

Avaliação de estratégias de operação em swing trade baseadas em aprendizado de máquina

Evaluation of machine learning-based swing trading strategies

Arthur E. S. Machado¹, Rubio T. C. Viana¹,
Daniel H. Dalip¹, Rodrigo T. N. Cardoso², André da Cruz¹

¹Departamento de Computação, ²Departamento de Matemática
Centro Federal de Educação Tecnológica de Minas Gerais
Av. Amazonas 7675 – Nova Gameleira – Belo Horizonte – MG – Brasil

{arthuresm, rubiotorres15}@gmail.com,
{hasan, rodrigocardoso, dacruz}@cefetmg.br

Abstract. *Carrying out operations on the stock exchange is a complex task, since changes in the most diverse sectors end up impacting the stock market and therefore, several studies in the area of artificial intelligence address this topic with the purpose of facilitating operations. This paper aims to present different strategies supported by the use of algorithms based on supervised learning in order to create an environment conducive to capital appreciation. Three strategies were developed for four assets from different segments listed on B3 between 2009 and 2021. The LSTM model was adopted as the algorithm for forecasting future values from the time series of the market and its indicators. The results indicate that the proposed strategy can generate profit in more than 70% of operations, obtaining an overall return greater than other investments used as a comparison, considering contributions between the years between 2012 and 2021. **Keywords:** Swing-Trade Strategies, Supervised Learning, Stock Exchange, LSTM.*

Resumo. *Realizar operações na bolsa de valores é uma tarefa complexa, uma vez que alterações nos mais diversos setores acabam impactando o mercado acionário e, por isso, diversos estudos na área de inteligência artificial abordam esse tema com o propósito de facilitar operações. Esse artigo visa apresentar diferentes estratégias apoiadas pelo uso de algoritmos baseados em aprendizado supervisionado com o intuito de criar um ambiente propício à apreciação do capital. Foram trabalhadas três estratégias para quatro ativos de segmentos diferentes listados na B3 entre 2009 e 2021. Foi adotado o modelo LSTM como o algoritmo para previsão de valores futuros a partir das séries temporais do mercado e seus indicadores. Os resultados apontam que a estratégia proposta pode gerar lucro em mais de 70% das operações, obtendo um retorno geral maior que outros investimentos utilizados como comparação, considerando aportes entre os anos entre os anos de 2012 e 2021. **Palavras-chave:** Estratégias de Swing-Trade, Aprendizado supervisionado, Bolsa de valores, LSTM.*

1. Introdução

O mercado de capitais é uma divisão do mercado financeiro que possibilita a captação de recursos para financiamento de projetos internos das empresas por meio da divisão so-

cietária a novos acionistas. Tendo em vista a complexidade e volatilidade do mercado ao precificar os papéis, surgiu a necessidade de recorrer a conjuntos de indicadores de qualidade que possibilitam avaliar tendências de mercado e assim, proporcionar ao investidor um ambiente propício à apreciação do capital investido. Tais indicadores podem ser elencados em duas análises principais: a fundamentalista e a técnica [Nti et al. 2019]. Este trabalho se baseia no uso da análise técnica, que fornece um conjunto de indicadores de *timing* que podem sinaliza bons momentos para comprar ou vender uma ação. Entretanto, a avaliação destes indicadores é sensível a erros inerentes à capacidade humana, o que poderá ocasionar em operações com depreciação do capital.

Há estudos sobre formas de capitalização no mercado de valores mobiliários há pelo menos 300 anos [Beattie 2020]. Entretanto, ferramentas computacionais com algoritmos de aprendizagem de máquina, que até pouco tempo eram restritas e representavam um risco ainda maior para a análise de ativos [Graham 2017], vêm ganhando notoriedade com o poder de processamento crescente, aliado ao avanço de técnicas que fazem uso de modelos de inteligência artificial.

O presente trabalho realiza um estudo de três estratégias de operação na bolsa de valores brasileira, visando a previsão de preço futuro por meio de um método de aprendizado e critérios de operação bem definidos. O uso de algoritmos baseados em aprendizado supervisionado com as séries temporais existentes no mercado podem ser interessantes na elaboração de estratégias de operação [Ahmadi et al. 2018], visto que erros de cálculos são menos recorrentes quando comparado ao critério de avaliação a cargo do investidor. Assim, a diminuição do número de erros em operações, proporcionam maior potencial de retorno do capital investido com mais operações vencedoras.

