

## PREVENDO FLUTUAÇÕES FINANCEIRAS NO IBOVESPA COM REDE NEURAL DE MEMÓRIA DE CURTO LONGO PRAZO (LSTM)

ISADORA ALVES TEIXEIRA PREVITALLE<sup>1</sup>  
RONNIE SHIDA MARINHO<sup>2</sup>

### RESUMO

O avanço das tecnologias tem proporcionado grandes mudanças em diversos segmentos, incluindo o mercado de ações. Nesse contexto, as Redes Neurais de Memória de Curto Longo Prazo (LSTM) surgem como um modelo promissor para a previsibilidade de flutuações de ações por meio de análises complexas de suas relações em séries temporais. Esse artigo analisa a eficiência da rede neural LSTM para previsão dos valores de fechamento e oscilações nas flutuações de três amostras de ações escolhidas ao acaso da carteira de mercado Ibovespa, utilizando uma análise de serie temporal dos dados históricos entre o período de 2019 até 2023. O estudo também examina a taxa de retorno financeiro ao colocar em prática a aplicação do sistema neural para avaliação de sua eficiência. Os resultados se mostram promissores, uma vez que alcança retornos positivos em todos os testes, ademais, suas conclusões enfatizam vantagens da utilização do modelo aplicadas em deliberações para tomada de decisões.

**Palavras-chave:** Ações; Previsões; Series Temporais.

### ABSTRACT

The advancement of technologies has brought about major changes in several segments, including the stock market. In this context, Short-Term Memory Neural Networks (LSTM) emerge as a promising model for the predictability of stock fluctuations through complex analyzes of their relationships in time series. This article analyzes the efficiency of the LSTM neural network for predicting the closing values and fluctuations in the fluctuations of three samples of shares chosen at random from the Ibovespa market portfolio, using a time series analysis of historical data between the period from 2019 to 2023. The study also examines the rate of financial return when putting into practice the application of the neural system to evaluate its efficiency. The results are promising, as it achieves positive returns in all tests, in addition, its conclusions emphasize the advantages of using the model applied in deliberations for decision-making.

**Key words:** Actions; Forecasts; Time Series.

---

<sup>1</sup>Tecnóloga em Ciência de Dados pela Faculdade de Tecnologia de Adamantina. E-mail: isadora.previtalle@fatec.sp.gov.br

<sup>2</sup>Docente, Curso Superior de Ciência de Dados, Faculdade de Tecnologia de Adamantina.

## INTRODUÇÃO

Ao longo do tempo vários estudos giraram em torno do desafio de gerar uma previsão confiável de series financeiras. Essa tarefa se torna complexa à medida que o mercado financeiro é influenciado por diversos fatores como eventos econômicos, sociais e políticos, padrões intrincados e constante evolução. Devido a isso, a procura por modelos eficazes em meio a era tecnológica tornou-se foco de pesquisas contemporânea.

Existem diversos estudos que buscam compreender as variações nos preços das ações utilizando Inteligência Artificial (IA) e Aprendizado de Máquina (AM) para prever o momento ideal de realizar movimentações, entretanto, até o momento, não há registro de um trabalho que tenha obtido consistentemente resultados positivos de forma robusta em diferentes cenários.

Mesquita (2019), desenvolveu uma pesquisa baseada na correlação temporal das series financeiras com 38 ativos da bolsa de valores brasileiras, mostrando ser possível uma associação entre os dados históricos das ações que viabilizam a construção de modelos de previsão baseados em registros passados.

Campos (2020), conduziu um estudo comparativo das técnicas de previsão para séries temporais utilizando variações históricas de uma empresa de capital aberto. Os resultados indicaram que os modelos Autorregressivo (AR), Autorregressivo Integrado de Médias Móveis (ARIMA) e Autorregressivo Integrado de Médias Móveis Sazonal (SARIMA) apresentaram desempenho inferior em comparação com modelos de aprendizagem, como Redes Neurais de Memória de Curto Longo Prazo (LSTM).

Corroborando com isso, o presente trabalho emprega três ações reais retiradas como amostras da carteira do Ibovespa (Petrobras, Apple, Honda), junto de dados históricos que representam flutuações na bolsa durante o período de 2019 a 2023 para alimentar um modelo LSTM. A validação de seu desempenho é realizada por meio da análise de acertos em relação as oscilações de valorização

ou desvalorização do preço da ação empregando métricas de Erro Médio Quadrado (RMSE), acurácia, *recall*, precisão e F1 Score.

Deste modo, esse estudo tem o objetivo de utilizar técnicas de Ciência de Dados e Aprendizado de Máquina, baseado em series temporais, para abordar a eficácia do modelo de rede neural LSTM como parâmetro notório na tomada de decisão, partindo da premissa de que os dados do passado possuem uma relação com os dados futuros que permitem a criação de um modelo de previsão proficiente.

