacando como informações financeiras precisas e divulgadas em tempo hábil podem influenciar significativamente as decisões do mercado. A volatilidade dos preços das ações frequentemente reflete a assimilação dessas informações pelos investidores, tornando fundamental o desenvolvimento de modelos preditivos eficazes para interpretar padrões e tendências nos dados financeiros.

O modelo desenvolvido na pesquisa analisada emprega uma variante da LSTM denominada AELSTM (LSTM Neural Network with Automated Encoder), que incorpora um codificador automatizado para reduzir a dimensionalidade dos dados e melhorar a extração de características relevantes. Esse modelo permite processar grandes volumes de informações financeiras e identificar padrões sutis que poderiam passar despercebidos em abordagens tradicionais.

A arquitetura do modelo inclui três camadas principais: a camada de embedding, que transforma os dados financeiros de alta dimensionalidade em

representações mais compactas; a camada LSTM, responsável por capturar as dinâmicas temporais do mercado de ações; e a camada de saída, que fornece previsões sobre o comportamento dos preços. A utilização de um codificador automático baseado em uma máquina de Boltzmann de capacidade limitada aprimora ainda mais o desempenho do modelo, otimizando a fase de treinamento por meio da minimização de erros na retropropagação.

Uma das principais vantagens do AELSTM é a capacidade de lidar com a complexidade inerente aos mercados financeiros, permitindo ajustes mais precisos às oscilações de preços. O estudo reforça a importância da IA e do aprendizado profundo na análise de dados financeiros, oferecendo novas perspectivas para a modelagem de previsões do mercado de ações. Ao combinar técnicas avançadas de aprendizado de máquina com dados financeiros, modelos como o AELSTM abrem caminho para estratégias de investimento mais informadas e baseadas em evidências quantitativas.

Eachempati et al. [14] realizaram uma investigação detalhada sobre o impacto das divulgações voluntárias na formação do sentimento dos investidores e sua consequente influência sobre os movimentos do mercado. O estudo analisou como informações provenientes de comunicados de imprensa, lançamentos de produtos e outras divulgações corporativas não obrigatórias afetam a percepção dos investidores e, por extensão, a direção dos preços das ações.

A pesquisa comparou a eficácia de diferentes modelos de aprendizado de máquina e redes neurais profundas na previsão da movimentação do mercado com base nessas divulgações. Os resultados indicaram que a incorporação de redes neurais de longa memória (LSTM) e redes neurais recorrentes (RNN) melhora significativamente a precisão das previsões em relação a modelos tradicionais, como máquinas de suporte vetorial (SVM) e Naïve Bayes. Além disso, foi identificado que variáveis como notícias de mercado não absorvidas, preços históricos das ações e surpresa nos lucros das empresas desempenham um papel crucial na formação do sentimento do investidor e na determinação das tendências de mercado.

Todas as pesquisas destacam a importância de as empresas monitorarem e gerenciarem suas divulgações voluntárias de forma estratégica, garantindo que

suas comunicações ao mercado sejam claras, transparentes e alinhadas com a percepção desejada pelos investidores. O estudo também sugere que a aplicação de técnicas avançadas de aprendizado profundo pode auxiliar na interpretação dessas informações, fornecendo previsões mais precisas para investidores e gestores de risco.

A relação entre o trabalho realizado e os estudos revisados na literatura é evidente, pois todos têm como foco a análise e previsão dos movimentos do mercado de ações, embora abordem aspectos diferentes e utilizem metodologias diversas. Enquanto os estudos revisados exploram principalmente a análise de sentimento nos mercados financeiros e o impacto das divulgações corporativas, o trabalho realizado concentra-se na aplicação de modelos de aprendizado de máquina, especialmente redes neurais recorrentes, para prever os preços das ações.

Os estudos revisados, como o de [1] e [3] destacam a importância do sentimento do investidor e a influência das notícias financeiras e das redes sociais nos preços das ações. Por outro lado, o trabalho realizado se concentra na análise técnica dos dados financeiros e na utilização de arquiteturas de redes neurais, como LSTMs e GRUs, para prever os movimentos do mercado.

Vários estudos como os de [4] e [14] investigam o impacto das divulgações corporativas nos preços das ações e no sentimento dos investidores para tomar decisões que influenciam na previsão dos modelos dos autores, já o trabalho desenvolvido nesta pesquisa se diferencia ao aplicar modelos de aprendizado de máquina para analisar diretamente os dados históricos do mercado e fazer previsões futuras, combinando diferentes arquiteturas de redes neurais e diferentes tipos de combinação de parâmetros para encontrar o menor erro nas previsões.

Apesar das diferenças nas abordagens e metodologias, há uma convergência no objetivo de entender e prever o comportamento do mercado de ações seja por meio da análise de sentimento, da investigação das divulgações corporativas ou da aplicação de modelos de aprendizado de máquina. Esses estudos, incluindo o trabalho realizado, contribuem para ampliar o conhecimento sobre os mercados financeiros e fornecem percepções valiosas para investidores e pesquisadores, suas principais diferenças podem ser observadas na Tabela 2.

| <b>Trabalho</b>            | <b>Abordagem</b>  | <b>IA utilizada</b>             |
|----------------------------|---|---------------------------------|
| [Menon, Singh, Parek 2019] | Análise de sentimento de notícias financeiras e redes sociais para prever impacto nos preços das ações                | Deep Neural Network (DNN) + PCA |
| [Liu, Wenping 2022]        | Previsão de tendências do mercado de ações com diferentes configurações de redes neurais                              | Machine Learning                |
| [Singh 2022]               | Análise técnica do mercado financeiro com redes neurais para prever preços das ações                                  | Redes neurais profundas (DNN)   |
| [Jiang 2021]               | Aplicação de aprendizado profundo na previsão do mercado de ações   | LSTM                            |
| [Silva, Li, Pamplona 2020] | Sistema automatizado de trading baseado em RNN e indicadores técnicos   | RNN                             |
| [Januário 2022]            | Comparação entre Naïve Bayes, SVM e aprendizado profundo para análise de sentimentos no mercado                       | Naïve Bayes, SVM, RNN e LSTM    |
| [Eachempati 2021]          | Impacto de divulgações corporativas na formação de sentimentos do investidor  | Machine Learning                |
| Este trabalho              | Aplicação de aprendizado profundo e IA na análise do mercado financeiro com diferentes configurações de redes neurais | LSTM, GRU, hybrid               |

**Tabela 2 - Tabela comparativa trabalhos relacionados (Fonte: Autor).**

## 4 ANÁLISE DOS RESULTADOS EXPERIMENTAIS

Este capítulo apresenta testes e treinamentos de duas RNNs – LSTM e GRU, e um modelo com a combinação utilizando as duas arquiteturas de redes neurais, com uma das ações com maior volume de negociação na bolsa de valores brasileira (Ibovespa), visando um melhor balanceamento das redes durante os experimentos. Os treinamentos dos modelos foram realizados na plataforma de programação Google Colab, que permite criar e executar códigos em Python, combinados com texto explicativo e imagens de forma integrada em computadores pessoais.

As características (features) utilizadas no modelo desempenham papel fundamental na previsão dos preços das ações. A partir dos dados históricos, foram selecionadas variáveis que representam aspectos técnicos e fundamentalistas do ativo. Os preços de abertura ("Open"), máximo ("High"), mínimo ("Low") e o volume de negociação ("Volume") são características técnicas que ajudam a capturar a volatilidade e a dinâmica diária do mercado. Além disso, foram incorporados dois indicadores fundamentalistas: o preço sobre patrimônio (PP) e o preço sobre lucro (PL). O indicador PP é obtido dividindo o preço atual da ação pelo valor patrimonial por ação, fornecendo uma medida do quão caro um ativo está em relação ao seu patrimônio líquido. PL é calculado como a razão entre o preço da ação e o lucro por ação, refletindo a expectativa do mercado sobre os ganhos futuros da empresa. Esses indicadores adicionam uma dimensão mais abrangente ao modelo, permitindo levar em conta tanto a movimentação do mercado quanto a saúde financeira da empresa. Para garantir que todas as variáveis estejam em uma mesma escala, é aplicada a normalização dos dados usando o MinMaxScaler.

Foram criados 3 modelos inicialmente, um modelo utilizando arquitetura LSTM, um de arquitetura GRU e outro modelo híbrido que combina arquitetura LSTM e GRU, neste conjunto de experimentos, ambos modelos de redes neurais foram construídos com entrada de dados seguida pela primeira camada de 50 neurônios com um dropout de 20%. Dropout é uma técnica utilizada na maioria das redes neurais modernas para prevenir *overfitting*, zerando aleatoriamente uma porcentagem de neurônios nas camadas da rede neural [24].

Um cenário de *overfitting* ocorre quando, nos dados de treino, o modelo tem

desempenho excelente, porém, o resultado é ruim quando utiliza os dados de teste, neste caso, o modelo aprendeu tão bem as relações existentes no treino que acabou apenas decorando o que deveria ser feito e, ao receber as informações das variáveis preditoras nos dados de teste, o modelo tenta aplicar as mesmas regras decoradas, mas com novos dados esta regra não tem validade, e o desempenho é afetado [25].

A segunda camada do modelo com mais 50 neurônios e com um dropout de 20%, e a terceira camada com a mesma configuração das demais, porém, sendo acompanhada com uma camada “densa”, após o dropout de 20%. Essa camada é chamada de “densa” porque cada neurônio na camada está conectado a todos os neurônios da camada anterior, formando uma grade densa de conexões, ela é necessária para atribuir um único valor à saída, este valor será a predição após o processamento dos dados na rede neural.

Modelos de aprendizado de máquina definem o parâmetro época (epoch), principalmente em redes neurais; epoch representa uma única passagem por todo o conjunto de dados de treinamento. Durante uma epoch, o modelo vê todas as amostras do conjunto de treinamento uma vez e ajusta seus pesos com base nos erros calculados. Os modelos utilizarão o valor 100, implicando que o modelo passará 100 vezes pelo conjunto de dados de treinamento, refinando seus pesos a cada iteração para minimizar a função de perda (RMSE). Escolher um número adequado de epoch é essencial, pois um valor muito baixo pode resultar em underfitting, enquanto um número muito alto pode levar a overfitting, onde o modelo aprende padrões do conjunto de treinamento que não generalizam bem para novos dados.

Após a implementação e organização do código para cada modelo, foi necessário definir os parâmetros que poderiam ser alterados para analisar o desempenho dos modelos. Os modelos foram programados para realizar previsões de preço de “fechamento” dos 22 dias subsequentes; este intervalo de dias ignora final de semana.

Para avaliar o desempenho dessas arquiteturas de redes neurais recorrentes, os três modelos desenvolvidos utilizando LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit) e LSTM+GRU, foram submetidos a diversos testes

conduzidos variando parâmetros fundamentais, como a taxa de dropout, o número de épocas de treinamento e a quantidade de neurônios por camada da rede neural de cada modelo.

O parâmetro dropout é utilizado para reduzir o overfitting durante o treinamento da rede, foi inicialmente definido como 0.2, ou seja, 20%, mas também testado com valores de 0.4 e 0.6 para avaliar seu impacto na capacidade de generalização do modelo. Já o número de epochs, que determina quantas vezes o modelo percorre o conjunto de treinamento, foi ajustado de 100 (valor padrão) para 50 e 200, a fim de observar possíveis melhorias na convergência e desempenho da rede. Por fim, a quantidade de neurônios por camada, responsável pela capacidade de representação da rede, foi testada com valores de 20, 50 (padrão) e 80, permitindo avaliar se redes mais simples ou mais complexas apresentaram melhor desempenho, para uma melhor observação dos parâmetros alternados é possível observar com maior facilidade na Tabela 3.

| <b>Modelo</b> | <b>Dropout</b> | <b>Epochs</b> | <b>Neurônios por camada</b> |
|---------------|----------------|---------------|-----------------------------|
| LSTM          | 0.2, 0.4, 0.6  | 50, 100, 200  | 20, 50, 80                  |
| GRU           | 0.2, 0.4, 0.6  | 50, 100, 200  | 20, 50, 80                  |
| LSTM + GRU    | 0.2, 0.4, 0.6  | 50, 100, 200  | 20, 50, 80                  |

**Tabela 3 - Tabela de parâmetros (Fonte: Autor).**

Para compreender o impacto do período de treinamento na precisão da previsão de preços, foram realizados testes com sete variações do conjunto de dados, considerando diferentes janelas temporais. O objetivo principal dessa abordagem foi avaliar como a inclusão ou exclusão de períodos históricos influencia o desempenho do modelo, especialmente em cenários marcados por eventos significativos, como crises econômicas ou pandemias.

Os testes foram conduzidos utilizando os seguintes períodos de treinamento:

- Todo o dataset disponível.
- Últimos 3 anos antes da última data registrada.
- Últimos 2 anos e 6 meses antes da última data registrada.
- Últimos 2 anos antes da última data registrada.
- Último 1 ano e 6 meses antes da última data registrada.

- Último 1 ano antes da última data registrada.
- Últimos 6 meses antes da última data registrada.

Essa estratégia permitiu avaliar como diferentes horizontes temporais afetam a capacidade preditiva da rede. Em períodos mais longos, o modelo tem acesso a um histórico maior de dados, o que pode ser benéfico para captar padrões sazonais e tendências de longo prazo. No entanto, a inclusão de eventos atípicos, como crises financeiras ou pandemias, pode introduzir ruídos que afetam a precisão da previsão para períodos mais recentes.

Por outro lado, janelas de treinamento menores permitem que o modelo se concentre em padrões mais recentes, refletindo melhor as condições atuais do mercado. No entanto, a limitação do histórico de dados pode comprometer a capacidade do modelo de identificar tendências robustas, tornando-o mais suscetível a flutuações temporárias.

#### 4.1 Modelo LSTM Default

Ao realizar os testes com o modelo LSTM de todo o período do dataset, utilizando a ação da Ambev (ABEV3), obtendo os dados da empresa através da API do Yahoo Finance, considerando o intervalo de 01/05/2005 até 09/12/2024 com o intuito de obter os próximos 22 dias úteis de previsão, o resultado obtido pelo modelo para este período é demonstrado na Figura 11.

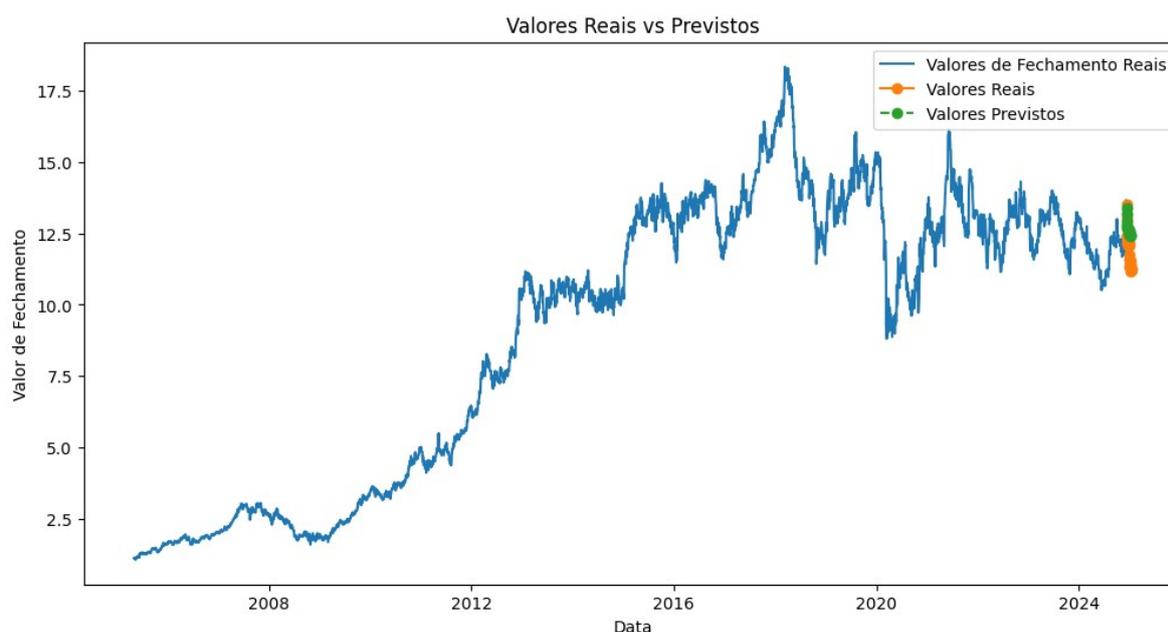


Figura 11 - Gráfico das previsões de todo período, modelo LSTM default (Fonte: Autor).

A Figura 11 mostra a evolução histórica dos valores de fechamento ao longo do tempo, com uma tendência de alta até 2020, seguida de uma fase de oscilações. Os pontos destacados no final do gráfico representam as previsões do modelo. Os valores reais estão indicados em laranja, enquanto os valores previstos pelo modelo LSTM estão marcados em verde. Os resultados mostram uma tendência de leve queda nos valores futuros, com uma redução gradual nos preços ao longo do período previsto. Isso sugere que o modelo identificou um possível padrão de comportamento na série histórica, projetando uma continuidade da movimentação atual. Os valores obtidos no teste estão expostos na Tabela 4.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,38    | 13,52 |
| 11/12/2024 | 13,18    | 13,08 |
| 12/12/2024 | 12,95    | 12,42 |
| 13/12/2024 | 12,81    | 12,4  |
| 16/12/2024 | 12,72    | 12,17 |
| 17/12/2024 | 12,67    | 12,42 |
| 18/12/2024 | 12,66    | 12,09 |
| 19/12/2024 | 12,66    | 12,11 |
| 20/12/2024 | 12,66    | 12,23 |
| 23/12/2024 | 12,65    | 12,22 |
| 24/12/2024 | 12,64    | 12,22 |
| 25/12/2024 | 12,63    | 12,22 |
| 26/12/2024 | 12,60    | 12,14 |
| 27/12/2024 | 12,58    | 12,07 |
| 30/12/2024 | 12,56    | 11,74 |
| 31/12/2024 | 12,53    | 11,74 |
| 01/01/2025 | 12,51    | 11,6  |
| 02/01/2025 | 12,49    | 11,6  |
| 03/01/2025 | 12,47    | 11,33 |
| 06/01/2025 | 12,45    | 11,29 |
| 07/01/2025 | 12,43    | 11,54 |
| 08/01/2025 | 12,41    | 11,42 |

**Tabela 4 - Resultados de todo período, modelo LSTM default (Fonte: Autor).**

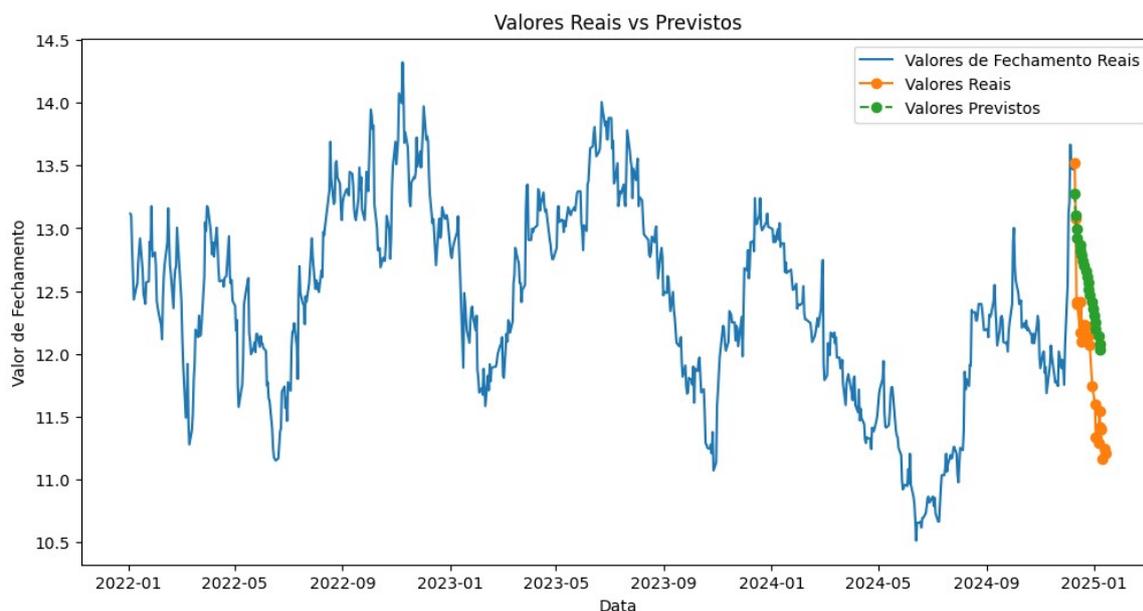
Na análise preditiva realizada com o teste desse modelo LSTM, foi utilizada a métrica RMSE para avaliar a precisão das previsões em relação aos valores reais. O RMSE obtido foi de 0.82, indicando um erro relativamente baixo, o que demonstra um bom desempenho do modelo na previsão da série temporal.

Com um RMSE de 0.82, podemos inferir que o modelo LSTM conseguiu capturar bem os padrões históricos e projetar valores futuros com um erro médio relativamente baixo. No entanto, mesmo com um bom desempenho, é sempre

importante considerar ajustes no modelo, como a otimização dos hiperparâmetros, ajustes no tamanho da janela de entrada ou o uso de técnicas adicionais para melhorar a precisão, especialmente em mercados financeiros onde a volatilidade pode impactar as previsões, isso será aprofundado nos próximos testes.

Para testar a eficácia do modelo LSTM na previsão de séries temporais financeiras, foi realizada uma análise, seguida de testes considerando os últimos três anos antes da última data registrada. O objetivo foi comparar os valores reais e previstos, analisar a robustez e adaptabilidade do modelo diante de eventos marcantes, determinando se períodos mais curtos ou mais longos fornece previsões mais confiáveis em diferentes cenários avaliando o desempenho do modelo ao capturar tendências e padrões de comportamento do mercado.

A Figura 12 ilustra a evolução dos valores de fechamento ao longo do período analisado, destacando-se as variações de preço e possíveis ciclos de alta e baixa. Os pontos laranja representam os valores reais registrados da ação, enquanto os pontos verdes indicam as previsões geradas pelo modelo.