As principais contribuições deste trabalho são um conjunto de estratégias de operação básicas e objetivas que podem servir de comparação com outras mais robustas no futuro, e um arcabouço que define um padrão de construção, reutilização e avaliação de estratégias de operação, com métricas relevantes para o investidor/pesquisador.

As demais seções deste texto são organizadas da seguinte forma: a Seção 2 apresenta uma visão dos trabalhos que são base do estudo; a Seção 3 mostra o arcabouço proposto para a realização do estudo e o método que o acompanha; a Seção 4 aponta os experimentos realizados para avaliação das estratégias bem como o resultado da pesquisa; por fim, a Seção 5 conclui o estudo.

2. Trabalhos relacionados

Ao estudar propostas envolvendo o mercado financeiro comumente se utiliza a análise técnica, que tem como foco as operações realizadas em um dado intervalo de tempo, considerando o preço e o volume das operações, por exemplo. O estudo e aplicação dos indicadores técnicos tem se destacado nos últimos anos, representando 66% das pesquisas relevantes publicadas entre 2007 e 2018 [Nti et al. 2019].

A utilização de indicadores combinados e a modelagem de um algoritmo de aprendizado supervisionado apresentam potencial de precisão de tendência acima de 50% para criar um ambiente propício à apreciação do capital alocado [Anbalagan and Maheswari 2015] [Guijarro 2020]. Os principais tipos de algoritmos foram baseados em aprendizado profundo, mas entre os métodos tradicionais que não utilizam redes neurais, a utilização

do SVM apresenta acurácia acima de 60% na previsão de tendências [Kumar 2018]. O modelo LSTM (*Long Short-Term Memory*) possui destaque em sua acurácia quando comparado com outros algoritmos como *Multi-Layer Perceptron* e *Random Forest* [Nelson et al. 2017].

Os métodos de regressão são mais comuns e possuem como foco a previsão dos preços e os de classificação para previsão de tendências do ativo [Ferreira et al. 2021]. No quesito avaliação dos modelos gerados, a utilização da janela deslizante se apresentou fundamental para validação e teste dos períodos, bem como agrupar padrões de precificação no curto prazo [Ferreira et al. 2020]. A janela deslizante, nesse cenário, consiste em agrupar um conjunto de dados sobre as operações diárias do mercado a fim de representar uma instância do conjunto.

3. Arcabouço Proposto

Este trabalho seguiu um conjunto de etapas que foram desenvolvidas utilizando a linguagem *python* para propor o arcabouço estruturado de avaliação de estratégias de operação na bolsa de valores. Na primeira etapa do estudo realizou-se uma coleta de dados extraindo-se os preços de abertura, mínimo, máximo, mínimo e fechamento, além do volume de negociações para a entrada do processamento de indicadores técnicos. Com a construção dos *folds* e janelas deslizantes, é gerado o modelo que retorna o preço dos dias preditos (entrada para definição dos sinais de operação). A partir dos sinais de operação, a estratégia inicia sua execução simulando operações de compra e venda no período.

Cada instância de dados é referente a um dia de pregão, que corresponde ao período em que os investidores podem realizar operações de compra e venda na bolsa de valores. Conforme apresentado pela Figura 1, com uma instância coletada computa-se um conjunto de indicadores que será utilizado também para a criação do modelo LSTM, que é responsável pela previsão de tendência de preços. Dessa forma, como resultado, o modelo determina as possíveis estratégias de operação. Ao final, faz-se uma avaliação das estratégias que o modelo executou ao longo da simulação preditiva.