A organização adotada nesse trabalho engloba revisão bibliográfica e experimentação. Ela foi subdividida em referencial teórico a respeito da rede neural LSTM, procedimentos metodológicos para sua estruturação, análise dos experimentos abordando as métricas de avaliação do modelo e conclusões.

## MATERIAL E MÉTODOS

A metodologia adotada nesse trabalho envolve revisões bibliográficas e experimentos práticos para a previsão de flutuações na bolsa de ações do Ibovespa. A fim de validar pesquisas que giraram em torno dessa temática, realizou-se uma revisão extensiva de métodos de previsão financeira e, subsequentemente, desenvolveu-se um sistema neural artificial em linguagem de programação *python* para análise de resultados.

### Rede Neural de Memória de Curto Longo Prazo

O Modelo Neural de Memória de Curto Longo Prazo é definido por Vasco (2020) como “um tipo de rede capaz de aprender dependências de longo prazo, projetada especificamente para evitar problemas de dissipação”. Ela foi uma das soluções introduzidas por Hochreiter e Schmidhuber (1997) para superar as limitações de memória, sendo eficiente em tarefas de classificação, processamento e predição em séries temporais.

Prevendo flutuações financeiras no Ibovespa com rede neural de memória de curto longo prazo (LSTM).	Isadora A. T. Previtalle; Ronnie S. Marinho.
---	---

As Redes Neurais Artificiais tinham como recurso a conexão de informações anteriores para fim de contexto em quadros atuais, entretanto, conforme Bengio et al. (1994) essa rede não consegue aprender as conexões ao decorrer do aumento entre as lacunas temporais, que, ao depender da limitação do contexto possui dificuldade em lembrar informações de sequencias muito longas.

Em certos casos não é necessário realizar análises de informações espalhadas em um intervalo de tempo muito distante, entretanto, há situações em que é necessário um contexto maior. Para esses tipos de problemas criou-se a rede LSTM, utilizada nesse trabalho devido ao seu bom desempenho em relação ao processamento de previsão de dados, com alto poder preditivo, atingindo melhores resultados comparados a outros modelos (Graves, 2012).

### **Estruturação do Modelo LSTM**

Para a realização do processo de estruturação dos dados foi utilizado a aplicação *web* de código aberto *Jupyter Notebook* na versão 6.5.4, com uma base de dados retirada do histórico do Ibovespa (B3) no período de 01 de janeiro de 2019 até 01 de setembro de 2023.

A etapa se inicia com a criação de uma função que extrai as principais colunas do arquivo importado, de acordo com cada parâmetro de posição, e as transformam em uma estrutura de dados tabular bidimensional conhecida como *dataframe*.

Nesse *dataframe* foram utilizadas as colunas *data\_pregao*, *Codbid*, *sigla\_acao*, *nome\_acao*, *preco\_abertura*, *preco\_max*, *preco\_min*, *preco\_fechamento*, *qtd\_negocios* e *volume\_negocios*, conforme ilustrado na Tabela 1, com um volume de dados de 650.828 linhas.

Prevendo flutuações financeiras no Ibovespa com rede neural de memória de curto longo prazo (LSTM).	Isadora A. T. Previtalle; Ronnie S. Marinho.
---	---

**Tabela 1.** Campos da base de dados retirada do Ibovespa (B3).

data_pregao	Data da transação
Coddbi	Código da transação
sigla_acao	Sigla da ação
nome_acao	Nome da ação
preco_abertura	Preço inicial da ação
preco_max	Preço máximo diário da ação
preco_min	Preço mínimo diário da ação
preco_fechamento	Preço final da ação
qtd_negocios	Quantidade de transações
volume_negocios	Quantidade de ativos

**Fonte:** Os Autores (2024).

A aplicação do modelo LSTM foi realizada na interface *Google Colab*, um ambiente corporativo para linguagem de programação *python*, na versão 3.10.12.

Para sua implementação, foram consideradas três ações presentes na carteira do Ibovespa. Essas ações incluem a Petrobras, representada pela sigla PETR4, com um total de 1.161 registros; a *Apple*, identificada como AAPL34, com um total de 937 registros; e a *Honda*, referenciada pela sigla HOND34, com um total de 508 registros.

A criação do modelo foi realizada com 20% dos dados para treino e 80% de teste, com um total de 50 neurônios, shape de 30, 60 e 90 informações para a geração de uma, e a adição de 25 neurônios após seu segundo retorno. Sua compilação foi realizada utilizando a Estimativa Adaptativa de Momentos (ADAM) modelo com técnicas de otimização para descida de gradiente usado em problemas que envolvem muitos dados ou parâmetros. Ele foi implementado com a função de perda para avaliação de desempenho durante o treinamento que, visa a diminuição do parâmetro de erro médio quadrático.