**Figura 12 - Gráfico das previsões de 3 anos, modelo LSTM default (Fonte: Autor).**

O modelo conseguiu captar a tendência geral do mercado, com previsões que seguem a direção dos movimentos históricos. Há uma aproximação considerável entre os valores reais e previstos, reforçando a capacidade do LSTM de aprender padrões a partir dos dados passados, os valores estão expostos na Tabela 5.

| <b>Data</b> | <b>Previsão</b> | <b>Real</b> |
|-------------|-----------------|-------------|
| 10/12/2024  | 13,28           | 13,52       |
| 11/12/2024  | 13,10           | 13,08       |
| 12/12/2024  | 13,00           | 12,42       |
| 13/12/2024  | 12,93           | 12,4        |
| 16/12/2024  | 12,87           | 12,17       |
| 17/12/2024  | 12,82           | 12,42       |
| 18/12/2024  | 12,78           | 12,09       |
| 19/12/2024  | 12,74           | 12,11       |
| 20/12/2024  | 12,70           | 12,23       |
| 23/12/2024  | 12,66           | 12,22       |
| 24/12/2024  | 12,61           | 12,22       |
| 25/12/2024  | 12,57           | 12,22       |
| 26/12/2024  | 12,52           | 12,14       |
| 27/12/2024  | 12,47           | 12,07       |
| 30/12/2024  | 12,41           | 11,74       |
| 31/12/2024  | 12,36           | 11,74       |
| 01/01/2025  | 12,30           | 11,6        |
| 02/01/2025  | 12,25           | 11,6        |
| 03/01/2025  | 12,19           | 11,33       |
| 06/01/2025  | 12,14           | 11,29       |
| 07/01/2025  | 12,08           | 11,54       |
| 08/01/2025  | 12,03           | 11,42       |

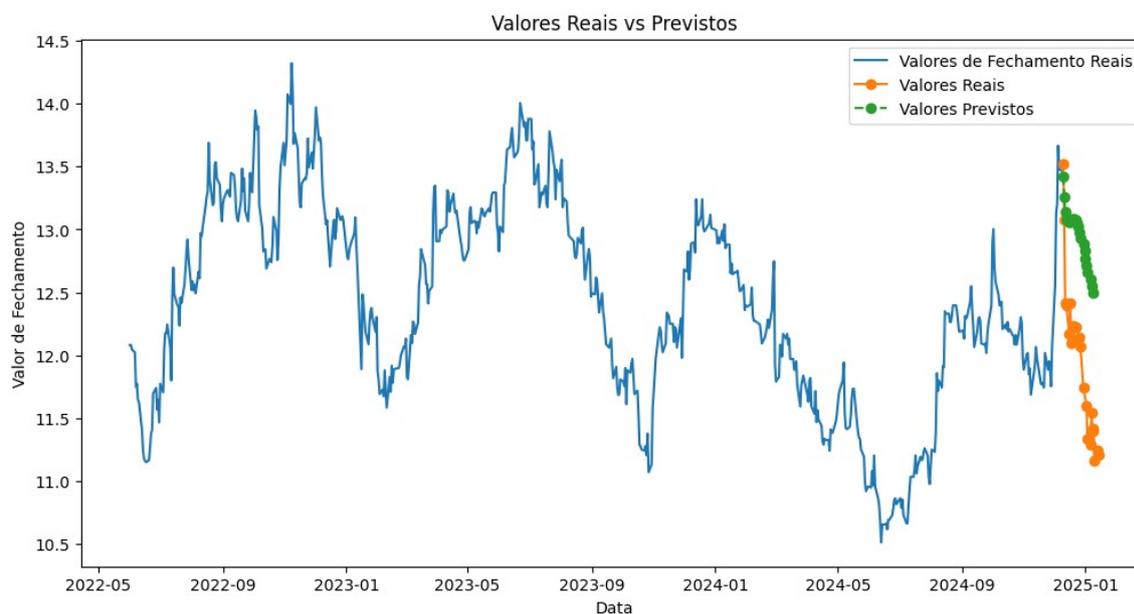
**Tabela 5 - Resultados de 3 anos, modelo LSTM default (Fonte: Autor).**

A avaliação do desempenho do modelo LSTM para previsão de séries temporais revelou diferenças no erro médio ao comparar dois períodos distintos. Para o período completo analisado, o RMSE (Raiz do Erro Quadrático Médio) foi de 0,82, enquanto para os últimos três anos antes da última data registrada, o RMSE foi de 0,71. Essa redução indica que o modelo apresentou um desempenho ligeiramente melhor quando aplicado a um intervalo com menos dados.

Uma possível explicação para essa melhora é que os padrões do mercado podem ter se tornado mais consistentes nos últimos anos, tornando as previsões mais precisas. Além disso, se a volatilidade foi menor nesse período, o modelo pode ter encontrado maior facilidade em identificar tendências e ciclos.

Para termos uma ideia mais concreta na realização de testes com intervalos menores do dataset, realizamos outro teste com os últimos 2 anos e 6 meses antes da última data registrada. A Figura 13 ilustra a evolução dos valores de fechamento

ao longo do período analisado e destaca as variações de preço e possíveis ciclos de alta e baixa, onde os pontos laranja representam os valores reais registrados da ação, enquanto os pontos verdes indicam as previsões geradas pelo modelo.



**Figura 13 - Gráfico das previsões de 2 anos e 6 meses, modelo LSTM default (Fonte: Autor).**

O modelo ainda assim conseguiu capturar a tendência geral do mercado, com previsões que seguem a direção dos movimentos históricos, porém há uma aproximação entre os valores reais e previstos já ficaram um pouco mais afastadas ao comparar com testes dos últimos 3 anos e de todo o período. Essa análise pode ser observada em mais detalhes através dos resultados numéricos apresentados na Tabela 6.

A avaliação do desempenho do modelo LSTM para previsão de séries temporais mostrou variações significativas no erro médio ao comparar diferentes períodos de teste. O RMSE para os últimos dois anos e seis meses antes da última data registrada foi de 1,08, um valor mais alto em relação aos 0,82 do período completo e aos 0,71 do teste com os últimos três anos. Esse aumento do erro sugere que, nesse intervalo específico, o modelo teve maior dificuldade em capturar os padrões de comportamento da série temporal, resultando em previsões menos precisas.

Uma possível explicação para esse aumento no RMSE é que o período analisado pode ter apresentado maior volatilidade, tornando mais desafiadora a previsão dos valores futuros. Movimentos instáveis no mercado, eventos externos e

mudanças na tendência podem ter impactado a estabilidade do modelo, reduzindo sua capacidade preditiva. Além disso, a distribuição dos dados ao longo do tempo pode ter influenciado a performance, pois se os últimos dois anos e meio contiveram variações atípicas, o modelo pode ter sido menos eficiente em identificar padrões consistentes.

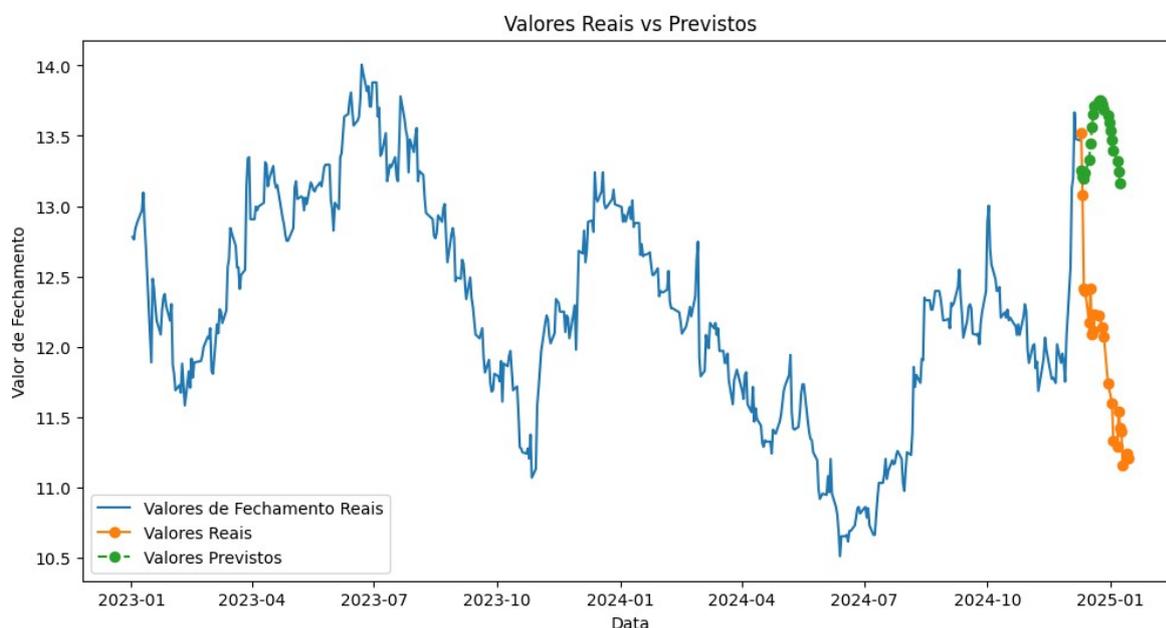
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,42    | 13,52 |
| 11/12/2024 | 13,26    | 13,08 |
| 12/12/2024 | 13,14    | 12,42 |
| 13/12/2024 | 13,08    | 12,4  |
| 16/12/2024 | 13,06    | 12,17 |
| 17/12/2024 | 13,06    | 12,42 |
| 18/12/2024 | 13,07    | 12,09 |
| 19/12/2024 | 13,08    | 12,11 |
| 20/12/2024 | 13,08    | 12,23 |
| 23/12/2024 | 13,07    | 12,22 |
| 24/12/2024 | 13,05    | 12,22 |
| 25/12/2024 | 13,02    | 12,22 |
| 26/12/2024 | 12,98    | 12,14 |
| 27/12/2024 | 12,93    | 12,07 |
| 30/12/2024 | 12,88    | 11,74 |
| 31/12/2024 | 12,83    | 11,74 |
| 01/01/2025 | 12,77    | 11,6  |
| 02/01/2025 | 12,72    | 11,6  |
| 03/01/2025 | 12,66    | 11,33 |
| 06/01/2025 | 12,60    | 11,29 |
| 07/01/2025 | 12,55    | 11,54 |
| 08/01/2025 | 12,49    | 11,42 |

**Tabela 6 - Resultados de 2 anos e 6 meses, modelo LSTM default (Fonte: Autor).**

A diferença entre os RMSEs também sugere que o desempenho do modelo não melhora linearmente à medida que se reduz o período de teste. Enquanto no intervalo de três anos houve um aprimoramento na precisão das previsões, o teste com dois anos e meio apresentou um erro maior, indicando que a escolha do período de análise pode ter um impacto direto na qualidade das previsões. Esse resultado reforça a necessidade de ajustes contínuos no modelo e na seleção dos dados de treinamento para garantir previsões mais precisas, considerando a dinâmica da série temporal ao longo do tempo.

Realizamos testes adicionais para descartar impactos de eventos externos e mudanças na tendência, o próximo a ser demonstrado é o de 2 anos antes da última data registrada. A Figura 14 apresenta a evolução dos valores de fechamento ao

longo do período analisado e destaca as variações de preço e possíveis ciclos de alta e baixa, onde os pontos em laranja representam valores reais registrados da ação, enquanto os pontos verdes indicam previsões geradas pelo modelo.



**Figura 14 - Gráfico das previsões de 2 anos, modelo LSTM default (Fonte: Autor).**

Neste teste, o modelo apresentou maior dificuldade em capturar a tendência geral do mercado. Embora suas previsões sigam parcialmente a direção dos movimentos históricos, nota-se um afastamento maior entre os valores reais e os valores previstos. Essa discrepância pode ser analisada com mais detalhes por meio dos resultados numéricos apresentados na Tabela 7.

A análise dos erros médios das previsões do modelo LSTM revelou uma variação significativa conforme o período de teste considerado. O RMSE para os últimos dois anos antes da última data registrada foi de 1,68, um valor mais alto do que os 0,82 observados para o período completo, os 0,71 dos últimos três anos e os 1,08 dos últimos dois anos e seis meses. Esse aumento no erro sugere que o modelo teve maior dificuldade em capturar os padrões recentes da série temporal, o que pode estar relacionado a uma maior volatilidade ou a mudanças estruturais no comportamento dos dados. O fato de o RMSE crescer conforme o intervalo de análise se reduz reforça a hipótese de que os dados mais recentes apresentam características distintas do restante da série, tornando a previsão mais desafiadora. Isso pode indicar a presença de eventos inesperados, mudanças na tendência do mercado ou períodos de maior oscilação nos preços, fatores que afetam

diretamente a precisão do modelo. Além disso, essa variação no erro mostra que o modelo pode estar mais ajustado a padrões de longo prazo e menos eficiente na captação de movimentos mais recentes e específicos da série.

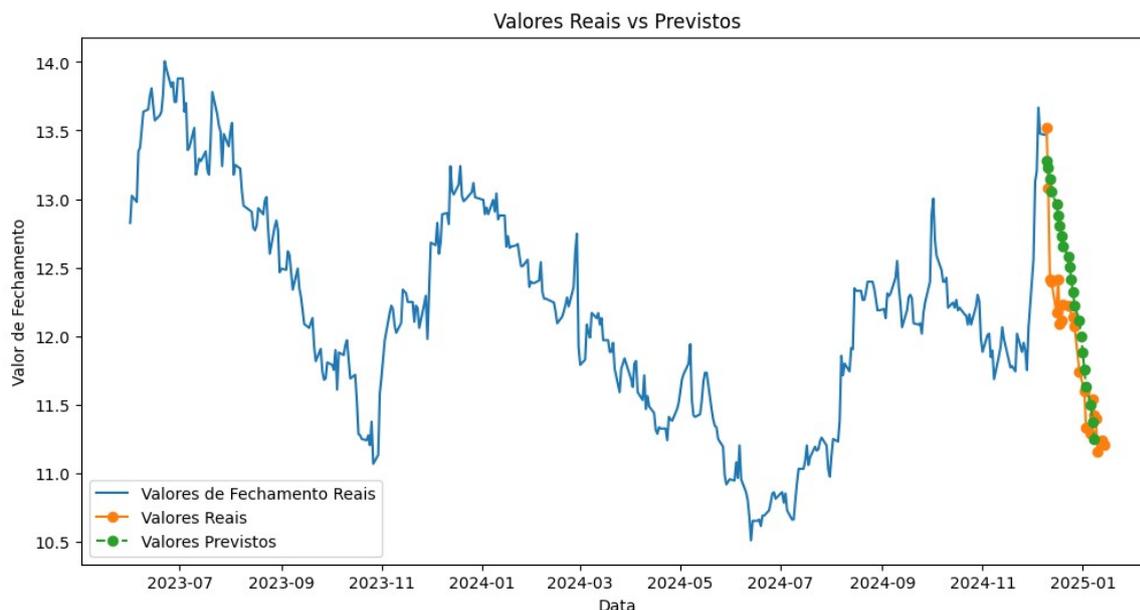
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,25    | 13,52 |
| 11/12/2024 | 13,22    | 13,08 |
| 12/12/2024 | 13,20    | 12,42 |
| 13/12/2024 | 13,24    | 12,4  |
| 16/12/2024 | 13,33    | 12,17 |
| 17/12/2024 | 13,45    | 12,42 |
| 18/12/2024 | 13,56    | 12,09 |
| 19/12/2024 | 13,66    | 12,11 |
| 20/12/2024 | 13,72    | 12,23 |
| 23/12/2024 | 13,75    | 12,22 |
| 24/12/2024 | 13,75    | 12,22 |
| 25/12/2024 | 13,74    | 12,22 |
| 26/12/2024 | 13,72    | 12,14 |
| 27/12/2024 | 13,69    | 12,07 |
| 30/12/2024 | 13,65    | 11,74 |
| 31/12/2024 | 13,60    | 11,74 |
| 01/01/2025 | 13,54    | 11,6  |
| 02/01/2025 | 13,47    | 11,6  |
| 03/01/2025 | 13,40    | 11,33 |
| 06/01/2025 | 13,32    | 11,29 |
| 07/01/2025 | 13,24    | 11,54 |
| 08/01/2025 | 13,16    | 11,42 |

**Tabela 7 - Resultados de 2 anos, modelo LSTM default (Fonte: Autor).**

A análise do desempenho do modelo LSTM foi estendida para considerar os últimos 1 ano e 6 meses antes da última data registrada. Esse teste permite avaliar a precisão das previsões do modelo em um período mais recente, observando possíveis variações na qualidade das previsões conforme a janela de análise se reduz. A comparação entre os valores reais e os previstos pelo modelo pode fornecer insights sobre sua capacidade de adaptação a padrões mais recentes da série temporal, bem como indicar se há desafios adicionais na captura das tendências de curto prazo.

Na Figura 15, é possível observar a correspondência entre os dados reais e as previsões do modelo. A análise desse comportamento pode ajudar a identificar possíveis desvios nas previsões, como uma tendência de superestimação ou subestimação dos valores. Além disso, o desempenho do modelo nesse período pode ser comparado com testes anteriores para verificar se a precisão se mantém

estável ou se há um aumento na discrepância entre os valores previstos e os observados.



**Figura 15 - Gráfico das previsões de 1 ano e 6 meses, modelo LSTM default (Fonte: Autor).**

Esse tipo de avaliação é essencial para entender como o modelo responde às mudanças mais recentes na série temporal, pois em muitos casos as características do comportamento dos dados podem mudar ao longo do tempo. Se o erro médio das previsões aumentarem significativamente nesse recorte mais curto, pode ser um indicativo de que o modelo não está conseguindo acompanhar as variações mais recentes, o que pode justificar ajustes no processo de treinamento, na seleção das variáveis ou na abordagem utilizada para prever os valores futuros.

Avaliando a Figura 15, é possível perceber que o desempenho do modelo para os últimos 1 ano e 6 meses antes da última data registrada apresenta um comportamento coerente com a tendência geral dos dados. O modelo parece captar bem a direção geral da tendência, mas pode ter enfrentado desafios para ajustar-se com precisão a variações mais bruscas nos valores reais, os mesmos podem ser observados na Tabela 8.

O RMSE para o resultado dos últimos 1 ano e 6 meses antes da última data registrada foi de 0,50, um valor mais baixo em comparação com os testes realizados para períodos maiores, como o de todo o período, o de 3 anos, o de 2 anos e 6 meses e o de 2 anos antes da última data registrada. Esse desempenho sugere que o modelo teve maior precisão ao prever os valores de fechamento mais recentes,

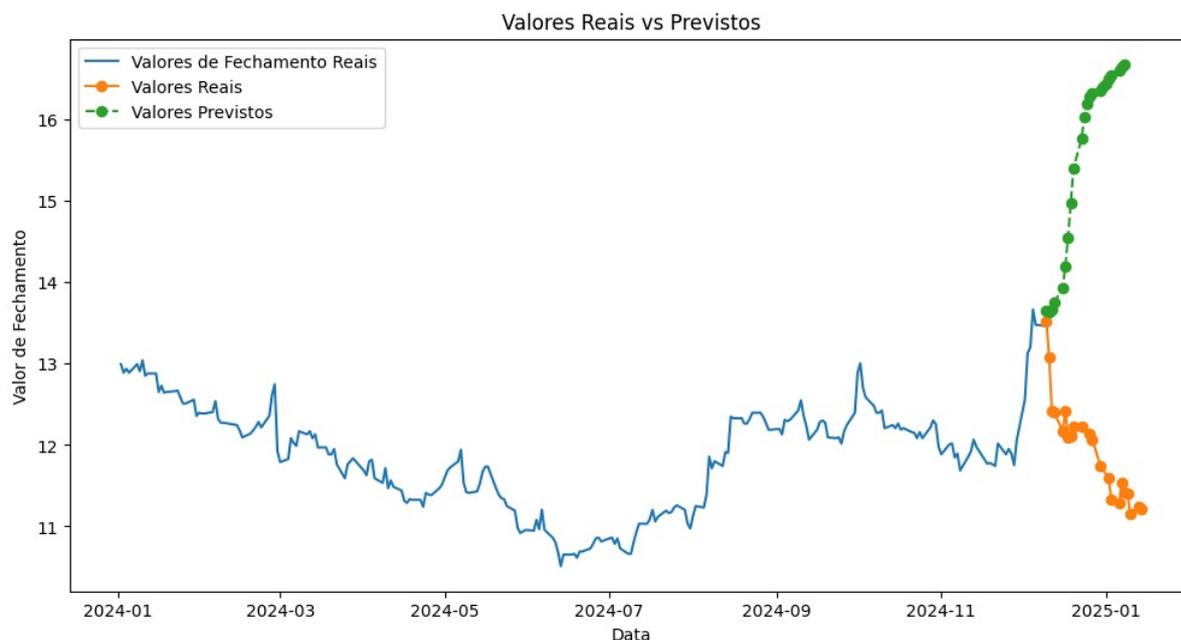
possivelmente por captar melhor as dinâmicas recentes do mercado. A redução do erro pode indicar que padrões mais recentes foram mais bem assimilados, resultando em previsões mais ajustadas aos dados reais.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,28    | 13,52 |
| 11/12/2024 | 13,23    | 13,08 |
| 12/12/2024 | 13,14    | 12,42 |
| 13/12/2024 | 13,05    | 12,4  |
| 16/12/2024 | 12,96    | 12,17 |
| 17/12/2024 | 12,88    | 12,42 |
| 18/12/2024 | 12,80    | 12,09 |
| 19/12/2024 | 12,73    | 12,11 |
| 20/12/2024 | 12,66    | 12,23 |
| 23/12/2024 | 12,58    | 12,22 |
| 24/12/2024 | 12,50    | 12,22 |
| 25/12/2024 | 12,42    | 12,22 |
| 26/12/2024 | 12,32    | 12,14 |
| 27/12/2024 | 12,22    | 12,07 |
| 30/12/2024 | 12,11    | 11,74 |
| 31/12/2024 | 12,00    | 11,74 |
| 01/01/2025 | 11,88    | 11,6  |
| 02/01/2025 | 11,76    | 11,6  |
| 03/01/2025 | 11,63    | 11,33 |
| 06/01/2025 | 11,50    | 11,29 |
| 07/01/2025 | 11,37    | 11,54 |
| 08/01/2025 | 11,25    | 11,42 |

**Tabela 8 - Resultados de 1 ano e 6 meses, modelo LSTM default (Fonte: Autor).**

Ao considerar o teste realizado com os dados do último 1 ano antes da última data registrada, é possível avaliar a capacidade do modelo em capturar as tendências mais recentes. Esse período mais curto permite verificar se o comportamento da série temporal manteve uma coerência maior entre os valores reais e as previsões. A análise desse intervalo possibilita compreender se a proximidade temporal influencia na precisão do modelo, tornando-o mais adaptado às mudanças recentes ou se, por outro lado, há um aumento do erro devido à redução do histórico disponível para aprendizado.

A comparação dos desempenhos com os períodos anteriores será essencial para determinar se a escolha de uma janela de tempo menor impacta de forma positiva ou negativa na precisão das previsões, dessa forma o resultado do teste dos dados do último 1 ano antes da última data registrada é exibido abaixo na Figura 16.