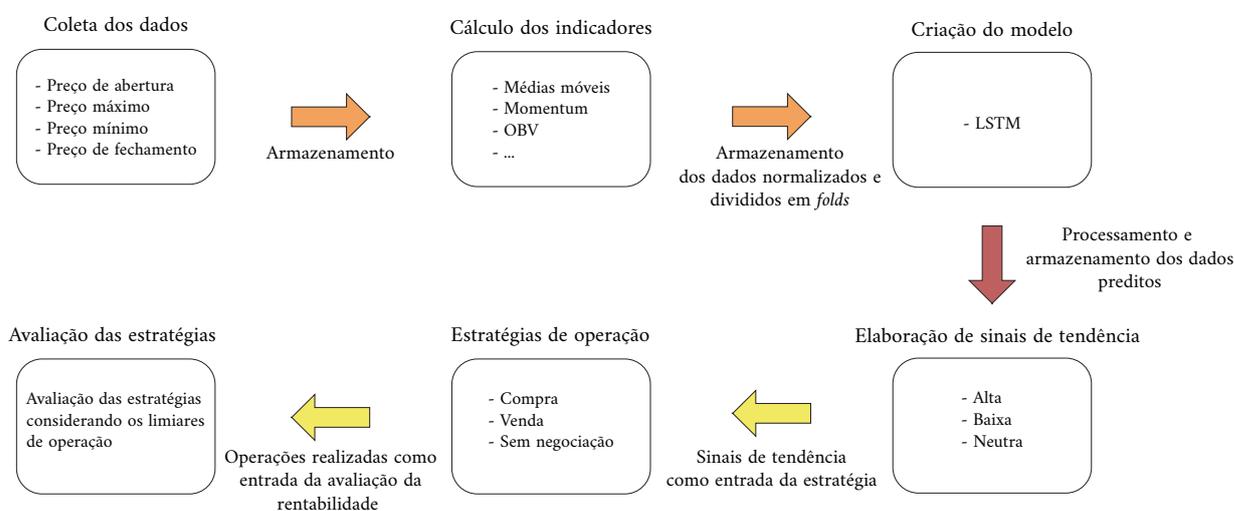


Figura 1. Estrutura de desenvolvimento do trabalho

3.1. Indicadores técnicos

A análise técnica, com seu conjunto de indicadores, é usada a fim de antecipar movimentos ou entender o sentimento de mercado. Com isso, pode-se ter a sensação de tendências de alta (baixa) nos preços, representando um sentimento otimista (pessimista), dependendo do perfil do investidor.

Neste trabalho, considere t o instante de referência para utilização do preço de fechamento e n o número passado de dias a partir do instante de referência para o dado determinado. Com os dados dos preços e volume disponíveis foram gerados e armazenados os indicadores técnicos [Edwards et al. 2018], que também são entrada do modelo: média móvel simples (20 dias), média móvel exponencial (20 dias), *momentum* (12 dias), MACD (12 e 26 dias via média móvel exponencial), oscilador estocástico %K (14 dias), Willians %R (14 dias), IFR (14 dias) e OBV. Os parâmetros dos indicadores são valores comumente usados na literatura.

3.2. Modelo

Após a construção da base de entrada, iniciou-se o treinamento do modelo para a previsão do preço de fechamento que compreendeu um dia após os cinco correspondentes à janela. Esse preço predito foi armazenado, para posteriormente gerar os sinais.

Os dados de entrada para o algoritmo de aprendizado foram construídos para transformar o problema que envolve séries temporais em uma estrutura supervisionada com dados multivariados para regressão. Os dados que seguem uma sequência temporal são separados em subconjuntos para fornecer uma instância de entrada do modelo, que preverá o preço de fechamento futuro. Para o problema em questão, o mais relevante é que ele consiga identificar as tendências de forma diária.

A Figura 2 fornece a representação de uma instância entrada do modelo. Seja x_{at} o vetor que representa o conjunto de indicadores técnicos em um determinado instante t de um determinado ativo a . Foi determinado um padrão a ser avaliado, no qual são utilizados cinco dias (em que cada dia possui os preços e indicadores) como entrada do modelo a fim de prever preço de fechamento do próximo dia.