### Medidas de Desempenho

Partindo da estruturação para redução de erros nos dados de treinamento do algoritmo, o Erro Médio Quadrado (RMSE) emerge como o principal indicador para valorar a diferença entre as previsões do modelo em relação aos valores reais da

base (1). Ele fornece uma indicação entre o observado e o previsto, sendo uma medida de desempenho que generaliza grandes desvios (Santos, 2019). Quanto menor seu erro, mais precisa é a previsibilidade do modelo, especialmente nos dados de treino.

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

Em termos de classificação, próxima etapa do modelo, os resultados são comparados com base em cálculos provindos da matriz de confusão, como Acurácia, *Recall*, Precisão e *F1 Score*, onde “cada coluna da matriz representa as instâncias de uma classe prevista, enquanto cada linha representa os casos em uma classe real” (Assis et. all, 2020). Suas classes são compostas por verdadeiros positivos (VP) correspondendo aos dados positivos rotulados corretamente, falsos positivos (FP) representando exemplos negativos erroneamente rotulados, verdadeiros negativos (VN) sendo os dados negativos rotulados corretamente e falsos negativos (FN) que indicam os registros positivos incorretamente rotulados.

A taxa de acerto (2) ou Acurácia diz respeito a proporção de previsões positivas e negativas classificadas corretamente em relação ao número total de amostras da série avaliada em percentual. Essa métrica é utilizada como um parâmetro de desempenho do modelo em um contexto em que as classes estão equilibradas, oferecendo uma perspectiva abrangente do quão bem a rede está se saindo em termos gerais.

$$Acuracia = \frac{VP + VN}{VP + VN + FP + FN} \quad (2)$$

A Precisão (3) desempenha o papel de analisar o número de classificação verdadeiras positivas em relação ao total de classificação positiva do modelo. Em outras palavras, ela avalia quantas das entradas classificadas como corretas são verdadeiramente representativas. Sua utilização é costumeira para garantir a

confiabilidade em previsões positivas, útil quando há consequências significativas associadas a falsas previsões positivas.

$$Precisao = \frac{VP}{VP + FP} \quad (3)$$

O *Recall*, sensibilidade ou Revocação (4), representa a capacidade do modelo em identificar corretamente os valores previstos de uma classe em comparação ao total de ocorrências existentes na mesma (Nelson, 2017). É uma métrica útil para minimizar falsos negativos à medida que fornece uma visão crítica na identificação efetiva de todas as instancias relevantes.

$$Revocacao = \frac{VP}{VP + FN} \quad (4)$$

Em última análise, o *F1 Score* (5) diz respeito a uma harmonia entre a Precisão e Revocação, à medida que equilibra essas duas métricas a fim de avaliar o desempenho de um modelo quando se faz necessário evitar o desequilíbrio entre as classes para classificação de falsos positivos ou negativos.

$$F1\ Score = \frac{2 * precisao * revocacao}{precisao + revocaco} \quad (5)$$

## RESULTADOS E DISCUSSÃO

Este Capítulo descreve os experimentos realizados e resultados obtidos durante a utilização da Rede LSTM nas ações da Petrobras, Apple e Honda retiradas da carteira do Ibovespa (B3).