**Figura 16 - Gráfico das previsões de 1 ano, modelo LSTM default (Fonte: Autor).**

Ao observar os valores previstos em comparação com os reais, nota-se que há leve divergência na captura da direção do preço dos valores previsto com os valores reais; a Tabela 9 permite visualizar numericamente a discrepância dos resultados.

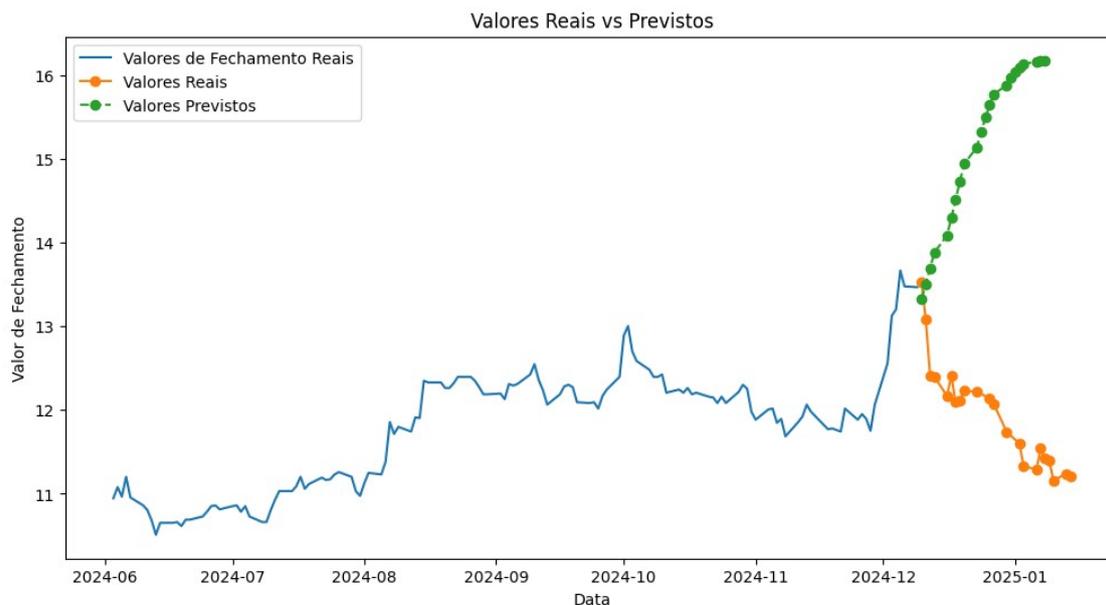
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,66    | 13,52 |
| 11/12/2024 | 13,64    | 13,08 |
| 12/12/2024 | 13,67    | 12,42 |
| 13/12/2024 | 13,76    | 12,4  |
| 16/12/2024 | 13,93    | 12,17 |
| 17/12/2024 | 14,20    | 12,42 |
| 18/12/2024 | 14,56    | 12,09 |
| 19/12/2024 | 14,98    | 12,11 |
| 20/12/2024 | 15,40    | 12,23 |
| 23/12/2024 | 15,77    | 12,22 |
| 24/12/2024 | 16,03    | 12,22 |
| 25/12/2024 | 16,19    | 12,22 |
| 26/12/2024 | 16,28    | 12,14 |
| 27/12/2024 | 16,33    | 12,07 |
| 30/12/2024 | 16,36    | 11,74 |
| 31/12/2024 | 16,40    | 11,74 |
| 01/01/2025 | 16,45    | 11,6  |
| 02/01/2025 | 16,50    | 11,6  |
| 03/01/2025 | 16,55    | 11,33 |
| 06/01/2025 | 16,60    | 11,29 |
| 07/01/2025 | 16,65    | 11,54 |
| 08/01/2025 | 16,68    | 11,42 |

**Tabela 9 - Resultados de 1 ano, modelo LSTM default (Fonte: Autor).**

O RMSE para o resultado do último 1 ano antes da última data registrada foi de 3,92, sendo o maior entre todas as análises realizadas. Esse valor indica um erro significativamente mais elevado em comparação com os outros períodos avaliados. O RMSE foi mais alto em relação ao teste que considerou todo o período disponível, sugerindo que a restrição dos dados nos últimos 12 meses comprometeu a precisão das previsões. Quando comparado ao teste dos últimos 3 anos antes da última data registrada, assim como aos testes de 2 anos e 6 meses, 2 anos e 1 ano e 6 meses, o desempenho também foi inferior, com um erro substancialmente maior. Esse resultado pode indicar que o modelo perdeu capacidade preditiva ao trabalhar com um intervalo menor de dados, possivelmente devido a menor quantidade de padrões históricos para calibrar a previsão com precisão. Além disso, a maior volatilidade recente pode ter influenciado a previsão, tornando os valores previstos menos alinhados com os reais.

A análise dos últimos 6 meses antes da última data registrada tem como objetivo avaliar o desempenho do modelo em um período ainda mais restrito, observando se a precisão das previsões se mantém ou se há um aumento no erro conforme a janela de dados utilizada diminui. Esse teste é fundamental para compreender como o modelo responde a um conjunto de dados mais recente e verificar se ele consegue capturar tendências de curto prazo de forma eficaz. Com um período menor para a extração de padrões, existe a possibilidade de que as previsões se tornem mais voláteis ou desviem significativamente dos valores reais. A expectativa é analisar se essa restrição temporal impacta negativamente o desempenho, resultando em um RMSE maior, ou se, pelo contrário, o modelo se ajusta bem às variações mais recentes. Dessa forma, os resultados obtidos permitirão uma comparação direta com as previsões feitas para períodos mais longos e ajudarão a determinar se a utilização de um intervalo reduzido de dados compromete a capacidade do modelo de generalizar padrões de comportamento.

O resultado gráfico dos testes da previsão dos últimos 6 meses pode ser observado na Figura 17.



**Figura 17 - Gráfico das previsões dos últimos 6 meses, modelo LSTM default (Fonte: Autor).**

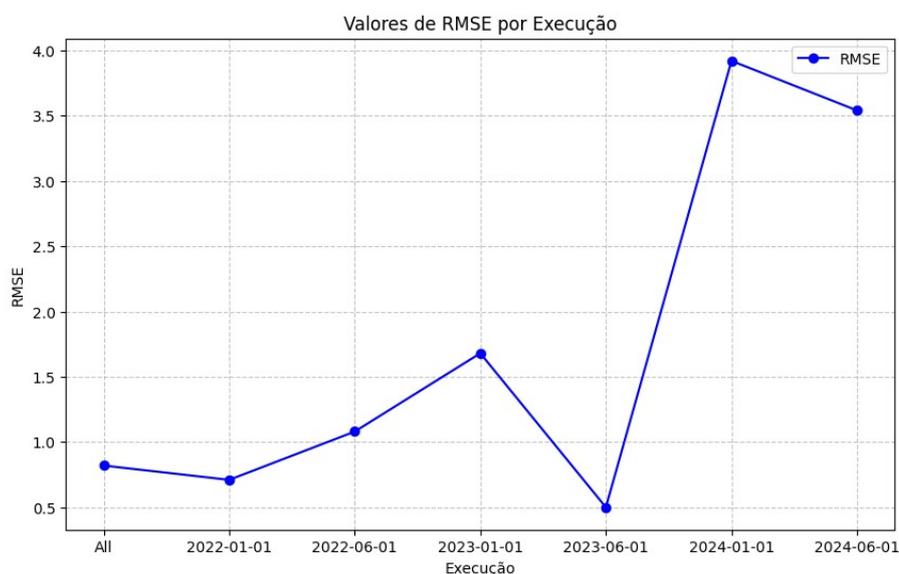
Novamente os valores previstos em comparação com os reais foram para caminhos distintos, notando-se que a captação da direção do preço dos valores previstos com os valores reais não foi correspondente, a Tabela 10 mostra os valores resultantes da previsão do modelo.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,33    | 13,52 |
| 11/12/2024 | 13,51    | 13,08 |
| 12/12/2024 | 13,69    | 12,42 |
| 13/12/2024 | 13,88    | 12,4  |
| 16/12/2024 | 14,09    | 12,17 |
| 17/12/2024 | 14,30    | 12,42 |
| 18/12/2024 | 14,51    | 12,09 |
| 19/12/2024 | 14,73    | 12,11 |
| 20/12/2024 | 14,94    | 12,23 |
| 23/12/2024 | 15,14    | 12,22 |
| 24/12/2024 | 15,32    | 12,22 |
| 25/12/2024 | 15,49    | 12,22 |
| 26/12/2024 | 15,64    | 12,14 |
| 27/12/2024 | 15,77    | 12,07 |
| 30/12/2024 | 15,88    | 11,74 |
| 31/12/2024 | 15,97    | 11,74 |
| 01/01/2025 | 16,04    | 11,6  |
| 02/01/2025 | 16,10    | 11,6  |
| 03/01/2025 | 16,14    | 11,33 |
| 06/01/2025 | 16,16    | 11,29 |
| 07/01/2025 | 16,17    | 11,54 |
| 08/01/2025 | 16,18    | 11,42 |

**Tabela 10 - Resultados dos últimos 6 meses, modelo LSTM default (Fonte: Autor).**

O RMSE para o resultado dos últimos 6 meses antes da última data registrada foi de 3,54, um valor relativamente alto quando comparado com os demais períodos analisados. Esse erro foi superior ao do teste realizado com todo o período, assim como ao dos testes considerando os últimos 3 anos, os últimos 2 anos e 6 meses, os últimos 2 anos e os últimos 1 ano e 6 meses antes da última data registrada. No entanto, esse RMSE foi menor do que o obtido no teste do último 1 ano antes da última data registrada, que apresentou o maior erro entre todos os períodos avaliados. Esse resultado indica que, apesar de aumentar o erro ao usar apenas os dados mais recentes, o desempenho ainda se mostrou melhor do que a previsão feita exclusivamente com o último ano. A tendência de crescimento do erro conforme a base de dados utilizada se torna menor sugere que um volume maior de dados pode contribuir para uma melhor generalização do modelo, reduzindo a variabilidade e melhorando a precisão da previsão.

Observando a variação dos erros da Figura 18, percebe-se que o RMSE inicia em um valor relativamente baixo quando analisado para todo o período, seguido por uma leve redução na execução correspondente ao início de 2022. A partir desse ponto, há um crescimento gradual nos valores, atingindo um pico intermediário no início de 2023. Posteriormente, observa-se uma queda acentuada no meio de 2023, indicando um período onde o modelo apresentou maior precisão. No entanto, essa melhora não se sustentou, e os erros dispararam nos testes desde o início de 2024,



**Figura 18 - Gráfico dos resultados de RMSE, modelo LSTM default (Fonte: Autor).**

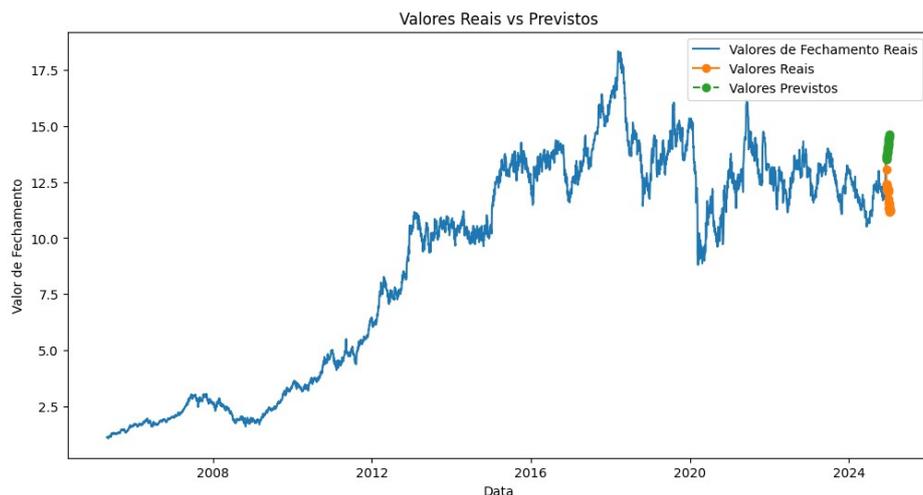
Posteriormente, observa-se uma queda acentuada no meio de 2023, indicando um período onde o modelo apresentou maior precisão. No entanto, essa melhora não se sustentou, e os erros dispararam nos testes desde o início de 2024,

atingindo o maior valor registrado. Apesar de uma leve redução na última execução do período, o RMSE ainda se mantém elevado em relação às execuções anteriores, sugerindo que o desempenho do modelo LSTM se deteriorou nos testes mais recentes. Essa tendência pode indicar mudanças nos padrões dos dados que não foram bem capturados pelo modelo, exigindo possíveis ajustes na abordagem utilizada.

A análise do RMSE ao longo do tempo revela que o modelo LSTM apresentou um desempenho variável, com períodos de maior precisão seguidos de momentos de deterioração na qualidade das previsões. A queda do erro no meio de 2023 sugere que, nesse intervalo, o modelo conseguiu capturar melhor os padrões dos dados. No entanto, o aumento significativo do RMSE no início de 2024 indica dificuldades na adaptação do modelo às mudanças recentes, resultando em previsões menos precisas. Embora tenha havido uma leve melhora na última execução, o erro ainda permanece elevado, o que pode indicar a necessidade de ajustes no modelo, seja por meio de refinamento dos hiperparâmetros, aumento da quantidade de dados de treinamento ou experimentação com arquiteturas alternativas que serão testadas ao decorrer deste trabalho.

## **4.2 Modelo GRU Default**

Outros testes foram realizados com o modelo GRU. Foi utilizado todo o período do dataset, sendo utilizada a ação da Ambev (ABEV3), obtendo os dados da empresa através da API do Yahoo Finance, considerando o intervalo de 01/05/2005 até 09/12/2024 com o intuito de obter os próximos 22 dias úteis de previsão. O resultado para este período é demonstrado na Figura 19.



**Figura 19 - Gráfico das previsões de todo período, modelo GRU default (Fonte: Autor).**

Os pontos destacados no final do gráfico representam as previsões do modelo. Os valores reais estão indicados em laranja, enquanto os valores previstos pelo modelo GRU estão marcados em verde. Os resultados mostram uma tendência de leve queda nos valores futuros reais, já os preços dos valores de previsão ao longo do período previsto tiveram uma alta de preço. Isso sugere que o modelo não conseguiu identificar o comportamento na série histórica, projetando uma previsão contrária da movimentação dos valores reais, os resultados de previsão estão expostos na Tabela 11.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,33    | 13,52 |
| 11/12/2024 | 13,51    | 13,08 |
| 12/12/2024 | 13,69    | 12,42 |
| 13/12/2024 | 13,88    | 12,4  |
| 16/12/2024 | 14,09    | 12,17 |
| 17/12/2024 | 14,30    | 12,42 |
| 18/12/2024 | 14,51    | 12,09 |
| 19/12/2024 | 14,73    | 12,11 |
| 20/12/2024 | 14,94    | 12,23 |
| 23/12/2024 | 15,14    | 12,22 |
| 24/12/2024 | 15,32    | 12,22 |
| 25/12/2024 | 15,49    | 12,22 |
| 26/12/2024 | 15,64    | 12,14 |
| 27/12/2024 | 15,77    | 12,07 |
| 30/12/2024 | 15,88    | 11,74 |
| 31/12/2024 | 15,97    | 11,74 |
| 01/01/2025 | 16,04    | 11,6  |
| 02/01/2025 | 16,10    | 11,6  |
| 03/01/2025 | 16,14    | 11,33 |
| 06/01/2025 | 16,16    | 11,29 |

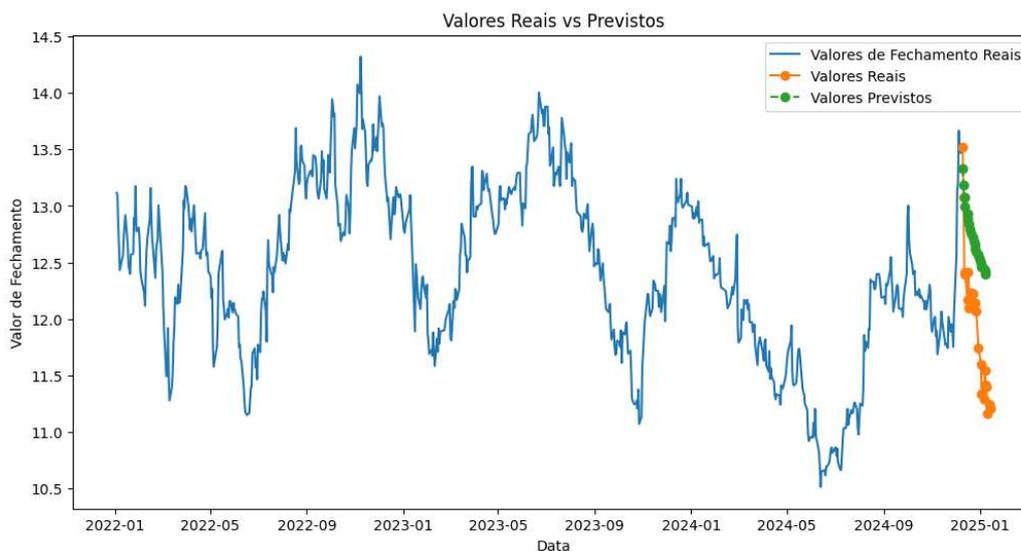
|            |       |       |
|------------|-------|-------|
| 07/01/2025 | 16,17 | 11,54 |
| 08/01/2025 | 16,18 | 11,42 |

**Tabela 11 - Resultados de todo período, modelo GRU default (Fonte: Autor).**

A comparação das previsões do modelo GRU com os valores reais mostra que o modelo superestimou os resultados ao longo do período analisado. A diferença entre os valores previstos e os reais se acentua conforme os dias avançam, indicando que o modelo apresenta um viés otimista. Enquanto as previsões sugerem uma tendência de crescimento constante, os valores reais mostram uma trajetória mais estável e em patamares inferiores. Além disso, a ausência de reações mais sensíveis às variações reais sinaliza que o modelo está excessivamente suavizado, o que pode limitar sua capacidade de adaptação a mudanças abruptas no comportamento da série temporal.

O RMSE das previsões do teste de todo período do modelo GRU foi de 2,29, indicando um erro médio relativamente alto na previsão do modelo. Esse valor mostra que, em média, as previsões do modelo se desviam dos valores reais nessa magnitude. A análise da tabela reforça essa conclusão, uma vez que os valores previstos se mantêm consistentemente acima dos reais ao longo do período. Essa discrepância sugere que o modelo pode estar captando tendências de longo prazo, mas sem precisão para representar oscilações reais dos dados. Uma análise mais profunda poderia investigar se essa diferença decorre do excesso de suavização do modelo ou necessidade de refinar dados de entrada e parâmetros utilizados no treinamento, para isso foi realizado teste com os últimos 3 anos antes da última data registrada, apresentado na Figura 20.

Os pontos destacados no final do gráfico representam as previsões do modelo, demonstrando que no teste dos últimos 3 anos antes da última data registrada, conseguiu captar melhor a tendência do preço de fechamento. Os valores reais estão indicados em laranja, enquanto os valores previstos pelo modelo GRU estão marcados em verde. Isso sugere que o modelo teve uma melhora significativa ao identificar o comportamento na série histórica, projetando uma previsão baixista dos valores previstos, os mesmos estão expostos na Tabela 12.



**Figura 20 - Gráfico das previsões de 3 anos, modelo GRU default (Fonte: Autor).**

A análise dos resultados do teste de três anos antes da última data registrada para o modelo GRU revelou um desempenho significativamente melhor em comparação ao teste de todo o período. O RMSE obtido nesse intervalo foi de 0,86, um valor consideravelmente inferior ao RMSE de 2,29 registrado para todo o período analisado. Essa diferença sugere que o modelo GRU consegue capturar melhor os padrões específicos dos últimos três anos, resultando em previsões mais precisas.

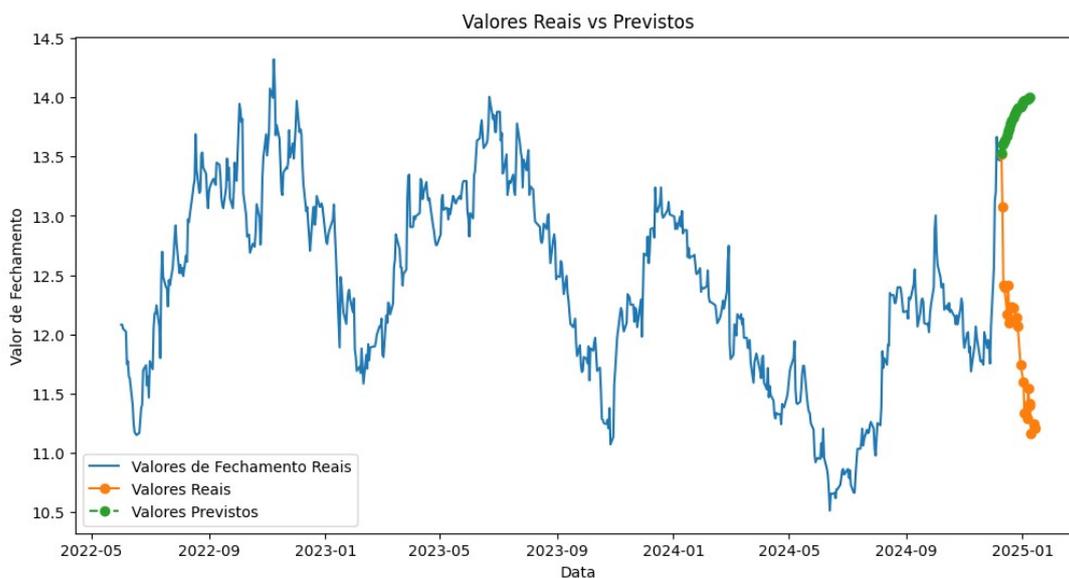
A tabela de valores reais e previstos reforça essa observação, pois os valores estimados pelo modelo apresentam menor dispersão em relação aos valores reais. Embora ainda existam pequenas discrepâncias entre as previsões e os valores observados, a proximidade dos números indica que o modelo conseguiu acompanhar as variações do mercado com um grau de erro reduzido. O fato de o RMSE ser maior no teste de todo o período sugere que, ao analisar um intervalo de tempo mais extenso, o modelo encontrou maior dificuldade para generalizar e capturar tendências ao longo dos anos. Isso pode estar associado a mudanças estruturais nos dados ou a variações de comportamento ao longo do tempo que afetam a previsibilidade. O desempenho mais consistente nos últimos três anos indica que o GRU pode ter maior eficácia quando aplicado a períodos mais recentes, especialmente se os dados mantiverem padrões similares aos identificados nesse intervalo.

| Data | Previsão | Real |
|------|----------|------|
|------|----------|------|

|            |       |       |
|------------|-------|-------|
| 10/12/2024 | 13,34 | 13,52 |
| 11/12/2024 | 13,18 | 13,08 |
| 12/12/2024 | 13,07 | 12,42 |
| 13/12/2024 | 12,99 | 12,4  |
| 16/12/2024 | 12,93 | 12,17 |
| 17/12/2024 | 12,88 | 12,42 |
| 18/12/2024 | 12,84 | 12,09 |
| 19/12/2024 | 12,80 | 12,11 |
| 20/12/2024 | 12,76 | 12,23 |
| 23/12/2024 | 12,73 | 12,22 |
| 24/12/2024 | 12,69 | 12,22 |
| 25/12/2024 | 12,66 | 12,22 |
| 26/12/2024 | 12,63 | 12,14 |
| 27/12/2024 | 12,59 | 12,07 |
| 30/12/2024 | 12,57 | 11,74 |
| 31/12/2024 | 12,54 | 11,74 |
| 01/01/2025 | 12,51 | 11,6  |
| 02/01/2025 | 12,49 | 11,6  |
| 03/01/2025 | 12,46 | 11,33 |
| 06/01/2025 | 12,44 | 11,29 |
| 07/01/2025 | 12,42 | 11,54 |
| 08/01/2025 | 12,40 | 11,42 |

**Tabela 12 - Resultados de 3 anos, modelo GRU default (Fonte: Autor).**

Os resultados do teste realizado para o período de 2 anos e 6 meses antes da última data registrada do modelo GRU(Figura 21 e Tabela 13) apresentaram um RMSE de 2,02.