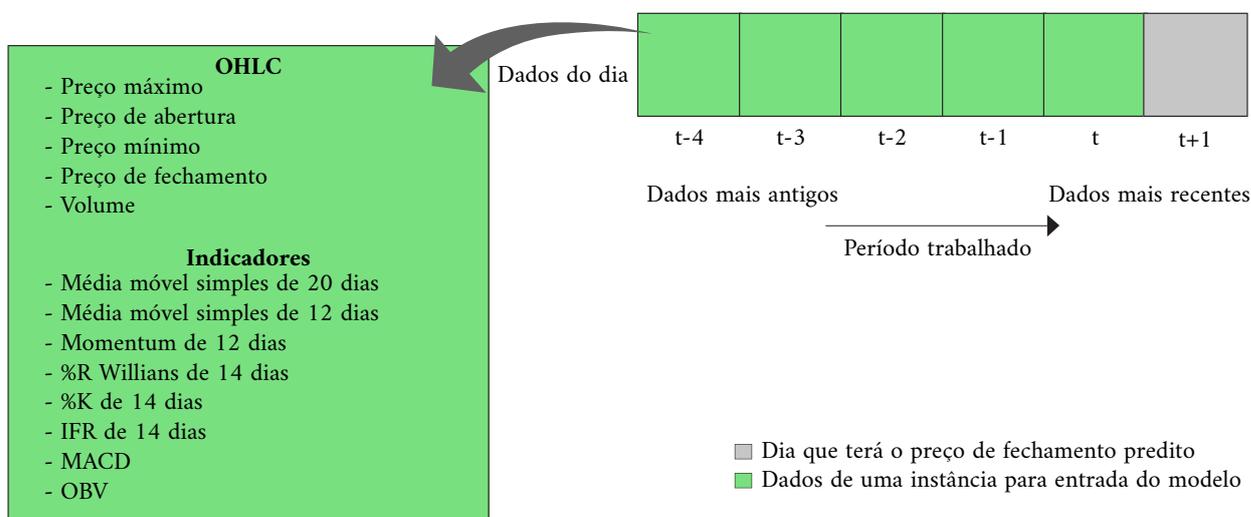


Figura 2. Instância de entrada do modelo

Para gerar o modelo, os dados passaram por uma etapa de normalização, via *Z-score* [Altman et al. 2017], para redimensionar cada variável de entrada do modelo para uma média 0 e desvio padrão 1. Por fim, o agrupamento de dados define um limite com o qual o modelo terá que trabalhar para cada instância, delimitando também os padrões da série temporal.

Em seguida, um conjunto de instâncias formaram os *folds*, também construídos no formato de janela deslizante. Após a criação dos respectivos *folds*, 90% de cada conjunto de dados foi utilizado como treino e validação, o restante ficou como dados de teste para avaliação do modelo.

Além disso, é dito que os modelos de aprendizado envolvendo redes neurais não possuem limitações para a previsão de dados dependência temporal conturbada [Brownlee 2018]. Para construção da pesquisa foi utilizado o modelo LSTM (*Long short-term memory*) que é um tipo de rede neural recorrente (RNN) do tipo aprendizado profundo e a arquitetura adotada segue o padrão de duas camadas empilhadas [Menon et al. 2019].

Os modelos foram criados com o auxílio da biblioteca TensorFlow [ten], utilizando os critérios de qualidade *erro médio absoluto*, que indica o quão a previsão está distante do valor real em média, e o *erro percentual médio absoluto*, para auxiliar no problema do erro numérico da amostra.

3.3. Sinais de Tendência

Tendo em vista o preço predito e o conhecimento do preço de fechamento atual, é possível criar um sinal de tendência que auxiliará as estratégias de operação. A Equação 1 apresenta o formato de definição de cada sinal de compra ou venda, que são gerados a partir da comparação entre o preço de fechamento atual e o predito. Considere, t o tempo instante de referência do preço de fechamento, p_{f_t} o preço de fechamento atual, L_c o limiar de compra e L_v o limiar de venda.

$$\begin{cases} \text{Sinal de venda,} & \text{se } \text{abs}\left(\frac{p_{t+1}}{p_t} - 1\right) \leq L_v. \\ \text{Sinal de compra,} & \text{se } \left(\frac{p_{t+1}}{p_t} - 1\right) \leq L_c \\ \text{Sinal de neutro,} & \text{se não atendeu a } L_v \text{ ou } L_c \end{cases} \quad (1)$$

Desse modo, é gerado um sinal de compra se o preço de fechamento previsto (futuro) for maior ou igual ao preço de fechamento atual, e um sinal de venda caso seja menor. Um sinal neutro ocorre quando o preço não excede os limiares de compra e venda definidos para a estratégia.

Neste trabalho são investigados o comportamento das seguintes combinações de limiares de compra e venda (L_c, L_v): (i) (0,0000; 0,0000), (ii) (0,0250, 0,0125), e (iii) (0,0500, 0,0250).

3.4. Execução da estratégia

Uma vez que os sinais de tendência foram computados, uma operação pode ser simulada considerando o preço de abertura do dia predito para negociação. A estratégia base de operação consistiu nas seguintes regras de operação: Compra-se em todo o sinal de compra e fecha a posição (realiza a venda de todas as ações compradas) no primeiro sinal de

venda. Por outro lado, a operação de venda, exige que tenha ações disponíveis para venda (não será tratado nesse contexto operações de venda a descoberto) e que seja um sinal de venda. A variação da estratégia decorre da mudança dos limiares de compra e venda trabalhados.

