



PREDIÇÃO DE TENDÊNCIA NOS PREÇOS DE ATIVOS FINANCEIROS USANDO INTELIGÊNCIA ARTIFICIAL

Leandro A. de O. ALVES¹; Douglas D. de C. BRAZ²

RESUMO

Este trabalho teve como objetivo apresentar uma análise utilizando técnicas de inteligência artificial para predição de tendências dos preços de ativos financeiros. Para isso, foram desenvolvidos modelos de aprendizado de máquina utilizando *Long Short-Term Memory* (LSTM). Além disso, o problema foi modelado como sendo uma classificação binária, na qual utilizamos como entrada atributos derivados da série temporal do preço, definidos como Indicadores de Análise Técnica, assim como preços realizados dos ativos utilizados. Foram utilizados dados diários de cinco ativos: Ambev (ABEV3), Banco Bradesco (BBDC4), Itaú Unibanco (ITUB4), Petrobrás (PETR4) e Vale (VALE3). Além da resolução do problema de previsão de tendência, foram realizadas simulações do retorno financeiro de estratégias de investimento utilizando a saída dos modelos como fonte para tomada de decisão. Os resultados das previsões ficaram acima do algoritmo baseline proposto para comparação. Entretanto, as simulações de retorno realizadas se mostraram satisfatórias em apenas algumas ações.

Palavras-chave:

Aprendizado de Máquina; Redes Neurais Artificiais; Previsão.

1. INTRODUÇÃO

Em 2022, a bolsa de valores do Brasil (B3) atingiu o número de 17,2 milhões de investidores, um crescimento de 37,1% no último ano em relação ao número de pessoas físicas investindo em ações e outros tipos de renda variável (ESTADÃO, 2023). Entretanto, obter ganhos muitas vezes é um desafio devido à volatilidade de preços das ações. Sendo assim, ferramentas que possam auxiliar na tomada de decisões, determinando qual o melhor momento para compra ou venda se tornam fundamentais. Existem muitos estudos feitos na tentativa de compreender essa volatilidade do preço de ações e ajudar na decisão de compra e venda. Principalmente na área de inteligência artificial (VILELA; PENEDO; PEREIRA, 2018). Tendo isso em mente, este trabalho buscou desenvolver modelos preditivos com base na rede neural *Long Short-Term Memory* (LSTM) para prever a tendência diária dos preços de ações do mercado brasileiro.

2. FUNDAMENTAÇÃO TEÓRICA

Inteligência artificial é uma área de conhecimento que busca desenvolver ferramentas que simulam capacidades humanas, como tomar decisões e resolver problemas. Uma abordagem especialmente poderosa nesse campo é o uso de redes neurais artificiais. Redes neurais são técnicas criadas que usam como inspiração a estrutura do cérebro humano, devido a forma que ele processa

¹Bolsista PIBIC/CNPq, IFSULDEMINAS – *Campus* Poços de Caldas. E-mail: leandro.augusto@alunos.ifsuldeminas.edu.br.

²Orientador, IFSULDEMINAS – *Campus* Poços de Caldas. E-mail: douglas.braz@ifsuldeminas.edu.br

as informações. Ao aplicar o aprendizado de máquina a essa estrutura, as redes neurais podem ser treinadas para reconhecer padrões em conjuntos de dados, aprender com exemplos e, posteriormente, tomar decisões ou fazer previsões.

A arquitetura LSTM é um tipo de rede neural recorrente que seu diferencial é poder guardar grandes sequências de dados (SIAMI-NAMINI *et al.*, 2019). Ela possui unidades de memória chamadas células que dentro existem gates, *input*, *forget* e *output*. Isso permite controlar o fluxo de informações da rede neural, descartando as informações dos dados que são inúteis e mantendo as úteis. Ademais, este processo permite a memorização de múltiplas dependências de tempo com diferentes características (LINDEMANN *et al.*, 2021).

3. MATERIAL E MÉTODOS

Os dados usados neste trabalho foram coletados do site Yahoo Finance. Foram selecionados 5 ativos financeiros, sendo eles escolhidos com base em sua participação no índice Ibovespa. Os ativos usados foram: Ambev (ABEV3), Banco Bradesco (BBDC4), Itaú Unibanco (ITUB4), Petrobrás (PETR4) e Vale (VALE3). Destes ativos, foram usados o histórico de fechamento diário do período entre maio de 2013 e maio de 2023. Os dados coletados foram: valor de abertura (*Open*), valor mais alto (*High*), mais baixo (*Low*) e valor de fechamento (*Close*). Em acréscimo, para tornar a base de dados mais robusta, foram criados indicadores de análise técnica com base no valor de fechamento dos ativos. Indicadores de análise técnica são ferramentas usadas no mercado financeiro para auxiliar na tomada de decisão. Os indicadores usados foram: ADX (*Average Directional Index*), ATR (*Average True Range*), CCI (*Commodity Channel Index*), CMO (*Chande Momentum Oscillator*), DX (*Directional Movement Index*), EMA (*Exponential Moving Average*), MACD (*Moving Average Convergence Divergence*), Midpoint, ROC (*Rate of Change*), RSI (*Relative Strength Index*), TEMA (*Triple Exponential Moving Average*), Trix (*Triple Exponential Average*), SMA (*Simple Moving Average*), WMA (*Weighted Moving Average*).