**Figura 21 - Gráfico das previsões de 2 anos e 6 meses, modelo GRU default (Fonte: Autor).**

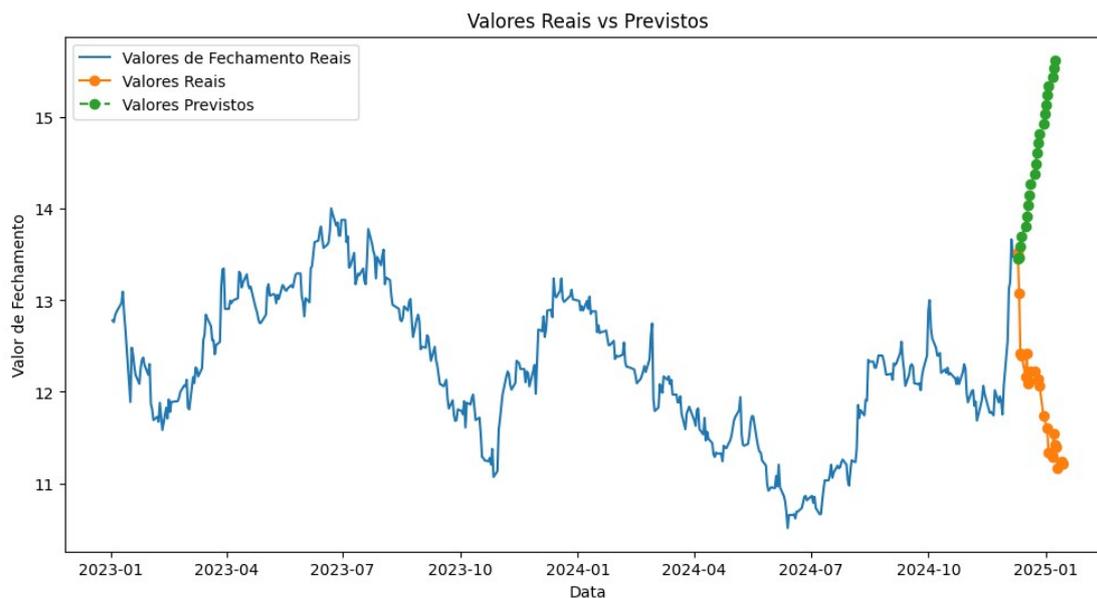
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,53    | 13,52 |

|            |       |       |
|------------|-------|-------|
| 11/12/2024 | 13,60 | 13,08 |
| 12/12/2024 | 13,62 | 12,42 |
| 13/12/2024 | 13,64 | 12,4  |
| 16/12/2024 | 13,67 | 12,17 |
| 17/12/2024 | 13,71 | 12,42 |
| 18/12/2024 | 13,74 | 12,09 |
| 19/12/2024 | 13,78 | 12,11 |
| 20/12/2024 | 13,81 | 12,23 |
| 23/12/2024 | 13,83 | 12,22 |
| 24/12/2024 | 13,86 | 12,22 |
| 25/12/2024 | 13,88 | 12,22 |
| 26/12/2024 | 13,89 | 12,14 |
| 27/12/2024 | 13,91 | 12,07 |
| 30/12/2024 | 13,93 | 11,74 |
| 31/12/2024 | 13,94 | 11,74 |
| 01/01/2025 | 13,95 | 11,6  |
| 02/01/2025 | 13,96 | 11,6  |
| 03/01/2025 | 13,97 | 11,33 |
| 06/01/2025 | 13,98 | 11,29 |
| 07/01/2025 | 13,99 | 11,54 |
| 08/01/2025 | 14,00 | 11,42 |

**Tabela 13 - Resultados de 2 anos e 6 meses, modelo GRU default (Fonte: Autor).**

O valor do RMSE ficou abaixo do teste de todo o período, que foi de 2,29, indicando uma leve melhora na precisão das previsões ao considerar um intervalo de tempo reduzido. No entanto, quando comparado ao teste dos últimos 3 anos antes da última data registrada, cujo RMSE foi de 0,86, observa-se um aumento significativo no erro. Esse contraste sugere que o modelo teve um desempenho mais consistente e preciso no período de 3 anos, mas apresentou uma queda na qualidade da previsão ao analisar o intervalo de 2 anos e 6 meses. A variação dos erros pode estar associada a mudanças na volatilidade dos dados ao longo do tempo ou à capacidade do modelo de capturar padrões específicos em diferentes períodos.

Os resultados do teste realizado para os últimos 2 anos antes da última data registrada no modelo GRU (Figura 22 e Tabela 14) apresentaram um RMSE de 2,88.



**Figura 22 - Gráfico das previsões de 2 anos, modelo GRU default (Fonte: Autor).**

O valor de 2,88 é superior ao erro médio registrado no teste considerando todo o período, que foi de 2,29. Essa diferença indica que, ao restringir a análise a esse intervalo mais recente, o modelo apresentou um desempenho inferior em termos de precisão.

Além disso, o RMSE de 2 anos também foi maior quando comparado ao teste feito para os últimos 3 anos, que obteve um erro consideravelmente menor de 0,86, evidenciando que o modelo teve um desempenho significativamente melhor ao considerar um período mais longo.

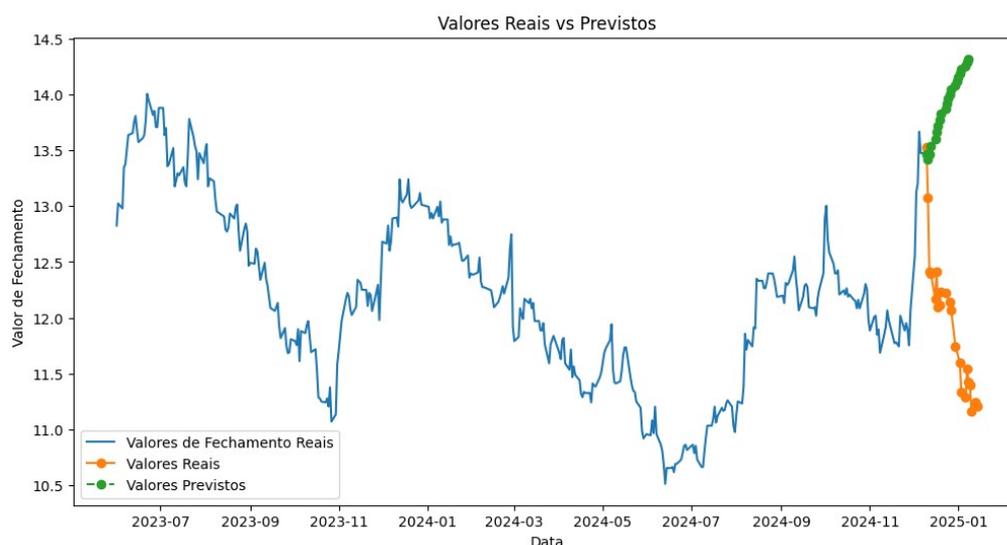
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,45    | 13,52 |
| 11/12/2024 | 13,46    | 13,08 |
| 12/12/2024 | 13,59    | 12,42 |
| 13/12/2024 | 13,70    | 12,4  |
| 16/12/2024 | 13,81    | 12,17 |
| 17/12/2024 | 13,92    | 12,42 |
| 18/12/2024 | 14,04    | 12,09 |
| 19/12/2024 | 14,15    | 12,11 |
| 20/12/2024 | 14,27    | 12,23 |
| 23/12/2024 | 14,38    | 12,22 |
| 24/12/2024 | 14,50    | 12,22 |
| 25/12/2024 | 14,61    | 12,22 |
| 26/12/2024 | 14,72    | 12,14 |

|            |       |       |
|------------|-------|-------|
| 27/12/2024 | 14,83 | 12,07 |
| 30/12/2024 | 14,93 | 11,74 |
| 31/12/2024 | 15,04 | 11,74 |
| 01/01/2025 | 15,14 | 11,6  |
| 02/01/2025 | 15,24 | 11,6  |
| 03/01/2025 | 15,34 | 11,33 |
| 06/01/2025 | 15,44 | 11,29 |
| 07/01/2025 | 15,54 | 11,54 |
| 08/01/2025 | 15,63 | 11,42 |

**Tabela 14 - Resultados de 2 anos, modelo GRU default (Fonte: Autor).**

Comparando com o teste realizado para os últimos 2 anos e 6 meses, que apresentou um RMSE de 2,02, observa-se que houve um aumento no erro ao reduzir ainda mais o intervalo analisado para 2 anos, sugerindo que a capacidade preditiva do modelo pode estar sendo mais afetada à medida que a análise se concentra nos dados mais recentes. Esse comportamento pode indicar uma maior volatilidade ou mudanças nas características dos dados ao longo do tempo, impactando a eficácia do modelo em prever corretamente os valores dentro dessas janelas temporais mais curtas.

A análise dos resultados do teste de 1 ano e 6 meses antes da última data registrada do modelo GRU (Figura 23 e Tabela 15) revelou um RMSE de 2,15, o que indica um desempenho melhor em relação ao teste de todo o período do modelo, que obteve um RMSE de 2,29.



**Figura 23 – Gráficos das previsões de 1 ano e 6 meses, modelo GRU default (Fonte: Autor).**

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,46    | 13,52 |

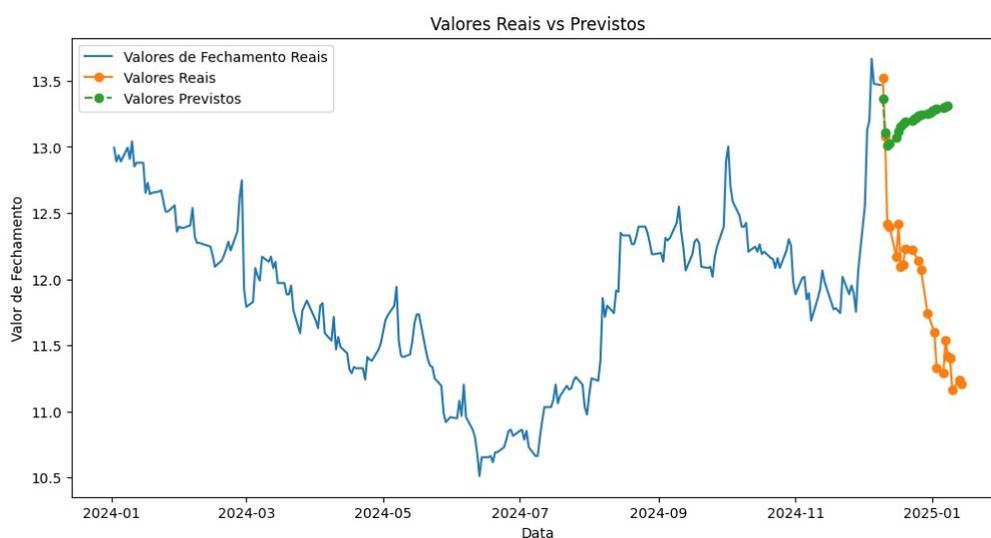
|            |       |       |
|------------|-------|-------|
| 11/12/2024 | 13,42 | 13,08 |
| 12/12/2024 | 13,47 | 12,42 |
| 13/12/2024 | 13,54 | 12,4  |
| 16/12/2024 | 13,60 | 12,17 |
| 17/12/2024 | 13,66 | 12,42 |
| 18/12/2024 | 13,72 | 12,09 |
| 19/12/2024 | 13,77 | 12,11 |
| 20/12/2024 | 13,82 | 12,23 |
| 23/12/2024 | 13,87 | 12,22 |
| 24/12/2024 | 13,92 | 12,22 |
| 25/12/2024 | 13,96 | 12,22 |
| 26/12/2024 | 14,00 | 12,14 |
| 27/12/2024 | 14,04 | 12,07 |
| 30/12/2024 | 14,08 | 11,74 |
| 31/12/2024 | 14,12 | 11,74 |
| 01/01/2025 | 14,16 | 11,6  |
| 02/01/2025 | 14,19 | 11,6  |
| 03/01/2025 | 14,23 | 11,33 |
| 06/01/2025 | 14,26 | 11,29 |
| 07/01/2025 | 14,29 | 11,54 |
| 08/01/2025 | 14,32 | 11,42 |

**Tabela 15 - Resultados de 1 ano e 6 meses, modelo GRU default (Fonte: Autor).**

Quando comparado ao teste realizado para os últimos 3 anos, cujo erro foi significativamente menor, de 0,86, observa-se um aumento considerável na taxa de erro, sugerindo que o modelo teve maior precisão ao considerar um período mais longo. No entanto, em relação ao teste dos últimos 2 anos e 6 meses, que apresentou um RMSE de 2,02, o desempenho do teste mais recente foi ligeiramente inferior, apontando um leve aumento no erro. Já em relação ao teste dos últimos 2 anos, cujo RMSE foi de 2,88, o desempenho do modelo no teste de 1 ano e 6 meses foi mais favorável, demonstrando uma melhora na precisão das previsões. Essas variações indicam que a performance do modelo oscila conforme a janela de tempo utilizada, sugerindo que fatores sazonais ou mudanças nos padrões dos dados podem influenciar a capacidade preditiva do modelo.

A Figura 24 e Tabela 16 apresentam os resultados do teste realizado com o modelo GRU, considerando um período de um ano antes da última data registrada. O objetivo desse teste é avaliar a capacidade do modelo em prever os valores de fechamento ao longo do tempo, comparando as previsões geradas com os valores reais observados. A análise desse desempenho permite verificar a precisão das previsões e identificar possíveis padrões ou desvios entre os valores reais e

estimados pelo modelo comparado com os testes anteriores.



**Figura 24 - Gráfico das previsões de 1 ano, modelo GRU default (Fonte: Autor).**

Os resultados do teste realizado um ano antes da última data registrada do modelo GRU demonstram um desempenho interessante, com um RMSE de 1,42. Esse valor é inferior ao RMSE obtido ao longo de todo o período de teste do modelo, que foi de 2,29, indicando uma melhora significativa na precisão das previsões. Além disso, o RMSE de 1,42 é maior do que o teste dos últimos três anos, que apresentou um valor de 0,86, evidenciando que, embora tenha havido uma melhoria em relação ao desempenho geral, ainda há espaço para aprimoramento em comparação a períodos mais longos.

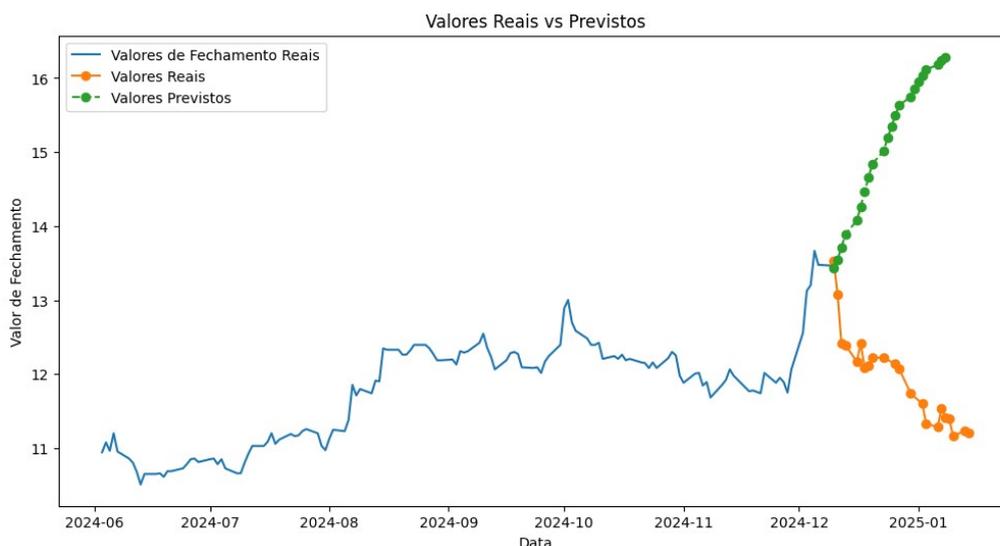
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,36    | 13,52 |
| 11/12/2024 | 13,11    | 13,08 |
| 12/12/2024 | 13,01    | 12,42 |
| 13/12/2024 | 13,02    | 12,4  |
| 16/12/2024 | 13,07    | 12,17 |
| 17/12/2024 | 13,12    | 12,42 |
| 18/12/2024 | 13,15    | 12,09 |
| 19/12/2024 | 13,17    | 12,11 |
| 20/12/2024 | 13,19    | 12,23 |
| 23/12/2024 | 13,20    | 12,22 |
| 24/12/2024 | 13,21    | 12,22 |
| 25/12/2024 | 13,22    | 12,22 |
| 26/12/2024 | 13,23    | 12,14 |
| 27/12/2024 | 13,24    | 12,07 |
| 30/12/2024 | 13,25    | 11,74 |
| 31/12/2024 | 13,26    | 11,74 |
| 01/01/2025 | 13,27    | 11,6  |

|            |       |       |
|------------|-------|-------|
| 02/01/2025 | 13,28 | 11,6  |
| 03/01/2025 | 13,29 | 11,33 |
| 06/01/2025 | 13,29 | 11,29 |
| 07/01/2025 | 13,30 | 11,54 |
| 08/01/2025 | 13,31 | 11,42 |

**Tabela 16 - Resultados de 1 ano, modelo GRU default (Fonte: Autor).**

Em uma análise mais detalhada, o teste realizado nos últimos dois anos e seis meses teve um RMSE de 2,02, que, embora seja melhor que o teste do último ano, ainda é menos preciso do que a média dos últimos três anos. O desempenho nos últimos dois anos apresentou um RMSE de 2,88, indicando aumento nos erros de previsão, enquanto o teste do último ano e meio ficou em 2,15, apontando leve melhora em relação a dois anos. Essa comparação ressalta a variabilidade do desempenho do modelo GRU ao longo do tempo, sugerindo que, embora tenha havido progressos significativos, requer refinamentos e ajustes no modelo para alcançar um nível de precisão mais consistente. A análise dos dados evidencia a importância de revisar os hiperparâmetros, métodos de previsão e considerar fatores externos que possam influenciar o desempenho das previsões, para garantir que o modelo se mantenha relevante e eficaz nas suas projeções futuras.

Para saber se as previsões de 1 ano antes da última data registrada não foram uma exceção, realizamos o teste com os últimos 6 meses antes da última data registrada; estes resultados são ilustrados na Figura 25 e Tabela 17. Os resultados do modelo GRU revelam um RMSE de 3,49; significativamente maior em comparação a diversos períodos de teste anteriores. Esse valor é superior ao RMSE obtido ao longo de todo o período do modelo, que foi de 2,29, indicando queda na precisão das previsões. Além disso, o desempenho do modelo nos últimos três anos apresentou um RMSE de 0,86, sugerindo que o modelo tem se mostrado bastante eficaz em previsões de longo prazo.