4. Experimentos

A seguintes subseções relatam a construção da base de dados, o processo de avaliação das estratégias, e os resultados com a respectiva análise.

4.1. Base de dados

Os dados iniciais foram coletados utilizando a biblioteca *yahooquery*. Pelo período de 02/01/2009 a 20/08/2021 (3130 dias de operação), distribuídos em 15 *folds*, os ativos selecionados para compor a pesquisa foram Petróleo Brasileiro S/A (PETR4), Itaúsa S/A (ITSA4), Oi S/A (OIBR3) e Via Varejo S/A (VIA3).

Tais ativos são de setores diversos e com uma alta negociação diária na B3. Além disso, é importante ressaltar a diversificação dos ativos selecionados possuem potencial de redução do risco não sistemático de uma carteira .

Para treinamento, teste e avaliação das estratégias foram utilizados 15 *folds* divididos de maneira igualitária entre as datas de 27/06/2012 a 19/08/2021. Cada *fold* possui aproximadamente 90 dias de operação, representando meses de operação em sequência. No presente trabalho não será considerada a distribuição de lucro aos acionistas, somente os resultados provenientes das negociações.

4.2. Avaliação

Com a execução das estratégias é possível estimar os resultados obtidos durante o período de negociação utilizado para o *backtest*, que é uma técnica que permite a execução de estratégias de operação utilizando dados passados a fim de avaliar lucros e prejuízos durante as negociações.

É importante ressaltar que analisar a acurácia dos sinais quando comparados com a tendência real para as estratégias e seus limiares, analisar a rentabilidade de cada ativo em seus respectivos períodos de operação para cada limiar trabalhado, examinar a rentabilidade de cada período de operação em relação aos demais investimentos, examinar a rentabilidade acumulada em relação aos demais investimentos e avaliar o efeito na alteração dos limiares no número médio de operações, conduz os estudo dos resultados obtidos pelas estratégias.

4.3. Resultados

Nesta seção, serão apresentados os resultados gerais da pesquisa para os 15 *folds* e seus respectivos dados de teste.

4.3.1. Acurácia

A acurácia média entre os *folds* de cada papel para os sinais de tendência dado os sinais esperados está apresentada na Tabela 1. Como a previsão do modelo tem influência direta

sobre o sinal, foi incluída uma base de comparação que utiliza o modelo com uma época de treinamento, com os mesmos dados de entrada. O cálculo da acurácia decorre da comparação do sinal predito para o instante t e o sinal esperado. Dado todos os sinais, é possível estimar a porcentagem de acertos dos sinais provenientes da estratégia que recebe como entrada a previsão do modelo.

Papel	Limiar de compra	Limiar de venda	Número de épocas	Acurácia (%)
ITSA4	0	0	1	54,24
			250	87,86
	0,025	0,0125	1	47,16
			250	83,45
	0,05	0,025	1	41,62
			250	81,40
OIBR3	0	0	1	55,67
			250	76,79
	0,025	0,0125	1	47,20
			250	70,38
	0,05	0,025	1	43,82
			250	67,65
PETR4	0	0	1	57,58
			250	88,97
	0,025	0,0125	1	47,56
			250	83,68
	0,05	0,025	1	41,81
			250	79,16
VIA3	0	0	1	54,40
			250	71,37
	0,025	0,0125	1	38,70
			250	61,45
	0,05	0,025	1	38,61
			250	67,18

Tabela 1. Comparativo da acurácia média entre os *folds* de cada papel para diferentes limiares de operação e épocas para o modelo.

Em todos os cenários, a acurácia média para os modelos com 250 épocas obteve um resultado melhor que os casos de modelo com 1 época. Isso sugere que ao longo das interações o modelo conseguiu captar particularidades das séries temporais que realmente contribuem na previsão de uma tendência do mercado, levando em consideração o formato de janela deslizante apresentado em 3.2.

Além disso, é possível observar que à medida que os limiares de operação ficam mais restritivos (exigindo uma maior ascensão ou recessão dos preços, portanto com limiares maiores), a acurácia diminui.

4.3.2. Rentabilidade

O cálculo da rentabilidade ocorre, neste trabalho, pela comparação entre a quantidade de capital aportado ao longo do período e a quantidade de capital total após o fechamento de

todas as posições. Com isso, quando o capital total é maior que o capital aportado, temos um período de apreciação e caso contrário, um período de depreciação.