Os dados foram separados em porções de treino e teste como forma de validação. Isso é útil porque os modelos usam os dados de treino para aprender e as de teste para avaliar o desempenho do modelo. Além disso, foi feita uma janela deslizante, para deslizar através dos dados usando janelas de tamanhos fixos. Sendo feita uma janela de 5 e outra de 22 para representar os fechamentos semanais e mensais, respectivamente. O valor que foi comparado à saída do modelo foi uma *feature Target*, criada com valores binários, quando a ação aumentou seu preço em relação ao dia anterior é 1, caso contrário é 0. Assim, as saídas dos modelos tentam prever essa variação. Como comparativo, foi criado um algoritmo de baseline, que é um método simples usado como referência para saber os valores mínimos a se obter. Por fim, foi feita uma simulação do retorno, que é um cálculo dos lucros ou prejuízos acumulados ao longo do tempo baseado nas previsões feitas.

4. RESULTADOS E DISCUSSÕES


Como forma de avaliar os resultados dos modelos desenvolvidos, 5 métricas de avaliação foram usadas: Acurácia, Precisão, Recall, F1 Score, AUC Score (JUNIOR *et al.*,2022)

Tabela 1 - Modelo LSTM

		Baseline (%)	Semanal (%)	Mensal (%)
ABEV3	Acurácia	51,25	53,22	52,98
	Precisão	51,25	56,09	54,55
	Recall	51,25	53,82	53,50
	F1 Score	51,25	41,57	40,42
	AUC Score	50,00	51,55	50,69
BBDC4	Acurácia	50,56	53,92	52,80
	Precisão	50,56	54,33	52,81
	Recall	50,56	54,48	52,98
	F1 Score	50,56	51,33	52,39
	AUC Score	50,00	53,14	52,13
ITUB4	Acurácia	50,36	51,74	51,28
	Precisão	50,36	54,14	53,55
	Recall	50,36	52,42	51,60
	F1 Score	50,36	46,42	39,48
	AUC Score	50,36	52,12	51,38
PETR4	Acurácia	50,72	51,03	53,04
	Precisão	50,72	52,14	52,94
	Recall	50,72	51,21	53,50
	F1 Score	50,72	45,26	48,31
	AUC Score	50,00	50,39	52,38
VALE3	Acurácia	50,32	48,15	47,14
	Precisão	50,32	48,15	47,08
	Recall	50,32	48,36	47,45
	F1 Score	50,32	47,97	47,46
	AUC Score	50,00	47,69	47,56

Fonte: O autor (2023)

Gráfico 1 - Simulação do Retorno LSTM



Fonte: O autor (2023)

Avaliando as métricas obtidas na Tabela 1, é possível notar que os resultados dos modelos LSTM tiveram melhor desempenho em relação ao baseline na maioria das métricas, para fechamentos semanais e mensais. Em ambos os casos, houve um aumento na acurácia para a maioria das ações avaliadas, indicando que os modelos foram capazes de fazer previsões mais precisas na tendência dos preços. Apesar disso, para a ação VALE3 os resultados foram abaixo do esperado, ficando abaixo do baseline. Quanto à simulação de retorno apresentada no Gráfico 1, os resultados se mostraram muito baixos e pouco aplicáveis para tomada de decisões.

5. CONCLUSÃO

Neste trabalho, foram desenvolvidos modelos preditivos baseados no algoritmo LSTM com a finalidade de avaliar seus resultados em comparação ao baseline. Os resultados obtidos mostraram que o modelo LSTM apresentou resultados superiores em relação ao baseline para os ativos como ABEV3 e BBDC4, por exemplo. No entanto, para o ativo VALE3, o desempenho do modelo LSTM não foi satisfatório. Quanto às simulações de retorno, os resultados obtidos se mostraram pouco aplicáveis em tomadas de decisões reais tendo em vista a inconsistência de lucro ao longo do tempo. Para trabalhos futuros, uma possibilidade seria ajustar os parâmetros usados nos modelos, na tentativa de obter melhor acurácia das previsões e resultados mais satisfatórios.

REFERÊNCIAS

ESTADÃO. Número de investidores na B3 aumenta em 2022. Investidor Estadão, 2022. Disponível em: <https://investidor.estadao.com.br/mercado/numero-investidores-b3-aumenta-2022/>. Acesso em: 24 jul. 2023.

JUNIOR, Guanis B. Vilela et al. Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. Revista CPAQV–Centro de Pesquisas Avançadas em Qualidade de Vida| Vol, v. 14, n. 2, p. 2, 2022.

LINDEMANN, Benjamin et al. A survey on long short-term memory networks for time series prediction. Procedia CIRP, v. 99, p. 650-655, 2021.

SIAMI-NAMINI, Sima; TAVAKOLI, Neda; NAMIN, Akbar Siami. A comparison of ARIMA and LSTM in forecasting time series. In: 2018 17th IEEE international conference on machine learning and applications (ICMLA). IEEE, 2018. p. 1394-1401.

VILELA, Eunice Henriques Pereira; PENEDO, Antonio Sergio Torres; PEREIRA, Vinícius Silva. Aplicação de Redes Neurais Artificiais na Predição de Preços de Ações por Indicadores Financeiros. Desafio Online, v. 6, n. 2, 2018.