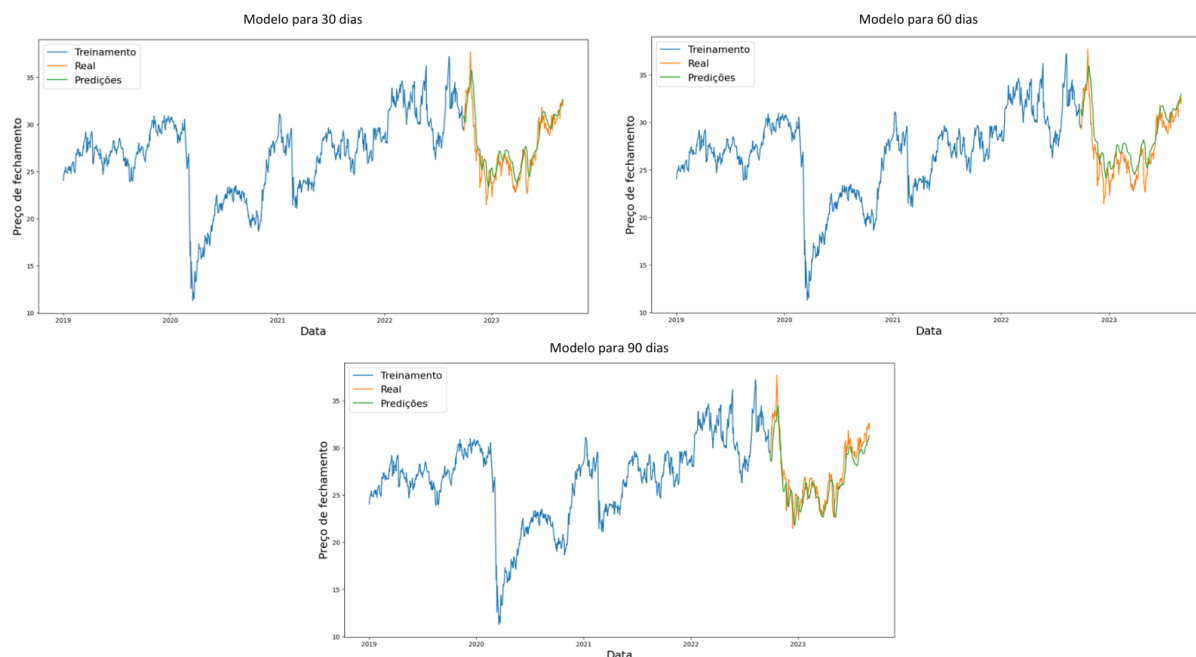
Os experimentos realizados pelo modelo de LSTM consistem na aplicação de *backtests* em três épocas diferentes, denominados pela análise de 30, 60 e 90 dias anteriores para previsão de um subsequente no decorrer do intervalo temporal de 01 de janeiro de 2019 até 01 de setembro de 2023.

### Previendo Valores da Petrobras

Os dados de entrada utilizados pelo algoritmo para ação PETR4 são constituídos, de 80% do total de transações para treino e 20% para teste, com oscilações em torno de 10 a 35 reais, e um total de dados consumidos de 1161 dias, com 929 dados de treino para 232 dados de validação.

A Figura 3 ilustra a evolução dos preços de ativos dessa ação, ao analisá-la é possível observar um declínio acentuado no início de 2020 em comparação ao longo da série financeira, entretanto tal ocorrência se deu em dados de treino, não gerando *outliers* para as previsões finais, cujo, passam por uma desvalorização seguida de uma leve ascensão com previsões relativamente próximas aos dados reais.

**Figura 3.** Desempenho do Ativo PETR4 em Diferentes Configurações de Treino e Teste ao Longo de 30, 60 e 90 Dias.



**Fonte:** Os Autores (2024).

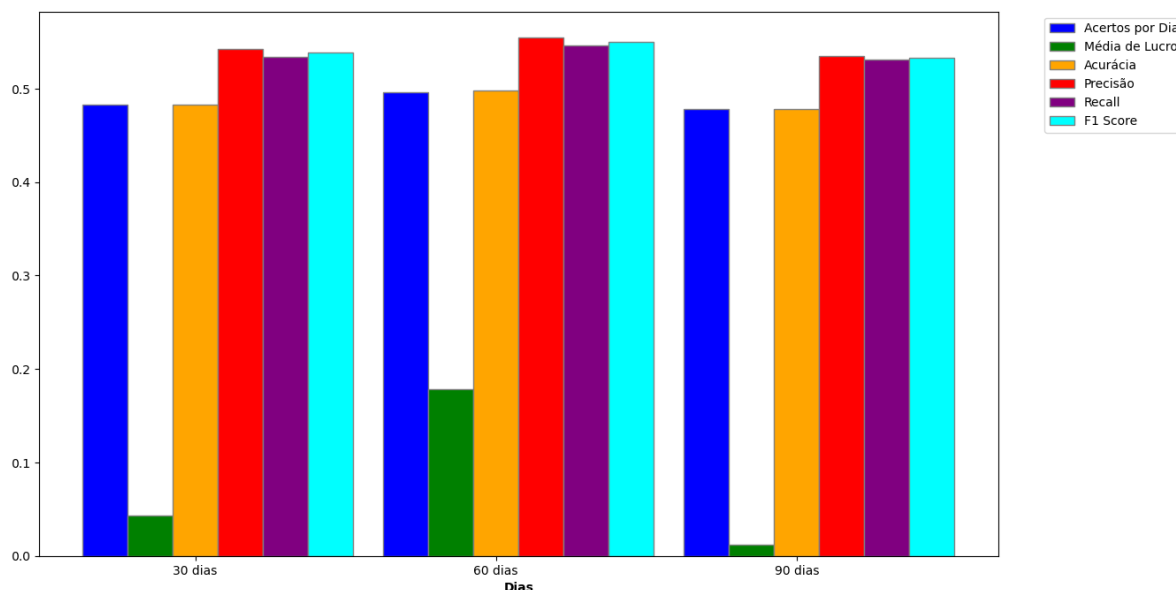
No primeiro e segundo período (30 e 60 dias) nota-se uma previsão mais assertiva na queda inicial e valorização final do ativo, com previsões ligeiramente



acima do real para o início de 2023, ambos contam com acurácia próximas, conforme o Gráfico 1, sendo 0,48 e 0,49 consecutivamente. Já o terceiro período avaliado (90 dias) se distingue dos anteriores por terem previsões abaixo do real durante toda etapa de validação do modelo, sua acurácia é de 0,47, com pouca diferença dos demais.