As Figuras 3 e 4 apresentam a rentabilidade de cada período para os ativos estudados considerando cada conjunto de limiares trabalhados. É possível observar que a combinação de limiares menos restritiva (0% e 0%), apresentada na Figura 3, gerou um ponto de prejuízo maior para VIIA3, mas possui apenas três pontos de prejuízo. A estratégia apresentada pela Figura 4 possui a maior rentabilidade de um período para o ativo OIBR3, contando com apenas três pontos de prejuízo.



Figura 3. Rentabilidade de cada *fold* para um limiar de compra e venda em 0% e 0% respectivamente.

Simulando uma carteira em que as operações de compra e venda envolvem somente os ativos no contexto desse trabalho, foram criadas as Figuras 5 e 6. A primeira apresenta a rentabilidade por período dada a composição dos ativos em uma carteira, enquanto a segunda apresenta a rentabilidade acumulada. Ambas trazem um comparativo dos limiares em relação a aportes no ETF BOVA11 (um fundo atrelado ao índice Ibovespa) e operações nos papéis considerando *buy and hold* (estratégia de operação que consiste em comprar e segurar o ativo até o final do período) para o período de cada *fold*. No caso dos investimentos em BOVA11 e utilizando a estratégia *buy and hold*, os períodos de novos aportes estão no início de cada *fold* e não ao longo do *fold*, como trabalham as estratégias. Com isso, foi realizada a compra no primeiro dia de operação do *fold* e a venda no último.

Cada intervalo de datas no eixo *x* representa um conjunto de dados de teste para um determinado *fold*. No caso da rentabilidade independente de cada período, apresentada na Figura 5, é possível observar que a oscilação para as estratégias é muito menor que para os outros dois formatos de investimento (*Buy and hold* e BOVA11). Em todos os *folds* as estratégias registraram rentabilidade positiva enquanto as demais registraram

Rentabilidade por período / L.C. - 0.025, L.V. 0.0125

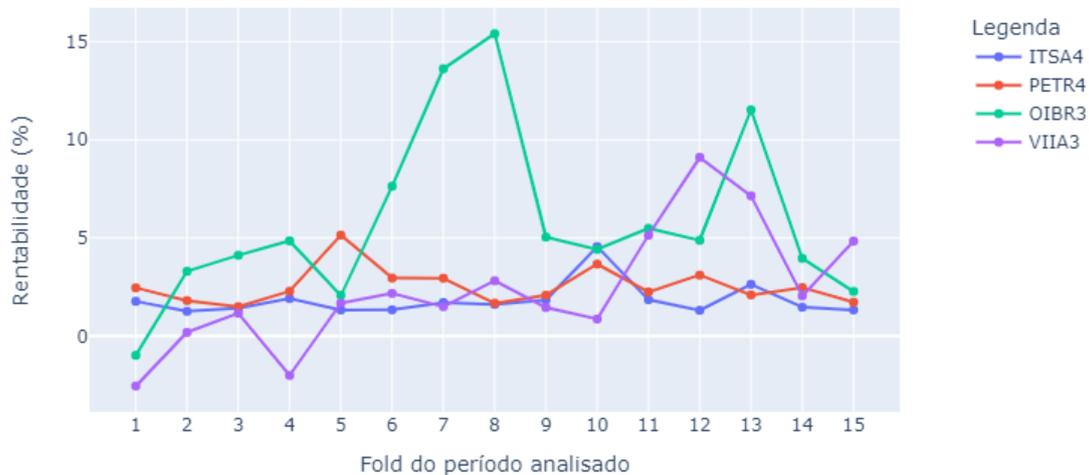


Figura 4. Rentabilidade de cada *fold* para um limiar de compra e venda em 2.5% e 1.25% respectivamente.