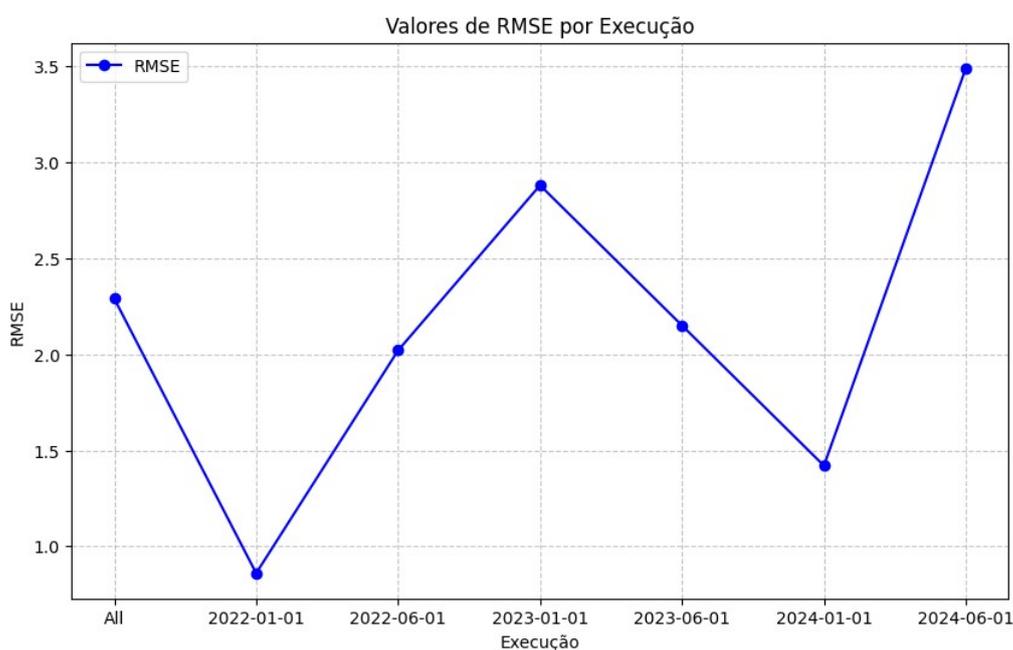
**Figura 25 - Gráfico das previsões de 6 meses, modelo GRU default (Fonte: Autor).**

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,43    | 13,52 |
| 11/12/2024 | 13,55    | 13,08 |
| 12/12/2024 | 13,71    | 12,42 |
| 13/12/2024 | 13,89    | 12,4  |
| 16/12/2024 | 14,07    | 12,17 |
| 17/12/2024 | 14,27    | 12,42 |
| 18/12/2024 | 14,46    | 12,09 |
| 19/12/2024 | 14,65    | 12,11 |
| 20/12/2024 | 14,84    | 12,23 |
| 23/12/2024 | 15,02    | 12,22 |
| 24/12/2024 | 15,19    | 12,22 |
| 25/12/2024 | 15,35    | 12,22 |
| 26/12/2024 | 15,5     | 12,14 |
| 27/12/2024 | 15,63    | 12,07 |
| 30/12/2024 | 15,75    | 11,74 |
| 31/12/2024 | 15,86    | 11,74 |
| 01/01/2025 | 15,95    | 11,6  |
| 02/01/2025 | 16,04    | 11,6  |
| 03/01/2025 | 16,11    | 11,33 |
| 06/01/2025 | 16,18    | 11,29 |
| 07/01/2025 | 16,24    | 11,54 |
| 08/01/2025 | 16,28    | 11,42 |

**Tabela 17 - Resultados de 6 meses, modelo GRU default (Fonte: Autor).**

Analisando os dados mais a fundo, o teste realizado nos últimos dois anos e seis meses apresentou um RMSE de 2,02, o que também foi superior ao desempenho nos últimos dois anos, que teve um RMSE de 2,88. O teste do último ano e seis meses resultou em um RMSE de 2,15, o que demonstra uma ligeira melhoria em relação ao teste de dois anos, mas ainda assim inferior ao

desempenho do último ano, que obteve um RMSE de 1,42. Esses resultados indicam que, embora o modelo GRU tenha apresentado uma performance aceitável em períodos anteriores, o teste mais recente de seis meses revela um aumento nos erros de previsão, o que pode sugerir a necessidade de ajustes e melhorias na metodologia utilizada. Essa comparação destaca a importância de monitorar continuamente a precisão das previsões e implementar refinamentos no modelo e ajustes nos hiperparâmetros, para que se mantenha relevante e eficaz em suas projeções, especialmente em contextos em que a volatilidade e a incerteza podem impactar diretamente os resultados.



**Figura 26 - Gráfico dos resultados de RMSE, modelo GRU default (Fonte: Autor).**

Os resultados dos RMSE dos testes realizados em diferentes períodos para o modelo GRU revelam uma variação significativa na precisão das previsões ao longo do tempo. O RMSE para todo o período do modelo foi de 2,29, refletindo uma performance geral que, embora aceitável, demonstra espaço para melhorias. Em contrapartida, o teste realizado nos últimos três anos apresentou um RMSE notavelmente mais baixo, de 0,86, indicando que, ao longo desse intervalo, o modelo conseguiu oferecer previsões mais precisas e consistentes. Ao considerar o desempenho nos últimos dois anos e seis meses, o RMSE subiu para 2,02, mostrando que, apesar de uma leve deterioração na precisão, o modelo ainda se mantinha relativamente eficaz. O teste realizado nos últimos dois anos trouxe um RMSE de 2,88, o que representa uma queda na acurácia em relação aos períodos

anteriores. Já no teste de um ano e seis meses, o RMSE foi de 2,15, indicando uma melhora em comparação ao período de dois anos, mas ainda inferior ao desempenho registrado nos últimos três anos.

O teste de um ano resultou em um RMSE de 1,42, o que destaca um desempenho superior em termos de precisão nas previsões. Por último, o teste realizado seis meses antes da última data registrada apresentou um RMSE de 3,49, o que foi uma surpresa negativa, sendo o mais alto entre todos os períodos analisados. Essa análise dos RMSE evidencia não apenas as flutuações na eficácia do modelo ao longo do tempo, mas também a importância de revisões constantes e ajustes no modelo para garantir que ele permaneça confiável e eficaz em suas previsões, especialmente em um cenário onde a precisão é crucial.

### **4.3 Modelo LSTM+GRU Default**

Com base na análise dos resultados apresentados dos modelos LSTM e GRU compreendem-se que cada um tem suas limitações individuais, visando esta limitação foi realizado a criação de uma arquitetura híbrida que combine elementos dessas duas redes neurais. A abordagem híbrida visa aproveitar os benefícios complementares de cada modelo, potencializando a precisão das previsões e mitigando possíveis pontos fracos de cada modelo. A integração de ambas as arquiteturas pode proporcionar uma solução mais robusta e confiável para a previsão de movimentos de preços no mercado financeiro, abrindo caminho para avanços significativos na área de análise preditiva.

A ideia foi criar este modelo híbrido com sua primeira camada com 50 neurônios de arquitetura GRU com um dropout de 20%, seguida da segunda camada com mais 50 neurônios de arquitetura LSTM com um dropout de 20%. A terceira camada será composta por 50 neurônios de arquitetura GRU com dropout de 20%, sendo acompanhada com uma camada densa, após o último dropout de 20%. A Figura 27 apresenta as previsões geradas pelo modelo de todo o período do dataset, utilizando a ação da Ambev (ABEV3), obtendo os dados da empresa através da API do Yahoo Finance, considerando o intervalo de 01/05/2005 até 09/12/2024.



**Figura 27 - Gráfico das previsões de todo período, modelo LSTM+GRU default (Fonte: Autor).**

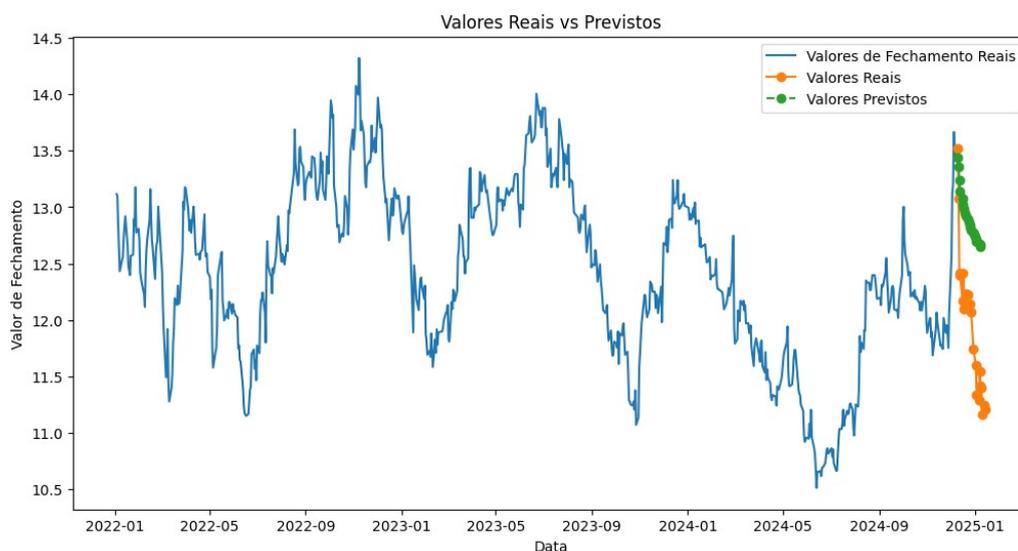
Os pontos destacados no final do gráfico representam previsões do modelo híbrido. Os valores reais estão em laranja, enquanto os valores previstos pelo modelo estão em verde. O resultado pode ser observado numericamente na Tabela 18.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,47    | 13,52 |
| 11/12/2024 | 13,31    | 13,08 |
| 12/12/2024 | 13,11    | 12,42 |
| 13/12/2024 | 12,96    | 12,4  |
| 16/12/2024 | 12,82    | 12,17 |
| 17/12/2024 | 12,69    | 12,42 |
| 18/12/2024 | 12,56    | 12,09 |
| 19/12/2024 | 12,44    | 12,11 |
| 20/12/2024 | 12,32    | 12,23 |
| 23/12/2024 | 12,20    | 12,22 |
| 24/12/2024 | 12,09    | 12,22 |
| 25/12/2024 | 11,98    | 12,22 |
| 26/12/2024 | 11,87    | 12,14 |
| 27/12/2024 | 11,76    | 12,07 |
| 30/12/2024 | 11,65    | 11,74 |
| 31/12/2024 | 11,54    | 11,74 |
| 01/01/2025 | 11,44    | 11,6  |
| 02/01/2025 | 11,34    | 11,6  |
| 03/01/2025 | 11,24    | 11,33 |
| 06/01/2025 | 11,14    | 11,29 |
| 07/01/2025 | 11,04    | 11,54 |
| 08/01/2025 | 10,95    | 11,42 |

**Tabela 18 - Resultados de todo período, modelo LSTM+GRU default (Fonte: Autor).**

O RMSE obtido para o resultado de todo o período foi de 0,31, indicando um desempenho menor e significativamente mais preciso em comparação com os demais testes realizados até o momento. Esse valor sugere que o modelo conseguiu captar com excelência a tendência dos dados ao longo do tempo, reduzindo a discrepância entre os valores previstos e os valores reais. Diferente dos testes em períodos menores, onde o RMSE apresentou valores mais elevados, esse resultado demonstra que a modelagem baseada em um conjunto de dados mais abrangente levou a previsões mais estáveis e coerentes. Isso reforça a ideia de que um modelo híbrido pode contribuir para uma melhor generalização do modelo, e evitar desvios expressivos. A menor taxa de erro observada confirma que, para esse caso específico, o uso de todo o período do histórico resultou em maior desempenho e confiabilidade nas previsões.

A observação do comportamento do modelo em diferentes janelas temporais dentro desses três anos pode fornecer insights sobre sua estabilidade e robustez ao longo do tempo, seus resultados são apresentados na Figura 28 e Tabela 19.



**Figura 28 - Gráfico das previsões de 3 anos, modelo LSTM+GRU default (Fonte: Autor).**

A análise do modelo híbrido LSTM e GRU para os últimos três anos antes da última data registrada permite avaliar o desempenho dessa abordagem combinada na previsão dos dados. Esse modelo une as características das redes LSTM, que são eficientes na captura de padrões de longo prazo, com as GRU, que apresentam uma estrutura mais simplificada e podem acelerar o processamento sem comprometer significativamente a precisão. Ao aplicar esse modelo ao período de

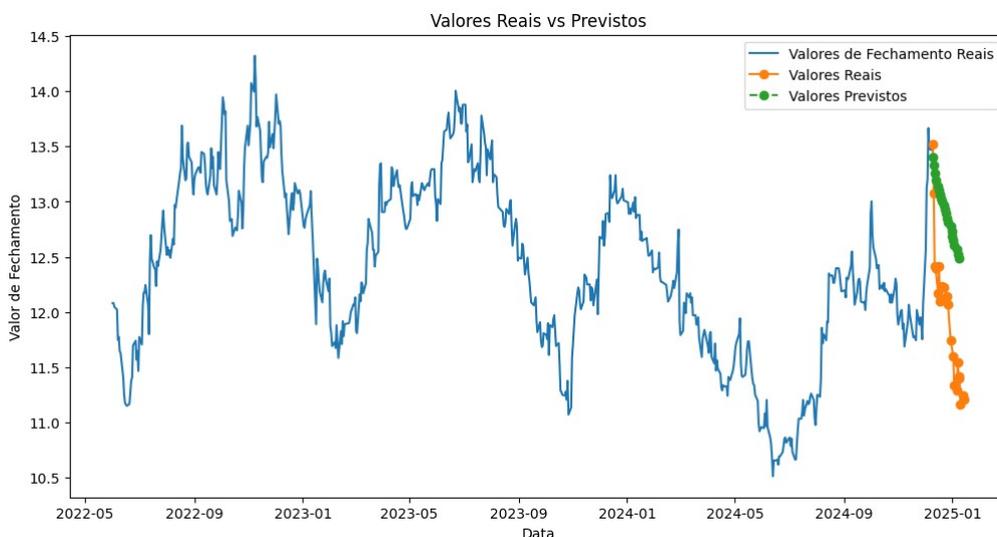
três anos antes da última data registrada, é possível verificar sua capacidade de adaptação às tendências e variações presentes nos dados históricos.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,44    | 13,52 |
| 11/12/2024 | 13,36    | 13,08 |
| 12/12/2024 | 13,24    | 12,42 |
| 13/12/2024 | 13,14    | 12,4  |
| 16/12/2024 | 13,07    | 12,17 |
| 17/12/2024 | 13,03    | 12,42 |
| 18/12/2024 | 12,99    | 12,09 |
| 19/12/2024 | 12,95    | 12,11 |
| 20/12/2024 | 12,92    | 12,23 |
| 23/12/2024 | 12,90    | 12,22 |
| 24/12/2024 | 12,87    | 12,22 |
| 25/12/2024 | 12,84    | 12,22 |
| 26/12/2024 | 12,82    | 12,14 |
| 27/12/2024 | 12,80    | 12,07 |
| 30/12/2024 | 12,78    | 11,74 |
| 31/12/2024 | 12,76    | 11,74 |
| 01/01/2025 | 12,74    | 11,6  |
| 02/01/2025 | 12,72    | 11,6  |
| 03/01/2025 | 12,70    | 11,33 |
| 06/01/2025 | 12,68    | 11,29 |
| 07/01/2025 | 12,66    | 11,54 |
| 08/01/2025 | 12,65    | 11,42 |

**Tabela 19 - Resultados de 3 anos, modelo LSTM+GRU default (Fonte: Autor).**

Com base nos resultados apresentados pela Tabela 19, a comparação entre os RMSEs dos modelos evidencia uma diferença no desempenho entre o teste de todo período e o teste realizado com o modelo híbrido LSTM+GRU. O RMSE de 1,05 do modelo híbrido, embora ainda relativamente baixo, mostra um erro um pouco maior em relação ao RMSE de 0,82 registrado no teste de todo período. Essa diferença pode indicar que o modelo híbrido teve uma leve perda de precisão ao longo da série temporal completa, possivelmente devido a variações nos padrões dos dados ou na forma como a combinação entre LSTM e GRU capturou as tendências e sazonalidades do conjunto analisado. Embora o modelo híbrido tenha apresentado um bom desempenho, o aumento do erro médio sugere que sua capacidade preditiva pode não ter sido tão eficiente quanto à abordagem anterior ao considerar todo o período. Isso pode levantar questões sobre o ajuste do modelo e a necessidade de refinamentos na arquitetura ou nos hiperparâmetros para buscar uma melhor generalização dos padrões históricos.

A análise do desempenho do modelo híbrido LSTM+GRU nos últimos dois anos e seis meses antes da última data registrada (Figura 29 e Tabela 20) busca avaliar sua capacidade de previsão em um período mais recente da série temporal.



**Figura 29 - Predições de 2 anos e 6 meses, modelo LSTM+GRU default (Fonte: Autor).**

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,44    | 13,52 |
| 11/12/2024 | 13,36    | 13,08 |
| 12/12/2024 | 13,24    | 12,42 |
| 13/12/2024 | 13,14    | 12,4  |
| 16/12/2024 | 13,07    | 12,17 |
| 17/12/2024 | 13,03    | 12,42 |
| 18/12/2024 | 12,99    | 12,09 |
| 19/12/2024 | 12,95    | 12,11 |
| 20/12/2024 | 12,92    | 12,23 |
| 23/12/2024 | 12,90    | 12,22 |
| 24/12/2024 | 12,87    | 12,22 |
| 25/12/2024 | 12,84    | 12,22 |
| 26/12/2024 | 12,82    | 12,14 |
| 27/12/2024 | 12,80    | 12,07 |
| 30/12/2024 | 12,78    | 11,74 |
| 31/12/2024 | 12,76    | 11,74 |
| 01/01/2025 | 12,74    | 11,6  |
| 02/01/2025 | 12,72    | 11,6  |
| 03/01/2025 | 12,70    | 11,33 |
| 06/01/2025 | 12,68    | 11,29 |
| 07/01/2025 | 12,66    | 11,54 |
| 08/01/2025 | 12,65    | 11,42 |

**Tabela 20 - Resultados de 2 anos e 6 meses, modelo LSTM+GRU default (Fonte: Autor).**

Esse tipo de teste é fundamental para verificar a adaptabilidade do modelo às tendências mais atuais dos dados, especialmente considerando possíveis

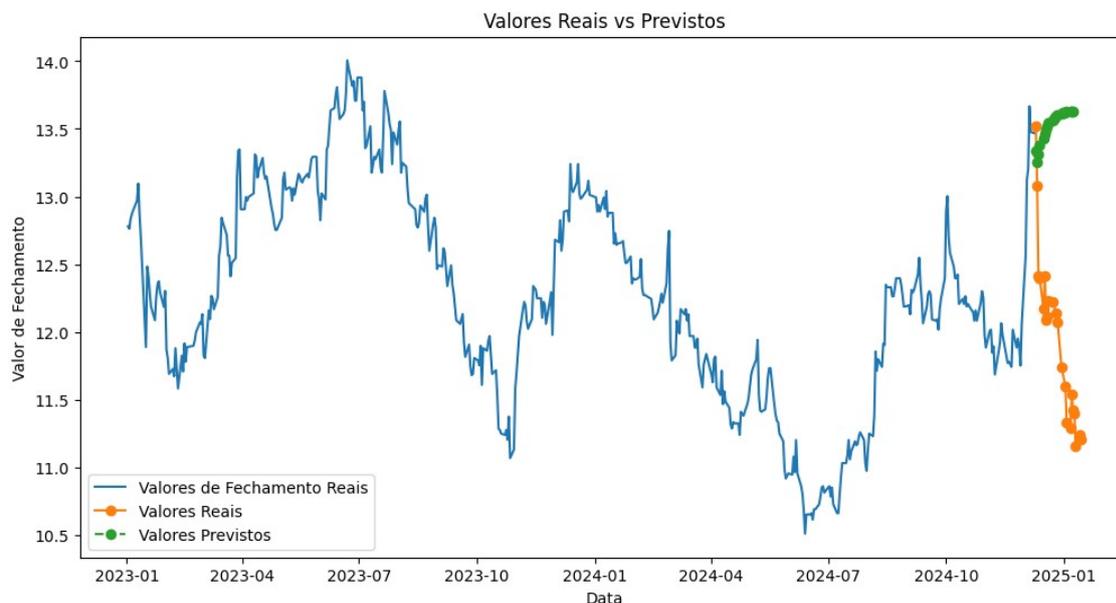
mudanças estruturais ou padrões sazonais que possam ter surgido ao longo do tempo. Comparando com outros testes realizados em períodos diferentes, esse experimento permitirá compreender se o modelo mantém um bom nível de precisão quando se concentra em um intervalo de tempo menor e mais próximo da data final disponível. Além disso, os resultados obtidos poderão indicar se há necessidade de ajustes na arquitetura ou nos hiperparâmetros para melhorar a capacidade preditiva em períodos mais curtos, garantindo um equilíbrio entre aprendizado global e adaptação às variações recentes dos dados.

A análise dos resultados das previsões do modelo híbrido LSTM+GRU revela uma variação na precisão ao longo dos diferentes períodos avaliados. Quando observamos o RMSE, notamos que para o teste de todo o período, o valor foi de 0,82, indicando um desempenho mais preciso do modelo nesse contexto. No entanto, ao analisar os últimos três anos antes da última data registrada, o RMSE aumentou para 1,05, sugerindo uma leve degradação na precisão da previsão mais recente. Já para os últimos dois anos e seis meses antes da última data registrada, o RMSE foi de 1,03, um valor um pouco menor do que o dos últimos três anos, mas ainda superior ao teste de todo o período.

Essa diferença nos valores do RMSE pode indicar que o modelo teve um desempenho mais consistente ao considerar o período completo, possivelmente devido a um maior volume de dados disponíveis para o treinamento. Nos períodos mais recentes, os erros aumentaram, o que pode estar relacionado a mudanças na tendência dos dados que o modelo não capturou com total precisão. Mais testes foram feitos com intervalos de data menores, assim como outros modelos testados a fim de comparar de forma mais clara se as previsões podem melhorar, a Figura 30 e Tabela 21 apresentam o teste com 2 anos antes da última data registrada.

Ao comparar os resultados das previsões realizadas para diferentes períodos antes da última data registrada, observa-se uma variação no desempenho do modelo, refletida nos valores do RMSE. O teste para todo o período apresentou um RMSE de 0,82, indicando um nível de precisão mais alto em relação aos testes segmentados. Já o teste realizado para os últimos três anos antes da última data registrada teve um RMSE de 1,05, revelando um aumento no erro e sugerindo que o modelo teve maior dificuldade em capturar padrões nesse intervalo. Para o período de dois anos e seis meses antes da última data registrada, o RMSE apresentou

redução para 1,03, o que pode indicar que o modelo conseguiu melhorar ligeiramente sua previsão para essa janela de tempo.