Examinando com maior minúcia os três períodos fica visível a baixa variação entre as métricas do desempenho do modelo ao que tange a Acurácia, Precisão, *Recall* e *F1 Score*, entretanto é notório o ganho de lucro por percentual diário da rede no intervalo de 60 dias, referentes a \$0.16, se destacado dos demais momentos.

**Gráfico 1.** Métricas de validação do modelo para PETR4.



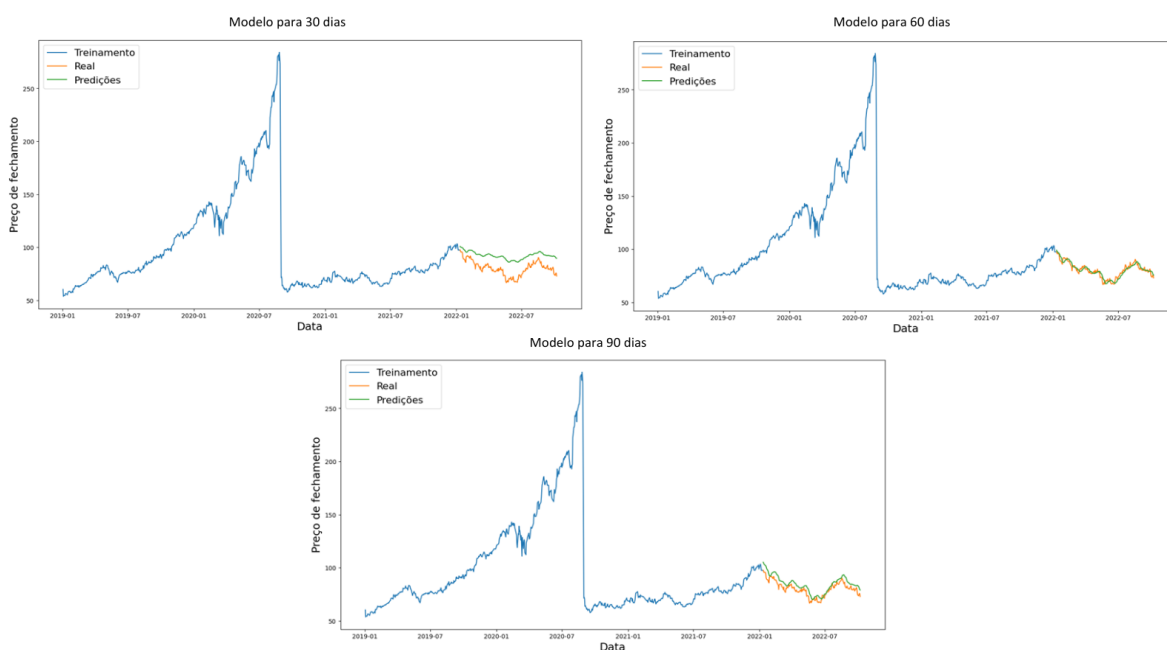
**Fonte:** Os Autores (2024).

### Previendo Valores da Apple

Os resultados alcançados para a ação AAPL34 foram derivados de uma análise abrangendo 937 títulos, dos quais 750 foram designados para o conjunto de treinamento, enquanto os restantes 187 constituíram o conjunto de avaliação do modelo. Essa ação, se caracteriza por flutuações na faixa de 50 a 150, com incrementos potenciais de até 300 reais.