Rentabilidade das estratégias (em carteira) - Por período

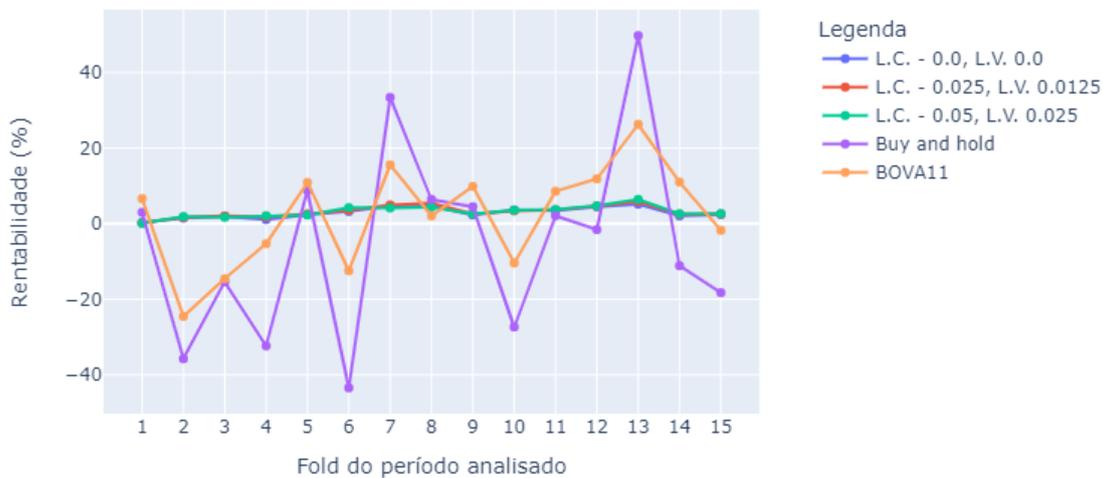


Figura 5. Rentabilidade da carteira para cada período.

prejuízo em oito dos quinze períodos trabalhados, cada uma.

Para a rentabilidade acumulada, apresentada na Figura 6, é possível observar que utilizando a estratégia de operação e seus limiares, a dispersão dos dados foi menor que as operações sobre BOVA11 e sobre os próprios papéis considerando *buy and hold*. Enquanto a estratégia ficou entre -5% e 5% nos dois cenários, operações em BOVA11 e *buy*

Rentabilidade acumulada das estratégias (em carteira)



Figura 6. Rentabilidade acumulada da carteira e outros formatos de investimento.

and hold alcançaram -20% de depreciação, que prejudicaram a rentabilidade até o final do período de estudo. Isso sugere que ao utilizar a estratégia de operação, o investidor estaria menos exposto ao risco de ter seu capital depreciado na mesma medida que um índice como o Ibovespa ou utilizando *buy and hold*.

Por fim, a rentabilidade de cada estratégia é apresentada na Tabela 2. Apesar da redução na acurácia pela combinação mais restritiva de limiares, apontada na subseção 4.3.1, a rentabilidade acumulada final das três estratégias possui valores muito próximos e por isso não seria um critério tão forte para desempate e utilização no mundo real.

Limiar de compra	Limiar de venda	Rentabilidade
0 (0%)	0 (0%)	2,87
0,025 (2,5%)	0,0125 (1,25%)	3,14
0,05 (5%)	0,025 (2,5%)	3,13

Tabela 2. Rentabilidade final acumulada da carteira para cada estratégia ao longo dos períodos de operação.

4.4. Sinais e limiares

Ao trabalhar com operações no mercado financeiro, é necessário se atentar ao número de negociações que serão realizadas, uma vez que existem medidas que isentam o investidor de pagar mais impostos até um limite e muitas corretoras ainda cobram taxa de corretagem por negociação. Com base nisso foi criada a Tabela 3 a fim de visualizar como os limiares da estratégia afetam nesse quesito.

É possível observar que à medida que o limiar é elevado, o número médio de operações cai, comprovando a ideia de que, quanto maior o retorno esperado, elencado

Papel	Limiar de compra	Limiar de venda	Número médio de operações
ITSA4	0	0	90,53
	0,025	0,0125	85,73
	0,05	0,025	80,20
OIBR3	0	0	90,53
	0,025	0,0125	80,93
	0,05	0,025	73,53
PETR4	0	0	90,53
	0,025	0,0125	85,00
	0,05	0,025	78,47
VIIA3	0	0	90,53
	0,025	0,0125	76,87
	0,05	0,025	67,40

Tabela 3. Comparativo do número médio de operações de compra e venda considerando os limiares trabalhados.

por um sinal de operação, menor o número de sinais que corroboram com esse retorno, já que é mais frequente uma ascensão de 2.5% que uma de 5%, considerando o intervalo de um dia. Ademais, o número médio de operações quando ambos os limiares possuem valor zero, corresponde ao número médio de sinais criados em cada papel, uma vez que o sinal neutro não existe nesse caso. Em um cenário que o investidor possui taxas de corretagem (cobrança da corretora para realizar a operação), pode ser interessante utilizar de estratégias mais restritivas, a fim de ter um menor número de operações e alocar uma menor quantidade de capital para essa finalidade.