**Figura 30 - Gráfico das previsões de 2 anos, modelo LSTM+GRU default (Fonte: Autor).**

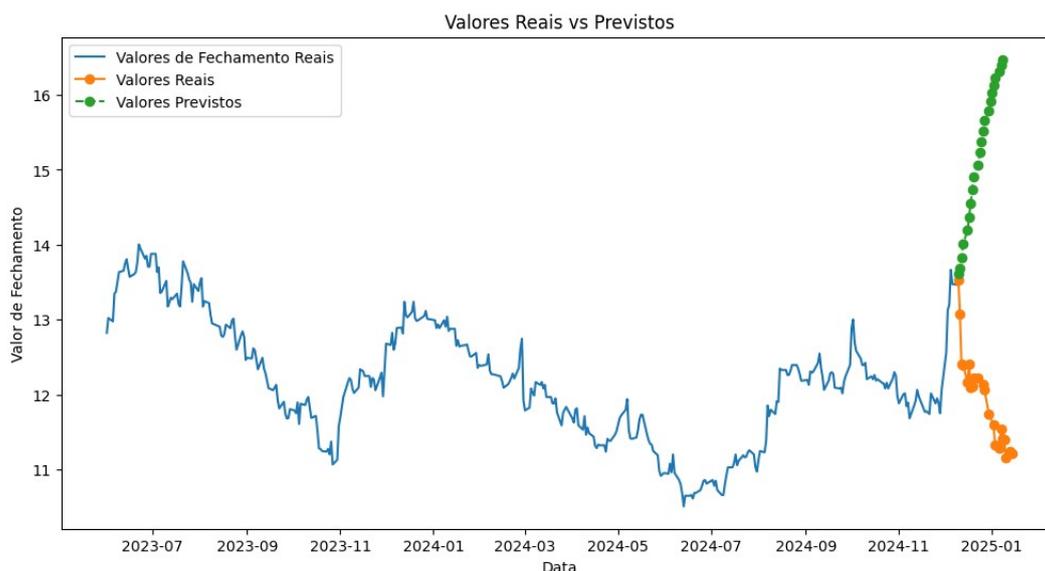
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,34    | 13,52 |
| 11/12/2024 | 13,25    | 13,08 |
| 12/12/2024 | 13,31    | 12,42 |
| 13/12/2024 | 13,38    | 12,4  |
| 16/12/2024 | 13,43    | 12,17 |
| 17/12/2024 | 13,47    | 12,42 |
| 18/12/2024 | 13,50    | 12,09 |
| 19/12/2024 | 13,52    | 12,11 |
| 20/12/2024 | 13,54    | 12,23 |
| 23/12/2024 | 13,56    | 12,22 |
| 24/12/2024 | 13,57    | 12,22 |
| 25/12/2024 | 13,59    | 12,22 |
| 26/12/2024 | 13,60    | 12,14 |
| 27/12/2024 | 13,60    | 12,07 |
| 30/12/2024 | 13,61    | 11,74 |
| 31/12/2024 | 13,62    | 11,74 |
| 01/01/2025 | 13,62    | 11,6  |
| 02/01/2025 | 13,62    | 11,6  |
| 03/01/2025 | 13,62    | 11,33 |
| 06/01/2025 | 13,63    | 11,29 |
| 07/01/2025 | 13,63    | 11,54 |
| 08/01/2025 | 13,63    | 11,42 |

**Tabela 21 - Resultados de 2 anos, modelo LSTM+GRU default (Fonte: Autor).**

No entanto, ao considerar o teste dos últimos dois anos antes da última data registrada, o RMSE subiu para 1,73, representando um aumento significativo no

erro das previsões. Esse crescimento sugere que o modelo enfrenta maior dificuldade em prever corretamente os valores mais recentes, possivelmente devido a mudanças estruturais na série temporal ou variações mais intensas nos dados. Essa diferença nos valores do RMSE entre os períodos pode indicar que o modelo tem melhor desempenho quando avaliado em um horizonte mais amplo, enquanto sua precisão tende a diminuir conforme a janela de previsão se reduz, reforçando a necessidade de ajustes para otimizar a captura das tendências mais recentes.

A análise do RMSE ao longo dos diferentes períodos revela uma variação significativa no desempenho dos modelos utilizados para prever os valores analisados. O RMSE do período completo foi de apenas 0,31, indicando um alto nível de precisão geral. No entanto, ao segmentar os períodos anteriores à última data registrada, observa-se um aumento progressivo no erro, sendo o mais alto registrado no intervalo de 1 ano e 6 meses antes da última data registrada (Figura 31 e Tabela 22), com um RMSE de 3,57. O RMSE de 3 anos antes da última data registrada foi de 1,05, mostrando um desempenho razoavelmente consistente. Para o período de 2 anos e 6 meses antes, o RMSE foi de 1,03, ligeiramente menor, o que indica uma leve melhora na precisão do modelo nesse intervalo. Já o teste de 2 anos antes da última data registrada resultou em um RMSE de 1,73, um aumento em relação ao período de 2 anos e 6 meses, mas ainda dentro de um patamar aceitável.



**Figura 31 - Predições de 1 ano e 6 meses, modelo LSTM+GRU default (Fonte: Autor).**

O valor significativamente mais alto do RMSE no período de 1 ano e 6 meses

antes da última data registrada sugere que o modelo teve dificuldades maiores em capturar os padrões da série temporal nesse intervalo. Isso pode estar relacionado a mudanças estruturais nos dados, maior volatilidade ou menor qualidade das previsões nesse período específico. Esse aumento no erro destaca a importância de avaliar a estabilidade dos modelos ao longo do tempo, reforçando a necessidade de ajustes para períodos mais recentes onde a incerteza parece ser maior.

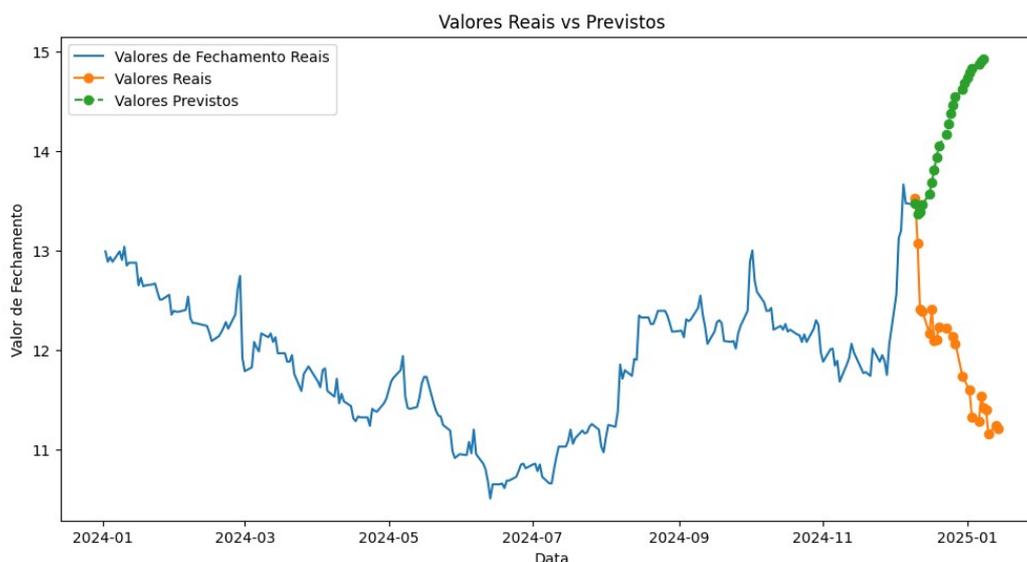
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,34    | 13,52 |
| 11/12/2024 | 13,25    | 13,08 |
| 12/12/2024 | 13,31    | 12,42 |
| 13/12/2024 | 13,38    | 12,4  |
| 16/12/2024 | 13,43    | 12,17 |
| 17/12/2024 | 13,47    | 12,42 |
| 18/12/2024 | 13,50    | 12,09 |
| 19/12/2024 | 13,52    | 12,11 |
| 20/12/2024 | 13,54    | 12,23 |
| 23/12/2024 | 13,56    | 12,22 |
| 24/12/2024 | 13,57    | 12,22 |
| 25/12/2024 | 13,59    | 12,22 |
| 26/12/2024 | 13,60    | 12,14 |
| 27/12/2024 | 13,60    | 12,07 |
| 30/12/2024 | 13,61    | 11,74 |
| 31/12/2024 | 13,62    | 11,74 |
| 01/01/2025 | 13,62    | 11,6  |
| 02/01/2025 | 13,62    | 11,6  |
| 03/01/2025 | 13,62    | 11,33 |
| 06/01/2025 | 13,63    | 11,29 |
| 07/01/2025 | 13,63    | 11,54 |
| 08/01/2025 | 13,63    | 11,42 |

**Tabela 22 - Resultados de 1 ano e 6 meses, modelo LSTM+GRU default (Fonte: Autor).**

A análise dos resultados do RMSE ao longo do tempo oferece uma visão interessante sobre a precisão dos modelos de previsão utilizados. O RMSE de 2,54 para o último ano (Figura 32 e Tabela 23) indica uma precisão moderada, que, embora não ideal, está dentro de um intervalo aceitável para muitas aplicações.

Quando comparamos esse valor ao RMSE de 3,57, obtido para um período de dois anos e seis meses, podemos notar uma leve melhora na precisão. Isso sugere que, ao longo do último ano, os modelos foram capazes de captar melhor as nuances dos dados, resultando em previsões mais próximas dos valores reais. No entanto, ainda há espaço para melhorias, especialmente quando consideramos o RMSE de 0,31, que é significativamente menor e reflete uma previsão muito mais

precisa ao longo de um período mais extenso. A comparação com os RMSE de três anos antes da última data registrada 1,05 e do teste de dois anos e seis meses antes da última data 1,03 mostra que o modelo atual não conseguiu superar as previsões anteriores, que tiveram um desempenho melhor. Além disso, o RMSE de 1,73 para o teste de dois anos antes da última data também evidencia que os modelos anteriores estavam mais ajustados aos dados, proporcionando previsões mais acuradas.



**Figura 32 - Gráfico das previsões de 1 ano, modelo LSTM+GRU default (Fonte: Autor).**

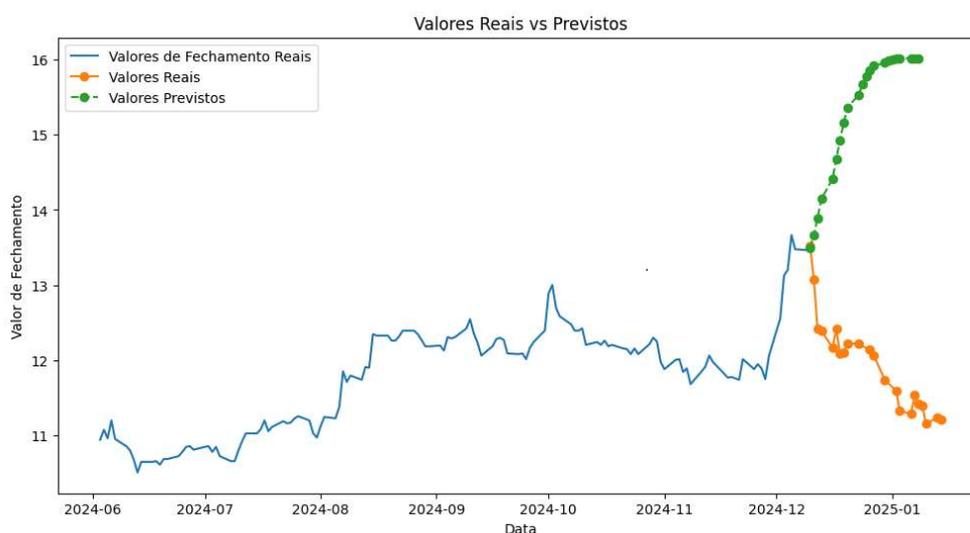
| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,47    | 13,52 |
| 11/12/2024 | 13,37    | 13,08 |
| 12/12/2024 | 13,39    | 12,42 |
| 13/12/2024 | 13,47    | 12,4  |
| 16/12/2024 | 13,57    | 12,17 |
| 17/12/2024 | 13,69    | 12,42 |
| 18/12/2024 | 13,81    | 12,09 |
| 19/12/2024 | 13,94    | 12,11 |
| 20/12/2024 | 14,06    | 12,23 |
| 23/12/2024 | 14,17    | 12,22 |
| 24/12/2024 | 14,28    | 12,22 |
| 25/12/2024 | 14,38    | 12,22 |
| 26/12/2024 | 14,47    | 12,14 |
| 27/12/2024 | 14,55    | 12,07 |
| 30/12/2024 | 14,62    | 11,74 |
| 31/12/2024 | 14,68    | 11,74 |
| 01/01/2025 | 14,74    | 11,6  |
| 02/01/2025 | 14,79    | 11,6  |
| 03/01/2025 | 14,83    | 11,33 |
| 06/01/2025 | 14,87    | 11,29 |

|            |       |       |
|------------|-------|-------|
| 07/01/2025 | 14,90 | 11,54 |
| 08/01/2025 | 14,93 | 11,42 |

**Tabela 23 - Resultados de 1 ano, modelo LSTM+GRU default (Fonte: Autor).**

Essas observações indicam que, embora haja uma melhoria em relação ao período mais recente, os resultados ainda estão aquém do que foi alcançado em períodos anteriores. Isso pode sugerir a necessidade de revisar e potencialmente ajustar os modelos de previsão, levando em conta novas variáveis ou técnicas que possam melhorar a precisão e a robustez das previsões futuras. A análise de RMSE, portanto, não apenas fornece uma medida de erro, mas também pode orientar decisões sobre a evolução e o aprimoramento das metodologias de previsão.

A análise dos últimos seis meses (Figura 33 e Tabela 24) revelou um RMSE de 3,63, o maior erro registrado em comparação com todos os outros testes realizados utilizando o modelo LSTM+GRU.



**Figura 33 - Gráfico das previsões de 6 meses, modelo LSTM+GRU default (Fonte: Autor).**

Esse resultado sugere que, nesse período mais recente, o modelo encontrou maior dificuldade para capturar corretamente os padrões dos dados, o que pode estar associado a uma maior volatilidade ou mudanças nas tendências que não foram bem assimiladas pelo treinamento.

Quando comparamos esse valor com os RMSE obtidos em períodos mais longos, fica evidente que o desempenho do modelo foi superior em janelas temporais mais amplas. Isso pode indicar que o LSTM+GRU teve um melhor ajuste

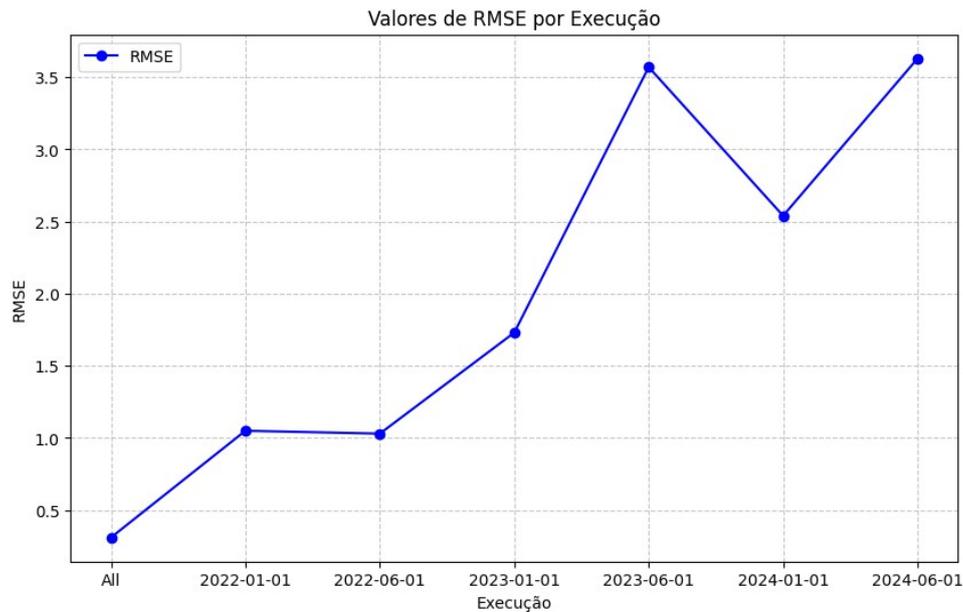
quando trabalhou com um volume maior de informações históricas, conseguindo extrair padrões mais consistentes ao longo do tempo. Por outro lado, no horizonte reduzido de seis meses, a previsão pode ter sido mais sensível a ruídos ou variações inesperadas que comprometeram a precisão.

| Data       | Previsão | Real  |
|------------|----------|-------|
| 10/12/2024 | 13,47    | 13,52 |
| 11/12/2024 | 13,37    | 13,08 |
| 12/12/2024 | 13,39    | 12,42 |
| 13/12/2024 | 13,47    | 12,4  |
| 16/12/2024 | 13,57    | 12,17 |
| 17/12/2024 | 13,69    | 12,42 |
| 18/12/2024 | 13,81    | 12,09 |
| 19/12/2024 | 13,94    | 12,11 |
| 20/12/2024 | 14,06    | 12,23 |
| 23/12/2024 | 14,17    | 12,22 |
| 24/12/2024 | 14,28    | 12,22 |
| 25/12/2024 | 14,38    | 12,22 |
| 26/12/2024 | 14,47    | 12,14 |
| 27/12/2024 | 14,55    | 12,07 |
| 30/12/2024 | 14,62    | 11,74 |
| 31/12/2024 | 14,68    | 11,74 |
| 01/01/2025 | 14,74    | 11,6  |
| 02/01/2025 | 14,79    | 11,6  |
| 03/01/2025 | 14,83    | 11,33 |
| 06/01/2025 | 14,87    | 11,29 |
| 07/01/2025 | 14,90    | 11,54 |
| 08/01/2025 | 14,93    | 11,42 |

**Tabela 24 - Resultados de 6 meses, modelo LSTM+GRU default (Fonte: Autor).**

Esse resultado reforça a importância de avaliar continuamente o comportamento do modelo em diferentes janelas temporais, pois, enquanto períodos mais longos podem fornecer previsões mais estáveis, períodos curtos podem exigir ajustes específicos, como uma revisão nos hiperparâmetros ou até mesmo a inclusão de novas variáveis que melhor representem as dinâmicas recentes do conjunto de dados.

A análise dos valores de RMSE apresentados na Figura 34 mostra uma evolução no erro do modelo híbrido LSTM+GRU ao longo do tempo. No período completo, o erro foi relativamente baixo, indicando um bom desempenho geral. No entanto, ao analisar os diferentes intervalos, observa-se um crescimento progressivo do RMSE, o que sugere desafios maiores na previsão conforme o período se torna mais recente.



**Figura 34 - Gráfico dos resultados de RMSE, modelo LSTM+GRU default (Fonte: Autor).**

Inicialmente, os valores de RMSE mantiveram-se abaixo de 1,0, mas começaram a aumentar gradualmente a partir de meados de 2022, onde foi pego dois anos e seis meses antes da última data registrada. Esse crescimento pode indicar mudanças nos padrões dos dados, tornando a previsão mais complexa para o modelo. O aumento expressivo do RMSE em torno de 2023-06-01, alcançando um pico de aproximadamente 3,5, evidencia que o modelo encontrou maior dificuldade nesse período. Em seguida, houve uma redução no erro em 2024-01-01, sugerindo uma possível melhora nas previsões, mas o valor voltou a subir no último intervalo analisado, atingindo novamente a casa de 3,5.

## 5 EXPERIMENTOS COM MUDANÇA DE HIPERPARÂMETROS

Para aprimorar os resultados e aumentar a performance dos modelos de previsão, foi realizado um conjunto de testes focado na modificação de hiperparâmetros. O ajuste desses parâmetros é crucial, pois permite que os modelos se adaptem melhor aos dados, melhorando sua capacidade de generalização, ou seja, sua habilidade em fazer previsões precisas em dados não vistos.

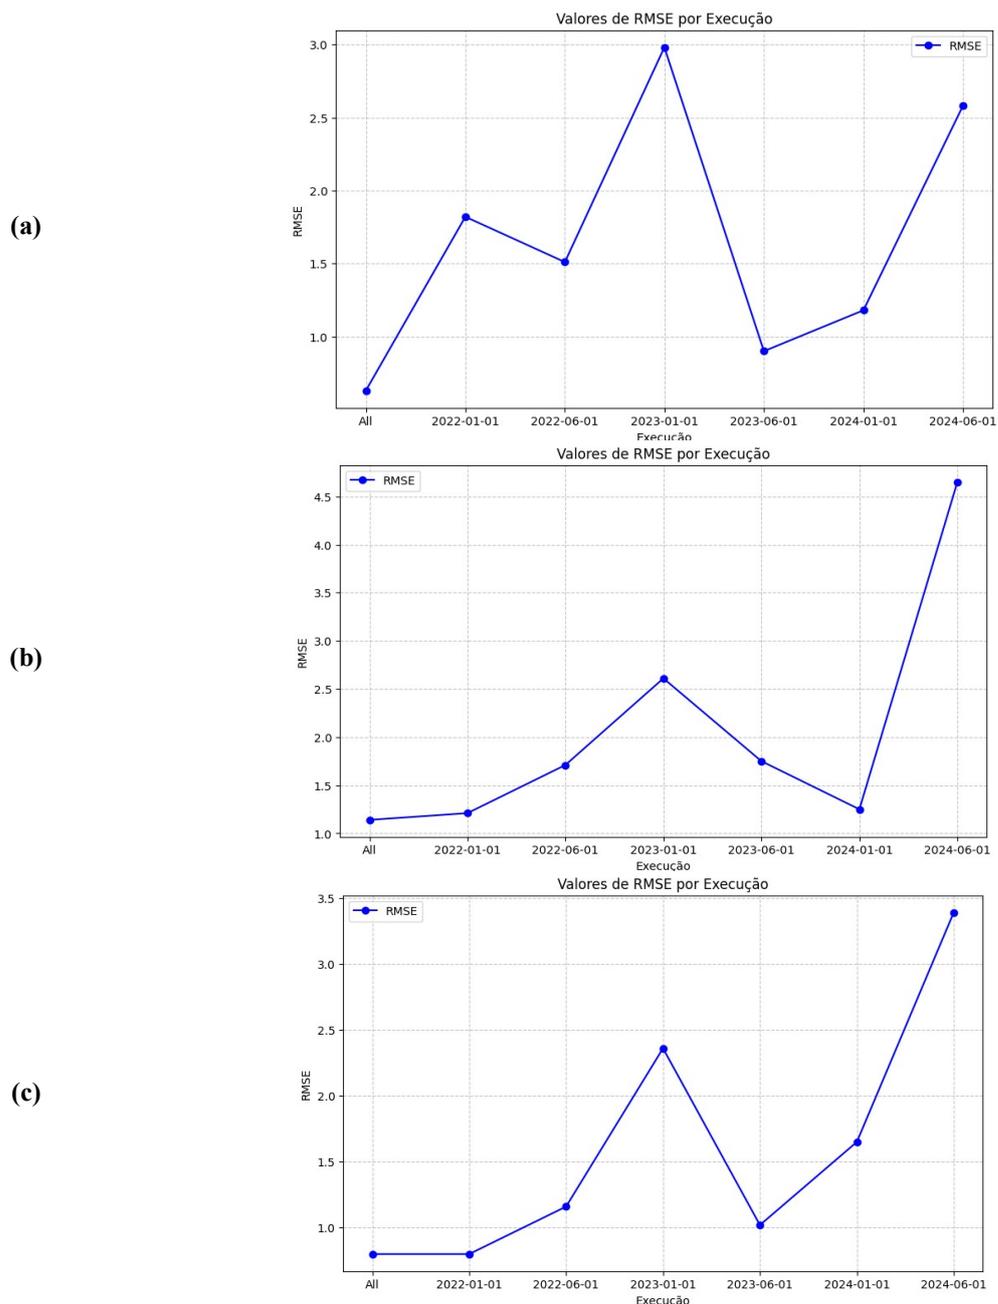
### 5.1 Dropout

O dropout é uma técnica de regularização utilizada para prevenir overfitting, um problema comum em modelos de aprendizado de máquina, onde o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalização. O default dos modelos em uso é uma taxa de dropout de 20%, mas testes adicionais foram realizados com taxas de 40% e 60%. Ao aumentar o dropout, espera-se que a rede se torne mais robusta, aprendendo representações mais genéricas e evitando a dependência excessiva de características específicas dos dados de treinamento. Essa abordagem pode levar a um desempenho melhor em dados novos e não vistos, que é o objetivo final de qualquer modelo de previsão.