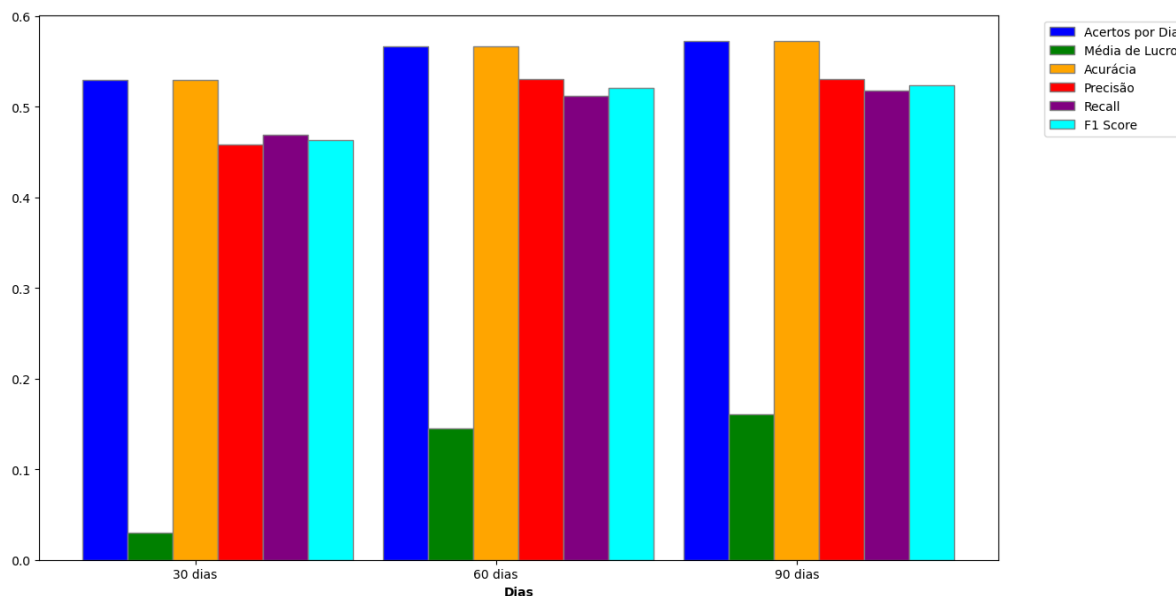
Na Figura 4 é possível avaliar a volatilidade inesperada da ação com uma queda drástica durante o ano de 2020, observa-se ainda que o modelo teve dificuldades em prever quedas em suas oscilações para o intervalo de 30 dias precedentes, mas, tal desvio não se generalizou aos demais intervalos temporais, pelo contrário, alcançou uma previsão satisfatória para 60 dias, sem uma dispersão além ou aquém da média.

**Figura 4.** Desempenho do Ativo AAPL34 em Diferentes Configurações de Treino e Teste ao Longo de 30, 60 e 90 Dias.



**Fonte:** Os Autores (2024).

Aprofundando a análise temporal, pode-se observar no Gráfico 2 a consistência nas métricas de desempenho do modelo. O impacto do intervalo temporal referente a 30 dias mostrou abalos em sua acurácia e assertividade, com todas as validações inferiores as previsões de 60 e 90 dias, parâmetros visíveis por uma acurácia de 0.52 em comparação a 0.56 e 0.57 sucessivamente, além de uma média de lucro entre \$0.03 reais por dia por ação comparados com \$0.14 e \$0.16.

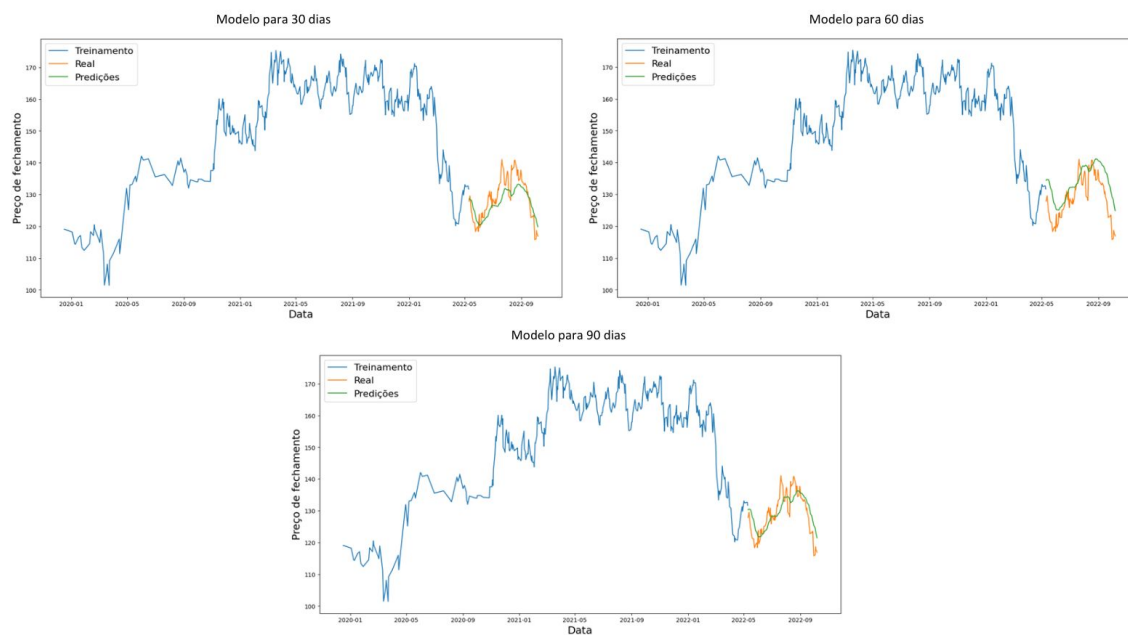
**Gráfico 2.** Métricas de validação do modelo para AAPL34.