5. Conclusão

Este trabalho apresentou estratégias, via rede neural LSTM, para um horizonte de tempo específico no qual os principais resultados foram definir um método padronizado para avaliação de estratégias de operação por meio do arcabouço. Foi possível observar que, estratégias simples, como as trabalhadas não conseguem obter lucros extraordinários e podem perder em cenários que a taxa SELIC ou outros investimentos em renda fixa estão em alta. Além disso, os resultados das estratégias foram consistentes, sem muita variação do capital alocado, quando comparado aos formatos *buy and hold* e aportes em BOVA11 e não obteve grandes prejuízos em períodos de recessão econômica (como por exemplo a pandemia de 2020). Foi visto também que se manteve consistentemente na apreciação do capital ao longo dos períodos trabalhados.

6. Trabalhos futuros

Como evolução do presente trabalho, em futuros casos é possível trabalhar com a otimização de parâmetros (épocas do modelo e limiares de operação para a estratégia), avaliar estratégias mais eficientes, que consideram tendências de mais de um dia, estudar estratégias que levam em consideração a posição atual e não somente o sinal de tendência, possibilitando avaliar o melhor momento para um novo aporte, analisar o impacto dos momentos de reversão na precificação do ativo, nas operações realizadas, considerar o risco

para realização de operações, utilizar novos modelos para predição dos preços, comparar modelos que preveem preços no formato de regressão e modelos construídos para categorização de tendência do período, otimizar a alocação de capital por ativo.

Referências

- Tensorflow. <https://www.tensorflow.org/>. Acessado em: 02 de fev. de 2021.
- Ahmadi, E., Jasemi, M., Monplaisir, L., Nabavi, M., Mahmoodi, A., and Jamd, P. (2018). New efficient hybrid candlestick technical analysis model for stockmarket timing on the basis of the support vector machine and heuristic algorithms of imperialist competition and genetic. *Expert Systems with Applications*.
- Altman, E. I., Iwanicz-Drozdowska, M., Laitinen, E. K., and Suvas, A. (2017). Financial distress prediction in an international context: A review and empirical analysis of altman's z-score model. *Journal of International Financial Management & Accounting*, 28(2):131–171.
- Anbalagan, T. and Maheswari, S. (2015). Classification and prediction of stock market index based on fuzzy metagraph. *Procedia Computer Science* 47.
- Beattie, A. (2020). The birth of stock exchanges. Investopedia. Acessado em: 10 de mar. de 2021.
- Brownlee, J. (2018). *Predict the Future with MLPs, CNNs and LSTMs in Python*. Deep Learning for Time Series Forecasting.
- Edwards, R. D., Magee, J., and Bassetti, W. C. (2018). *Technical analysis of stock trends*. CRC press.
- Ferreira, F., Gandomi, A., and Cardoso, R. (2020). Financial time-series analysis of brazilian stockmarket using machine learning. *IEEE Symposium Series on Computational Intelligence (SSCI)*.
- Ferreira, F., Gandomi, A., and Cardoso, R. (2021). Artificial intelligence applied to stock-market trading: A review. *IEEE Access (Volume: 9)*.
- Graham, B. (2017). *The Intelligent Investor (4.ed. rev.)*.
- Guijarro, F. (2020). Forecasting stock market trend: a comparison of machine learning algorithms. *Finance, Markets and Valuation*.
- Kumar, I. (2018). A comparative study of supervised machine learning algorithms for stock market trend prediction. *IEEE Xplore Compliant*.
- Menon, A., Singh, S., and Parekh, H. (2019). A review of stock market prediction using neural networks. In *2019 IEEE International Conference on System, Computation, Automation and Networking (ICSCAN)*, pages 1–6. IEEE.
- Nelson, D., Pereira, A., and Oliveira, R. (2017). Stock market's price movement prediction with lstm neural networks. In *2017 International Joint Conference on Neural Networks (IJCNN)*.
- Nti, I., Adekoya, A., and Weyori, B. (2019). A systematic review of fundamental and technical analysis of stock market predictions. *Springer Nature B.V.*