Os testes foram conduzidos em diferentes períodos para aumentar a abrangência dos modelos em diversos contextos temporais assim como foi feito nos modelos default. Os períodos escolhidos incluem todo o dataset disponível, assim como segmentos específicos, como os últimos três anos, dois anos e seis meses, dois anos, um ano e seis meses, um ano, e os últimos seis meses antes da última data registrada. Essa estratégia permite observar como os modelos se comportam em diferentes janelas de tempo e entender como as características dos dados podem influenciar os resultados. Por exemplo, em períodos mais curtos, como os últimos seis meses, os dados podem refletir tendências mais recentes, enquanto janelas mais longas podem incluir flutuações sazonais ou ciclos econômicos. Essa análise detalhada proporciona insights valiosos sobre a interação entre os hiperparâmetros ajustados e o contexto temporal dos dados, possibilitando comparação eficaz entre as configurações. Objetivamos identificar as combinações de hiperparâmetros que oferecem os melhores resultados, permitindo um avanço

significativo na precisão das previsões. Assim, o estudo não só contribui para o aprimoramento dos modelos, mas também para um entendimento mais profundo dos fatores que influenciam o desempenho das previsões em aprendizado de máquina.

A Figura 35(a) a (c) apresenta resultados de RMSE para os três modelos, com a aplicação de dropout de 40%.



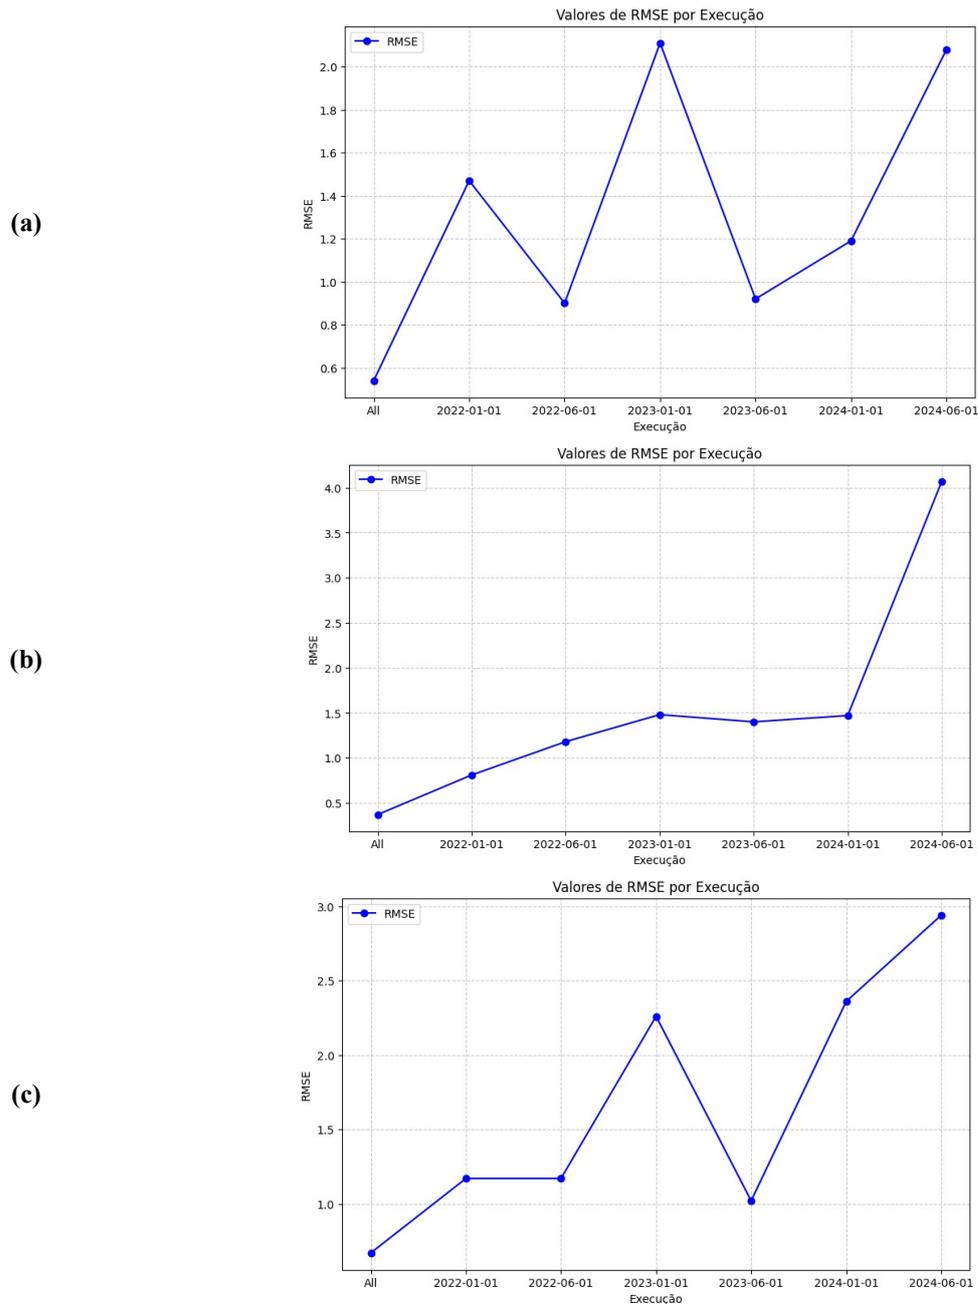
**Figura 35 - Resultados RMSE dos modelos (a)LSTM, (b) GRU e (c) LSTM+GRU - todos os modelos com dropout de 40% (Fonte: Autor).**

A Figura 35(a) mostra que o GRU teve uma redução no erro em algumas

janelas temporais, especialmente nos períodos intermediários, mas apresentou um aumento significativo na última janela, indicando possíveis dificuldades na generalização para previsões mais recentes. Por outro lado, a Figura 35(b) mostra que o LSTM sofreu um aumento expressivo nos erros intermediários, o que sugere que a regularização imposta pelo dropout pode ter prejudicado sua capacidade de aprendizado de padrões mais longos, embora tenha trazido melhorias nas previsões mais próximas à data final. Por fim, a Figura 35(b) ilustra que o modelo LSTM+GRU, apesar de ter apresentado um desempenho relativamente equilibrado em comparação com os demais, não demonstrou uma vantagem clara sobre as abordagens individuais, oscilando entre bons e maus desempenhos dependendo do período analisado.

A Figura 36(a) a (c) apresenta resultados de RMSE para os três modelos, com a aplicação de dropout de 40%. Com a aplicação de dropout de 60%, a Figura 36(a) mostra que o GRU mostrou uma melhora expressiva em algumas janelas, especialmente no início da série, onde o erro foi reduzido significativamente. Entretanto, a última janela apresentou um aumento acentuado no erro, indicando que a alta regularização pode ter prejudicado a capacidade do modelo de capturar padrões recentes. A Figura 36(b) ilustra o LSTM, este modelo, ao receber essa configuração de dropout, demonstrou um comportamento misto, com melhorias nos períodos mais distantes da última data registrada, mas um aumento do erro em momentos intermediários. Isso sugere que, embora a regularização tenha ajudado na estabilidade do modelo, ela pode ter afetado negativamente a retenção de informações de longo prazo.

A combinação LSTM+GRU, apresentada na Figura 36(c), por sua vez, apresentou uma relativa estabilidade em comparação com suas versões individuais, com um erro médio menor em algumas janelas. Esse resultado reforça a hipótese de que a fusão das duas abordagens pode ser vantajosa para capturar diferentes padrões da série temporal. No entanto, o modelo ainda apresentou flutuações nos erros, sugerindo que ajustes adicionais nos hiperparâmetros, como uma redução na taxa de dropout ou um aumento no número de épocas, podem ser necessários para melhorar a consistência dos resultados.



**Figura 36 - Resultados RMSE dos modelos (a)LSTM, (b) GRU e (c) LSTM+GRU - todos os modelos com dropout de 60% (Fonte: Autor).**

## 5.2 Epoch

Para aprimorar os resultados e aumentar a performance dos modelos de previsão, nós variamos o número de épocas de treinamento. O valor padrão para essas épocas é de 100, mas foram realizados testes com configurações alternativas de 50 e 200 épocas.

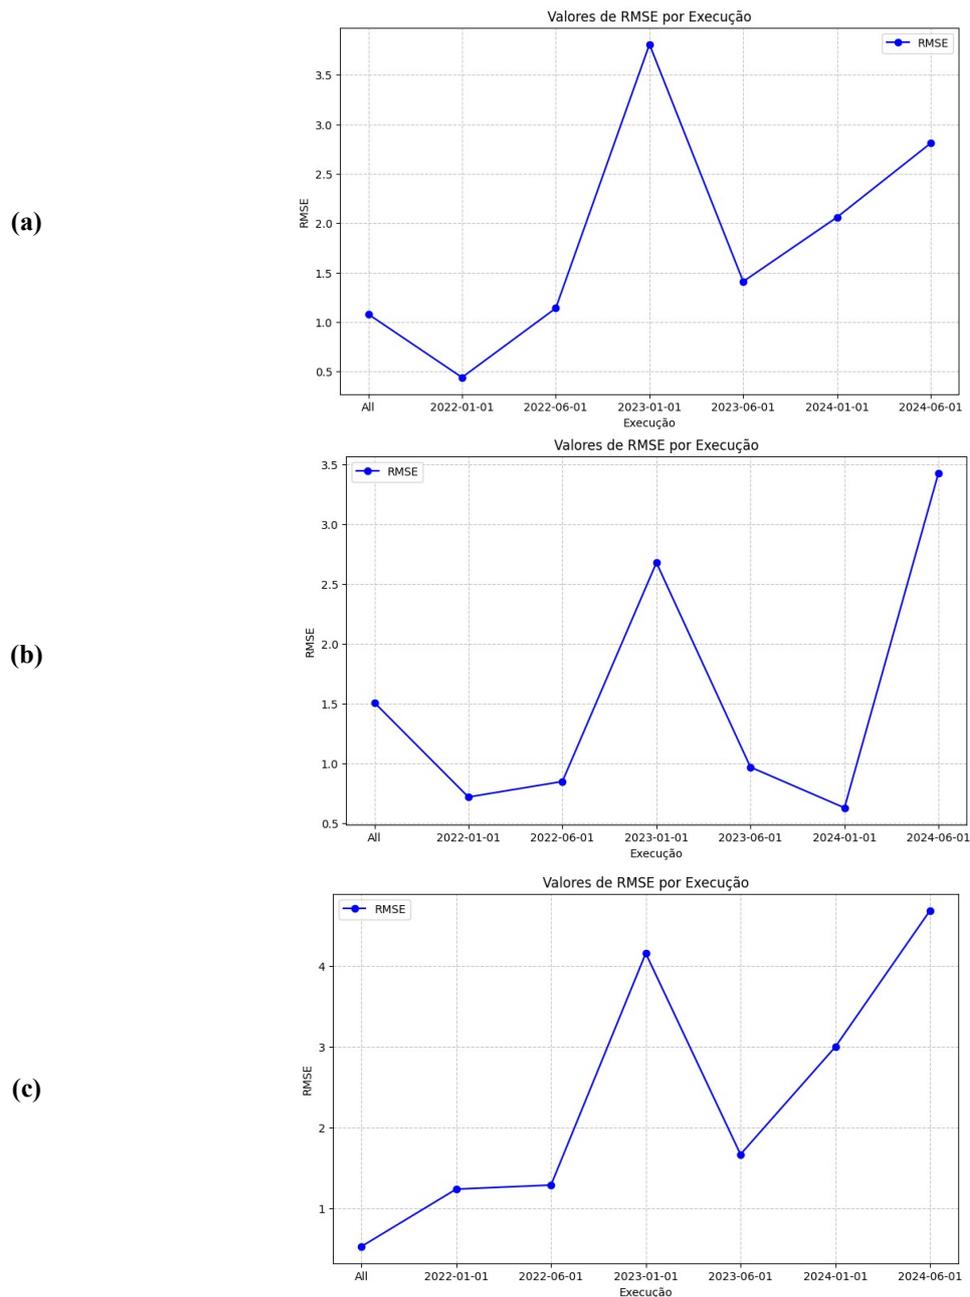
A alteração do número de épocas permite observar como diferentes níveis de

treinamento impactam o desempenho do modelo. Enquanto um número menor de épocas pode resultar em subajuste, onde o modelo não tem tempo suficiente para aprender as características dos dados, um número excessivo pode levar ao overfitting, onde o modelo se ajusta excessivamente aos dados de treinamento e perde a capacidade de generalização. Portanto, explorar essas variações é crucial para encontrar um equilíbrio que maximize a eficiência do modelo.

Os testes foram realizados em diversos períodos temporais, proporcionando uma análise abrangente da performance dos modelos em diferentes contextos. As análises incluem todo o dataset disponível, permitindo uma avaliação do desempenho geral, assim como períodos mais restritos. Essa abordagem visa não apenas verificar como as alterações no número de épocas afetam os resultados, mas também entender como a dinâmica dos dados em diferentes janelas temporais pode influenciar a eficácia dos modelos.

A Figura 37(a) a (c) mostra os resultados de RMSE com a diminuição do número de épocas para 50, para os modelos LSTM, GRU e LSTM+GRU, respectivamente. O GRU mostrou uma redução significativa no erro em diversas janelas, especialmente nos períodos iniciais e intermediários, sugerindo que o treinamento adicional permitiu um melhor ajuste dos pesos e maior capacidade de generalização. No entanto, seu desempenho nos últimos seis meses não apresentou uma melhora significativa, o que indica que o modelo pode estar enfrentando dificuldades em capturar padrões mais recentes da série temporal.

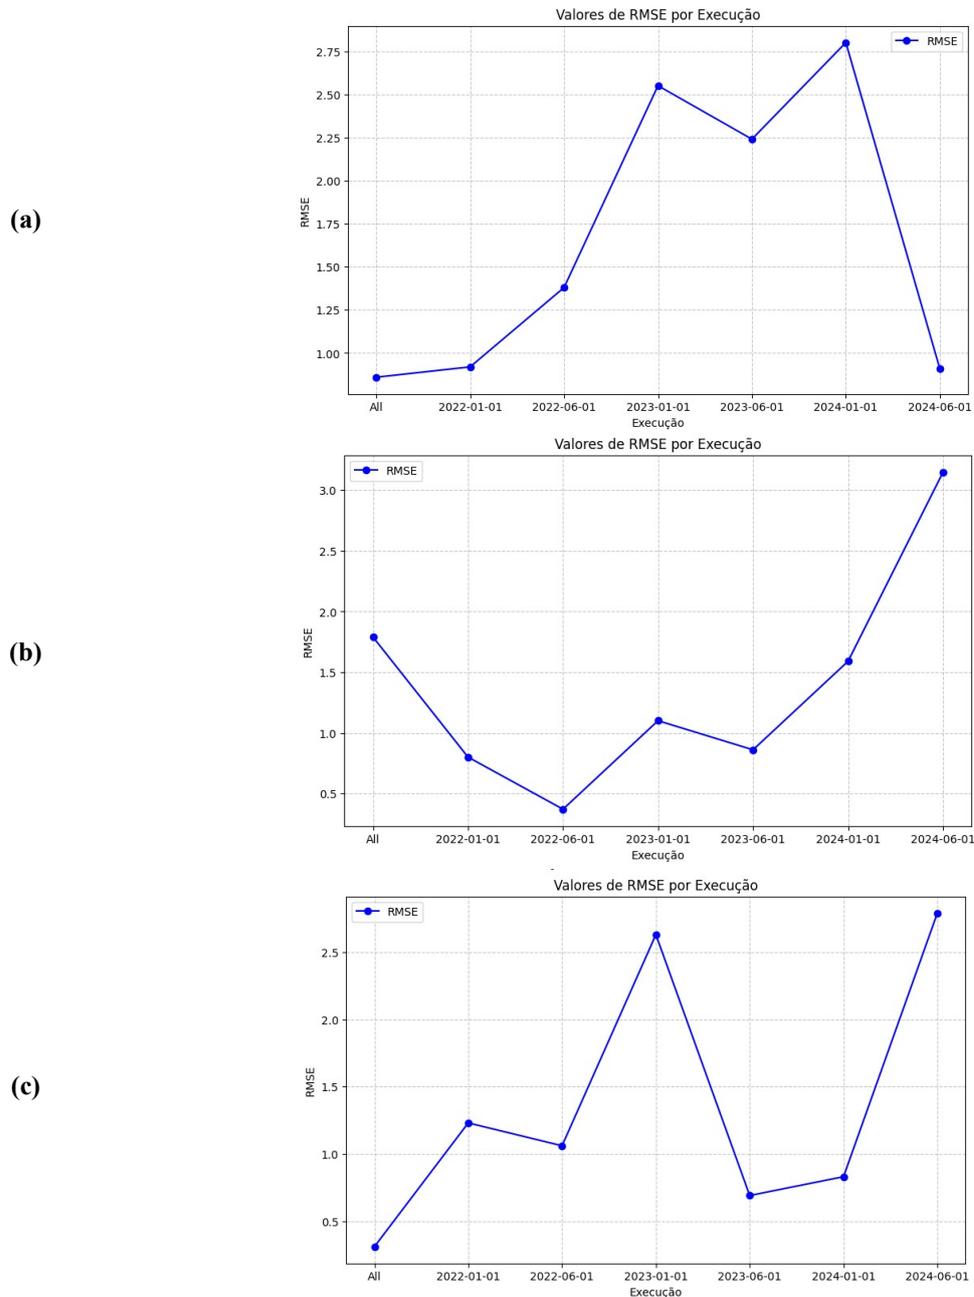
Por outro lado, a Figura 37(b) mostra que o LSTM teve uma queda de desempenho em alguns períodos importantes, especialmente ao se aproximar dos últimos intervalos de data. O erro aumentou significativamente em alguns momentos, o que pode indicar que um número menor de épocas pode ter levado o modelo a um sobreajuste em determinadas fases da série, prejudicando sua capacidade de adaptação aos padrões mais recentes. No entanto, seu desempenho melhorou nos primeiros períodos, sugerindo que a maior quantidade de treinamento pode ter fortalecido a captação de tendências de longo prazo.



**Figura 37 - Resultados RMSE dos modelos (a)LSTM, (b) GRU e (c) LSTM+GRU - todos os modelos com 50 epochs(Fonte: Autor).**

Já o modelo combinado LSTM+GRU, ilustrado na Figura 37(c), apresentou um comportamento mais volátil com o aumento do número de épocas. Embora tenha mostrado alguma melhora em períodos isolados, em outros, como dois anos antes da última data registrada, o erro aumentou consideravelmente. Nos períodos mais recentes, houve um crescimento significativo no erro, o que sugere que o modelo pode estar se tornando excessivamente ajustado aos padrões mais antigos da série e perdendo eficiência na previsão de eventos mais recentes.

A Figura 38(a) a (c) ilustra o desempenho dos modelos GRU, LSTM e LSTM+GRU, respectivamente, com o aumento do número de épocas para 200.



**Figura 38 - Resultados RMSE dos modelos (a)LSTM, (b) GRU e (c) LSTM+GRU - todos os modelos com 200 epoch(Fonte: Autor).**

Na configuração padrão e após o aumento do número de épocas para 200, observa-se que o desempenho dos modelos foi impactado de maneiras diferentes. O modelo GRU, que inicialmente apresentava um erro significativo em alguns períodos, demonstrou uma melhora expressiva em momentos específicos após o ajuste, especialmente em janelas temporais mais distantes, como três anos antes e

dois anos e seis meses antes da última data registrada. No entanto, nos últimos seis meses, o erro continuou elevado, sugerindo que, apesar de uma melhor captação de tendências passadas, o modelo ainda apresenta dificuldades na previsão de eventos mais recentes.

O modelo LSTM, que já se destacava na configuração padrão em algumas janelas, também passou por alterações perceptíveis com o aumento do número de épocas. Enquanto seu desempenho melhorou significativamente em determinados períodos, como no início da série temporal, houve um leve aumento do erro em outros momentos, especialmente em previsões intermediárias. Esse comportamento pode indicar que, embora o modelo tenha conseguido refinar sua capacidade de previsão ao longo do treinamento, o aumento das épocas não necessariamente trouxe uma melhoria uniforme em todas as janelas temporais.

Já o modelo combinado LSTM+GRU apresentou um comportamento peculiar, pois seus resultados para 200 épocas foram idênticos aos do modelo LSTM isolado, o que sugere que o modelo pode ter sido dominado pela estrutura LSTM no processo de treinamento, anulando os possíveis benefícios da combinação das arquiteturas. Isso pode indicar que ajustes mais finos nos hiperparâmetros são necessários para que a interação entre GRU e LSTM seja melhor explorada, evitando que um dos componentes se sobreponha completamente ao outro.

### **5.3 Neurônios**

Esta seção analisa os modelos LSTM, GRU e LSTM+GRU com relação à variação do número de neurônios na rede. O padrão estabelecido para esses modelos é de 50 neurônios, mas foram feitos testes alternativos com configurações de 20 e 80 neurônios.