**Fonte:** Os Autores (2024).

### Prevedo Valores da Honda

Analisando a ação HOND34, composta por 508 dados, subdivididos por 406 para 102 e precificadas na faixa de 100 a 170 reais, observa-se, na Figura 5, que o ativo apresenta uma notável ascensão nos dados de treino e uma subsequente diminuição nos dados de teste, estando em boa parte do conjunto de estruturação nos valores máximos do ativo. Este fenômeno é particularmente evidente no intervalo de 60 dias, onde as previsões da rede mostram-se desafiadoras, revelando uma perda de assertividade em comparação com os períodos adjacentes.

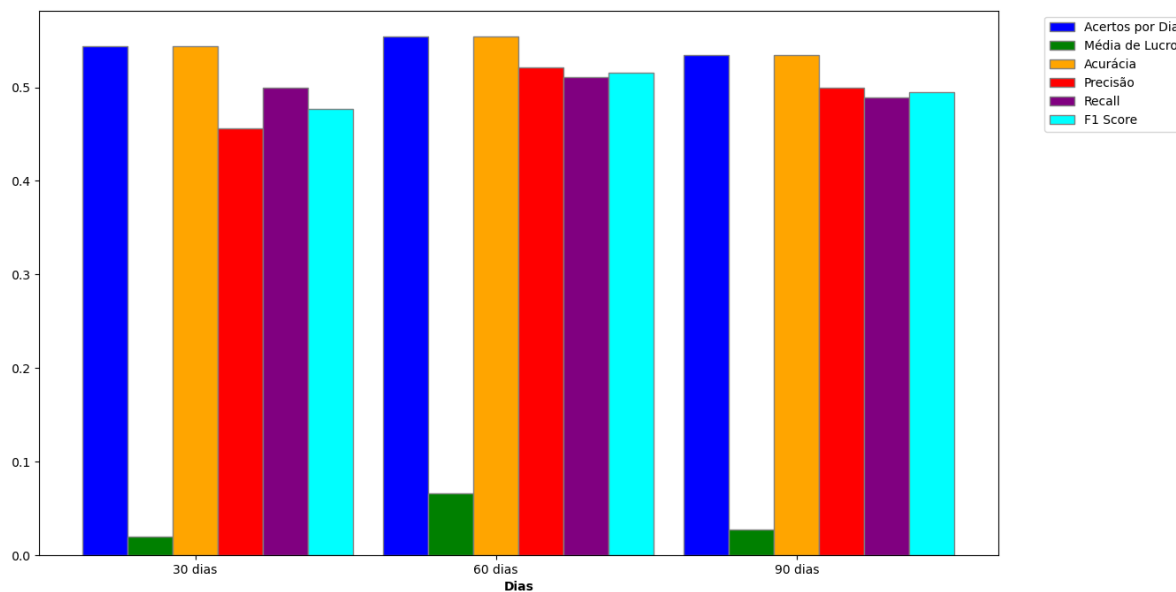
**Figura 5.** Desempenho do Ativo HOND34 em Diferentes Configurações de Treino e Teste ao Longo de 30, 60 e 90 Dias.



**Fonte:** Os Autores (2024).

Intrigantemente, mesmo com previsões menos precisas para os 60 dias equiparados ao demais intervalos, o modelo alcança um retorno significativo de lucro ao moldar suas flutuações diárias conforme o Gráfico 3. Considerando o período de 30 dias, o algoritmo exibe uma acurácia de 0,54, enquanto o intervalo de 60 dias apresenta uma acurácia de 0,55, e o período de 90 dias registra uma acurácia de 0,53.

Ao inspecionar com maior detalhe suas métricas de desempenho, percebe-se uma consistência notável na Acurácia, Precisão, Recall e F1 Score para os três períodos avaliados. Contudo, o destaque recai sobre o intervalo de 60 dias, onde, apesar da menor assertividade nas previsões, é evidente um ganho significativo de lucro diário, totalizando \$0,06 em relação a \$0.01 e \$0.03 restituição de ganhos.

**Gráfico 3.** Métricas de validação do modelo para HOND34.

**Fonte:** Os Autores (2024).

## CONCLUSÃO

Nesse trabalho foi possível mensurar o potencial das Redes LSTM no contexto financeiro alicerçado com experimentos e análises meticulosas de três ações do Ibovespa.