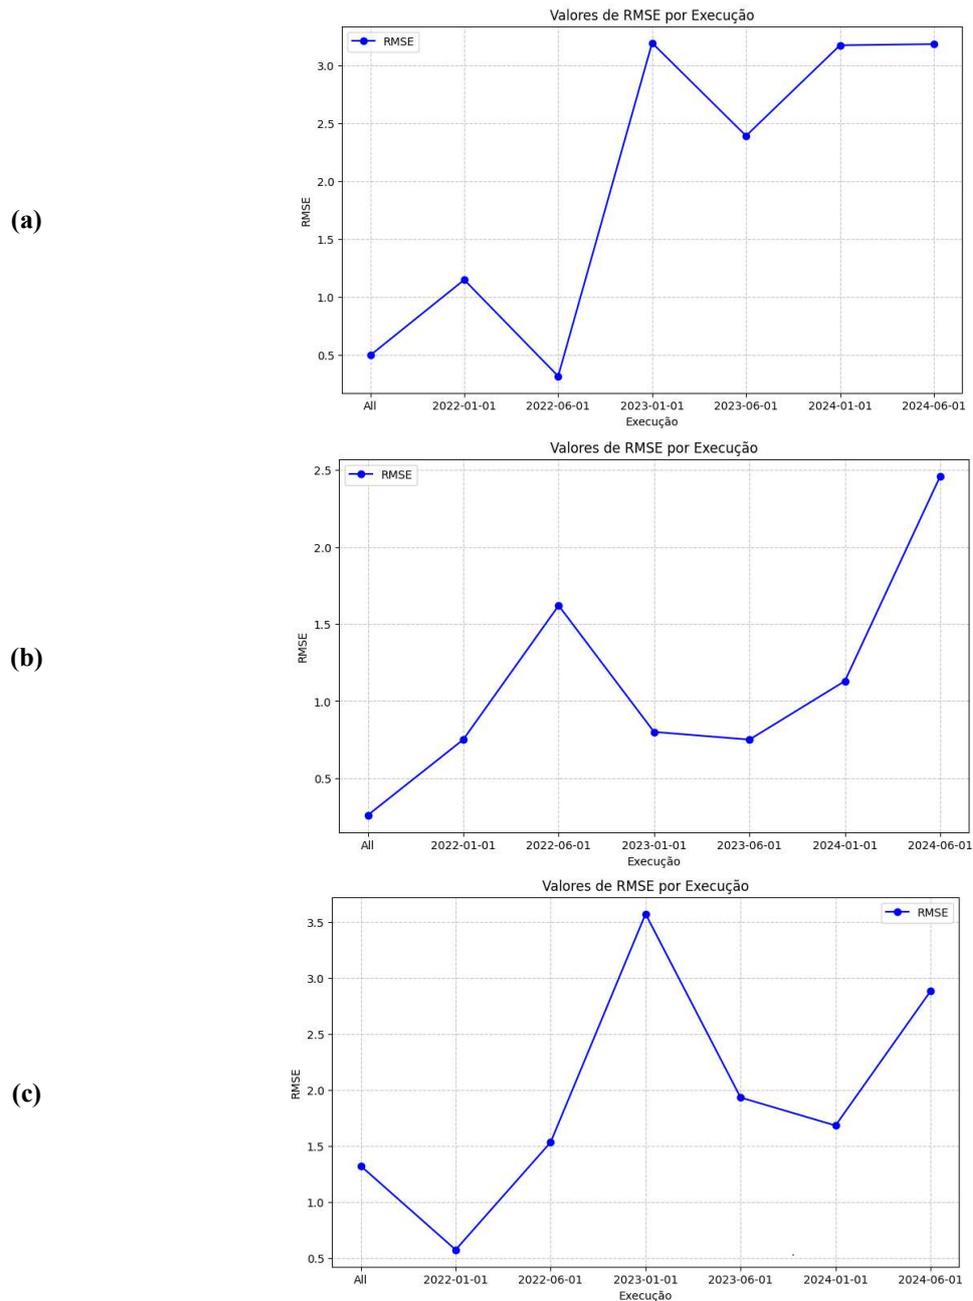
Alterar o número de neurônios em cada camada da rede neural é uma estratégia importante, pois influencia diretamente a complexidade do modelo e sua capacidade de captura de informações. Um número menor de neurônios pode levar a uma sub-representação dos dados, resultando em um modelo que não consegue aprender adequadamente os padrões presentes. Por outro lado, um número excessivo de neurônios pode resultar em overfitting, onde o modelo se ajusta excessivamente aos dados de treinamento e falha em generalizar bem para dados

novos. Portanto, a exploração dessas diferentes configurações é essencial para encontrar um equilíbrio que otimize a eficiência e a precisão dos modelos.

A Figura 39(a) a (c) apresenta os resultados de RMSE para os modelos GRU, LSTM e LSTM+GRU, respectivamente, considerando 20 neurônios. Ao comparar os desempenhos dos modelos na configuração padrão e após a alteração para camadas de 20 neurônios, é possível notar mudanças significativas no erro em diferentes períodos analisados. O modelo GRU, que anteriormente apresentava um erro elevado em diversas janelas, teve uma grande melhora ao reduzir a complexidade da rede. O erro diminuiu expressivamente em quase todos os períodos, sendo especialmente evidente em previsões mais longínquas, como em toda a série histórica e nos últimos seis meses. Isso sugere que uma estrutura mais simples permitiu ao modelo capturar melhor os padrões de longo prazo, evitando sobreajustes.

A Figura 39(b) mostra que o LSTM teve um comportamento distinto, pois, apesar de apresentar um bom desempenho em sua configuração original, a alteração para 20 neurônios resultou em um aumento considerável do erro em momentos críticos, como um ano e seis meses antes da última data registrada. Além disso, o desempenho foi altamente variável, com melhorias pontuais em períodos mais distantes, mas um aumento expressivo do erro em janelas intermediárias. Esse comportamento sugere que o modelo pode ter perdido parte de sua capacidade de aprendizado ao reduzir o número de neurônios, impactando negativamente sua generalização.

A Figura 39(c) ilustra que o modelo híbrido LSTM+GRU também apresentou mudanças notáveis, mas seu desempenho foi menos consistente. Em algumas janelas, como três anos antes e dois anos antes, o erro permaneceu relativamente estável ou teve uma leve melhora. No entanto, em outros momentos, como dois anos e seis meses antes e um ano antes da última data, o erro aumentou, o que indica que a redução da complexidade da rede pode ter prejudicado a interação entre as duas arquiteturas. Embora o modelo tenha mantido um desempenho competitivo em certos períodos, os resultados sugerem que a escolha do número de neurônios precisa ser mais bem ajustada para equilibrar a capacidade de aprendizado e a generalização ao longo do tempo.



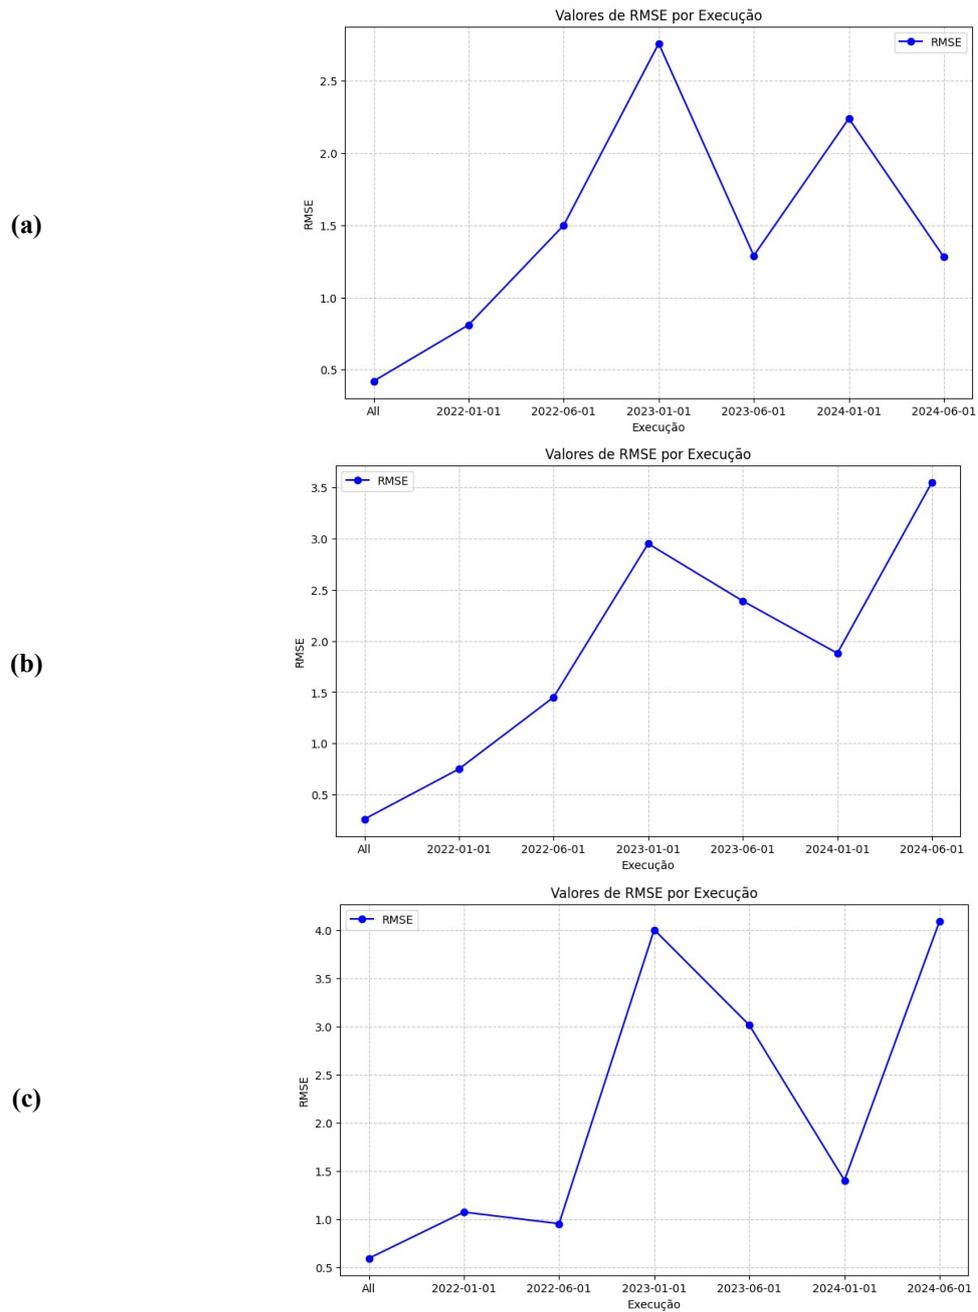
**Figura 39 - Resultados RMSE dos modelos (a)LSTM, (b) GRU e (c) LSTM+GRU - todos os modelos com 20 neurônios(Fonte: Autor).**

A Figura 40(a) a (c) apresenta os resultados de RMSE para os modelos GRU, LSTM e LSTM+GRU, respectivamente, considerando 80 neurônios. Ao analisar os desempenhos dos modelos na configuração padrão e após a modificação para camadas de 80 neurônios, percebe-se que o impacto da mudança foi distinto para cada arquitetura. No caso do GRU (Figura 40(b)), a performance variou conforme o período avaliado. O erro foi reduzido em toda a série histórica e nos períodos mais antigos, como três anos antes e dois anos e seis meses antes da última data

registrada. No entanto, o aumento do erro em previsões mais recentes, como um ano e seis meses antes e seis meses antes, indica que a maior complexidade do modelo pode ter dificultado sua capacidade de generalização a curto prazo. Isso sugere que o acréscimo de neurônios pode ter favorecido a captura de padrões de longo prazo, mas, ao mesmo tempo, pode ter contribuído para um possível sobreajuste nos períodos mais próximos da última data registrada.

A Figura 40(a) mostra que o LSTM apresentou uma resposta mista à alteração. O erro diminuiu em períodos como três anos antes e um ano antes da última data registrada, indicando um benefício no ajuste da arquitetura para esses momentos. No entanto, em outros períodos, como dois anos antes e um ano e seis meses antes, houve um aumento do erro, possivelmente devido à complexidade excessiva da rede, que pode ter tornado o modelo mais sensível a ruídos ou padrões específicos do treinamento. O fato de que o erro foi reduzido nos últimos seis meses antes da última data sugere que, para previsões mais curtas, a maior quantidade de neurônios ajudou o modelo a se adaptar melhor aos dados recentes.

Já no modelo híbrido LSTM+GRU, a alteração para 80 neurônios resultou em um comportamento mais instável. Em períodos como dois anos e seis meses antes e um ano e seis meses antes, o erro aumentou consideravelmente, o que pode indicar que a interação entre as duas arquiteturas não se beneficiou de um aumento de complexidade na mesma proporção que os modelos individuais. Esse aumento do erro em momentos intermediários pode ter sido causado pela dificuldade do modelo em equilibrar padrões de curto e longo prazo simultaneamente. Apesar disso, houve uma melhora perceptível em períodos mais distantes, como três anos antes e em toda a série histórica, o que sugere que, para previsões de longo prazo, essa configuração pode ser mais eficiente.



**Figura 40 - Resultados RMSE dos modelos (a)LSTM, (b) GRU e (c) LSTM+GRU - todos os modelos com 80 neurônios(Fonte: Autor).**

## 6 CONSIDERAÇÕES FINAIS

A avaliação dos modelos GRU, LSTM e LSTM+GRU revelou padrões interessantes quanto ao desempenho em diferentes períodos e configurações de hiperparâmetros. No cenário padrão, o LSTM apresentou o menor RMSE, sugerindo uma performance mais consistente. No entanto, ajustes como aumento do dropout e variação no número de épocas e neurônios impactaram significativamente os resultados.

Ao analisar o menor RMSE por período para qualquer modelo e configuração:

| Período                | Melhor RMSE | Configuração                    |
|------------------------|-------------|---------------------------------|
| Todo período           | 0.26        | GRU (Camadas 20 e 80 neurônios) |
| 3 anos antes           | 0.44        | LSTM (Epoch 50)                 |
| 2 anos e 6 meses antes | 0.32        | LSTM (Camadas 20 neurônios)     |
| 2 anos antes           | 0.8         | GRU (Camadas 20 neurônios)      |
| 1 ano e 6 meses antes  | 0.5         | LSTM (Default)                  |
| 1 ano antes            | 0.63        | GRU (Epoch 50)                  |
| 6 meses antes          | 1.28        | LSTM (Camadas 80 neurônios)     |

**Tabela 25 - Melhores resultados de RMSE (Fonte: Autor).**

A aplicação de dropout de 60% se destacou, reduzindo o erro em vários casos, especialmente para GRU e LSTM. O uso de 50 épocas mostrou-se mais eficaz do que 200 épocas em termos de estabilidade, enquanto a redução do número de neurônios para 20 favoreceu GRU e LSTM, apresentando os menores erros individuais.

Entre os modelos, GRU com dropout de 60% foi o mais estável ao longo dos períodos, enquanto LSTM com dropout de 60% teve o menor erro geral. Já a combinação LSTM+GRU, embora promissora ao comparar os modelos default, onde a mesma apresentou o menor resultado de RMSE entre os modelos default, acabou não demonstrando melhoras de vantagem na variação dos hiperparâmetros.

A partir dessas observações, as melhores escolhas dependem do objetivo: se a prioridade for menor erro geral, LSTM com dropout de 60% se destaca; se for estabilidade ao longo do tempo, GRU com dropout de 60% é a opção mais robusta.

Espera-se que este estudo possa trazer percepções de uma transformação significativa na economia e na sociedade dos investimentos financeiros. Ao automatizar processos, prever cenários e personalizar serviços financeiros, a AI não

apenas aumenta a eficiência e a precisão das decisões de investimento, mas também gera acesso a estratégias sofisticadas, permitindo que um público mais amplo participe do mercado financeiro com maior segurança e previsibilidade.

## 7 REFERÊNCIAS

- [1] A. Menon, S. Singh and H. Parekh, “A Review of Stock Market Prediction Using Neural Networks”, Proceedings of the IEEE International Conference on System, Computation, Automation and Networking (ICSCAN), pp. 1-6, 2019.
- [2] R. Araújo, N. Nedjah, A. Oliveira, S. Meira, “A deep increasing–decreasing-linear neural network for financial time series prediction”, Neurocomputing, v. 347, pp. 59-81, Jun. 2019.
- [3] G. Liu, M. Wenping, “A quantum artificial neural network for stock closing price prediction”, Information Sciences, v. 598, pp. 75-85, Jun. 2022.
- [4] A. Singh, G. Bhardwaj, A. Srivastava, A. Bindra, P. Chaudhary, Ritika, “Application of Neural Network to Technical Analysis of Stock Market Prediction”, Proceedings of the IEEE International Conference on Intelligent Engineering and Management (ICIEM), pp. 302-306, 2022.
- [5] W. Jiang, “Applications of deep learning in stock market prediction: Recent progress”, Expert Systems with Applications, v.184, pp. 115537:1-22, Dec. 2021.
- [6] T. Silva, A. Li, E. Pamplona, “Automated Trading System for Stock Index Using LSTM Neural Networks and Risk Management”, Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN), pp. 1-8, 2020.
- [7] G. Duan, M. Lin, H. Wang, Z. Xu, “Deep Neural Networks for Stock Price Prediction”, Proceedings of the IEEE International Conference on Computer Research and Development (ICCRD), pp. 65-68, 2022.
- [8] H. Zhu, “Green Fund Price Prediction Based on Machine Learning LSTM Neural Network Model”, Proceedings of the International Conference on Aviation Safety and Information Technology (ICASIT), pp. 147-150, 2021.
- [9] A. Emad, H. Abbas, M. Khalil, “Machine Learning Models for Financial Applications”, Proceedings of the International Conference on E-Commerce, E-Business and E-Government (ICEEG), pp. 85-90, 2021.
- [10] I. Medarhri, M. Hosni, N. Nouisser, F. Chakroun, K. Najib. “Predicting Stock Market Price Movement using Machine Learning Techniques”, Proceedings of the IEEE International Conference on Optimization and Applications (ICOA), pp. 1-5, 2022.
- [11] A. Januário; A. Carosia; A. da Silva; G. Coelho, “Sentiment Analysis Applied to News from the Brazilian Stock Market”, Proceedings of the IEEE Latin America Transactions, v. 20, n. 3, pp. 512-518, Mar. 2022.
- [12] S. Goswami, S. Yadav, “Stock Market Prediction Using Deep Learning LSTM Model”, Proceedings of the IEEE International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON), pp. 156-161, 2021.
- [13] A. Moghar, M. Hamiche, “Stock Market Prediction Using LSTM Recurrent Neural Network”, Procedia Computer Science, v. 170, pp. 1168-1173, Apr. 2020.
- [14] P. Eachempati, P. Srivastava, A. Kumar, K. Tan, S. Gupta, “Validating the impact of accounting disclosures on stock market: A deep neural network approach”, Technological Forecasting and Social Change, v. 170, pp. 120903:1-14, Sep. 2021.
- [15] P. Prass, “Aprendizado Profundo e Inteligência Artificial Aplicado na Análise do Mercado Financeiro”, disponível em: <https://tconline.feevale.br/tc/php/trabalhos.php?codcurso=1&cod=1159>, 2022, acessado 20 de Fevereiro de 2024.
- [16] E. Rivero, “Raio-X da B3 em 2023: Como investidores têm encarado o mercado

- brasileiro?”, disponível em: <https://investidor.estadao.com.br/colunas/einar-rivero/raiox-b3-desempenho-bolsa-primeiro-semester-2023/>, 2023, acessado 20 de Fevereiro de 2024.
- [17] Neoway, “Inteligência Artificial: como funciona, exemplos e soluções inteligentes para automação e aprendizado de máquina”, disponível em: <https://blog.neoway.com.br/inteligencia-artificial/>, 2023, acessado 20 de Fevereiro de 2024.
- [18] Amazon, “O que é o aprendizado profundo?”, disponível em: <https://aws.amazon.com/pt/what-is/deep-learning/#:~:text=O%20aprendizado%20profundo%20%C3%A9%20um,produzir%20insights%20e%20previs%C3%B5es%20precisas>, 2023, acessado 20 de Fevereiro de 2024.
- [19] Amazon, “O que é uma rede neural?”, disponível em: <https://aws.amazon.com/pt/what-is/neural-network/#:~:text=As%20redes%20neurais%20profundas%2C%20ou,um%20n%C3%B3%20reprimir%20o%20outro>, 2023, acessado em 20 de Fevereiro de 2024.
- [20] Amazon, “O que é RNN?”, disponível em: [https://aws.amazon.com/pt/what-is/recurrent-neural-network/#:~:text=Uma%20Recurrent%20Neural%20Network%20\(RNN,sa%C3%ADa%20de%20dados%20sequencial%20espec%C3%ADfica](https://aws.amazon.com/pt/what-is/recurrent-neural-network/#:~:text=Uma%20Recurrent%20Neural%20Network%20(RNN,sa%C3%ADa%20de%20dados%20sequencial%20espec%C3%ADfica), 2023, acessado em 20 de Fevereiro de 2024.
- [21] IBM, “O que são Redes Neurais?”, disponível em: <https://www.ibm.com/br-pt/topics/neural-networks>, 2023, acessado em 20 de Fevereiro de 2024.
- [22] The Alan Turing Institute, “Enigma machine goes on display at The Alan Turing Institute”, disponível em: <https://www.turing.ac.uk/news/enigma-machine-goes-display-alan-turing-institute>, 2017, acessado em 20 de Fevereiro de 2024.
- [23] Junior, “Inteligência Artificial”, disponível em: [https://icmcjunior.com.br/inteligencia-artificial/?gad\\_source=1&gclid=Cj0KCQiA5rGuBhCnARIsAN11vgQG6-XisLNgzqPKB1bKTgiSsghPQ9Mo4EfsJEX2q-pHPuFdmMUg8FlaAvcpEALw\\_wcB](https://icmcjunior.com.br/inteligencia-artificial/?gad_source=1&gclid=Cj0KCQiA5rGuBhCnARIsAN11vgQG6-XisLNgzqPKB1bKTgiSsghPQ9Mo4EfsJEX2q-pHPuFdmMUg8FlaAvcpEALw_wcB), 2021, acessado em 21 de Fevereiro de 2024.
- [24] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting”, *Journal of Machine Learning Research* 15 (JMLR), v. 15, n. 1, pp. 1929-1958, Jan. 2014.
- [25] Didática Tech, “Underfitting e Overfitting”, disponível em: <https://didatica.tech/underfitting-e-overfitting/>, 2022, acessado em 21 de Fevereiro de 2024.
- [26] E. Rivero, “Raio-X da B3 em 2023: Como investidores têm encarado o mercado brasileiro?”, disponível em: <https://investidor.estadao.com.br/colunas/einar-rivero/raiox-b3-desempenho-bolsa-primeiro-semester-2023/#:~:text=Como%20podem%20notar%2C%20o%20volume,25%2C6%20bilh%C3%B5es%20por%20dia>, 2023, acessado em 21 de Fevereiro de 2024.
- [27] S. Banik, N. Sharma, M. Mangla, S. Mohanty, S. Shitharth, “LSTM based decision support system for swing trading in stock market”, *Knowledge-Based Systems*, v. 239, pp. 107994:1-8, Mar. 2022.
- [28] P. Vasconcellos, “Como saber se seu modelo de Machine Learning está funcionando mesmo.”, disponível em: <https://paulovasconcellos.com.br/como-saber-se-seu-modelo-de-machine-learning-est%C3%A1-funcionando-mesmo-a5892f6468b>, 2018, acessado em 21 de Fevereiro de 2024.



Pontifícia Universidade Católica do Rio Grande do Sul  
Pró-Reitoria de Pesquisa e Pós-Graduação  
Av. Ipiranga, 6681 – Prédio 1 – Térreo  
Porto Alegre – RS – Brasil  
Fone: (51) 3320-3513  
E-mail: [propesq@pucrs.br](mailto:propesq@pucrs.br)  
Site: [www.pucrs.br](http://www.pucrs.br)