Ao adentrar nos resultados obtidos em meio as aplicações é possível validar que o modelo não apenas gerou lucros positivos para todas as ações trabalhadas, como também alcançou acurácia acima de 50% em sua implementação, mérito digno de destaque partindo da premissa de que a volatilidade e imprevisibilidade do mercado são fatores desafiadores.

As conclusões extraídas destacam assim vantagens substanciais que a implementação de modelos de redes neurais artificiais pode oferecer no panorama de tomadas de decisões e deliberações de estratégias. Dessa forma, corrobora-se uma ferramenta promissora para aprimorar novas transações, além de uma oportunidade de desenvolvimento de futuros trabalhos baseados em mais atributos durante a estruturação de um novo recurso.

## REFERÊNCIAS BIBLIOGRÁFICAS

ASSIS, C.; CARRANO, E.; PEREIRA, A. **Predição de tendências em séries financeiras utilizando meta-classificadores**. Economia Aplicada, v. 24, n. 1, p. 29-78, 2020.

B3. Índice Bovespa. Disponível em: [https://www.b3.com.br/pt\\_br/market-data-e-indices/indices/indices-amplos/ibovespa.htm](https://www.b3.com.br/pt_br/market-data-e-indices/indices/indices-amplos/ibovespa.htm). Acesso em: 21 ago. 2023.

BENGIO, Y.; SIMARD, P.; FRASCONI, P. **Learning long-term dependencies with gradient descent is difficult**. IEEE Transactions on Neural Networks, v. 5, n. 2, p. 10, 1994.

BLUVOL, L. **Análise de algoritmos de machine learning e redes neurais para previsão de preços de ações do Ibovespa**. Dissertação (Mestrado profissional em Economia Empresarial e Finanças) – EPG Escola Brasileira de Economia e Finanças, Universidade Federal do Rio de Janeiro, p. 44. 2022.

CAMPOS, B. **Análise Comparativa de Técnicas para a Previsão de Séries Temporais no Contexto de Mercados Financeiros**. TCC (Graduação) - Curso de Sistemas de Informação, Universidade Federal de Santa Catarina, Florianópolis, 2020.

GRAVES, A. **Supervised Sequence Labelling with Recurrent Neural Networks**. of Studies in Computational Intelligence. Springer. ISBN 978-3-642- 24796-5. v. 385, p. 146, 2012.

HOCHREITER, S.; SCHMIDHUBER, J. **Long Short-term Memory**. MIT Press Direct, Instituto de Tecnologia de Massachusetts, ed. 8, v. 9, p. 33, Cambridge, Massachusetts, Estados Unidos, 1997.

MESQUITA, C. **Ciência de Dados e Aprendizado de Máquina para Predição em Séries Temporais Financeiras**. Dissertação (Mestrado em Ciência da Computação) – Instituto de Ciências Exatas, Departamento de Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, p. 131. 2019.

NASCIMENTO, O.; SANTOS, F.; FERREIRA, K. **Previsão de Preços de Ações Utilizando Inteligência Artificial**. In: BRAZILIAN WORKSHOP ON ARTIFICIAL INTELLIGENCE IN FINANCE (BWAIF), 1., 2022, Niterói. Anais. Porto Alegre: Sociedade Brasileira de Computação, 2022. p. 37-47.

Prevendo flutuações financeiras no Ibovespa com rede neural de memória de curto longo prazo (LSTM).
---

Isadora A. T. Previtalle; Ronnie S. Marinho.
---

NELSON, D. **Uso de Redes Neurais Recorrentes para Previsão de Séries Temporais Financeiras**. Dissertação (Mestrado em Ciência da Computação) - Instituto de Ciências Exatas, Universidade Federal de Minas Gerais, Belo Horizonte, p. 73. 2017.

PASSOS, B. **Long Short Term Memory: redes neurais artificiais que são capazes de ler, ouvir e ver**. Disponível em: <https://ateliware.com/blog/long-short-term-memory>. Acesso em 08 set. 2023.

SANTOS, E. **Avaliação do desempenho de redes neurais artificiais na previsão de vazões críticas a partir de séries curtas de dados**. Dissertação (Graduação em Engenharia Civil) – Departamento de Engenharia Civil Ambiental, Universidade Federal da Paraíba, João Pessoa, p. 88. 2019.

VASCO, L. **Um Estudo de Redes Neurais Recorrentes no Contexto de Previsões no Mercado Financeiro**. Dissertação (Graduação em Engenharia da Computação) – Departamento de Computação, Universidade Federal de São Carlos, São Carlos, São Paulo, p. 49. 2020.