

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
UFGD

**Aplicação de Redes Neurais LSTM para Previsão de Séries
Temporais Financeiras**

Autor(a): Jhonatan Correa Leandro
Orientador: Prof. Dr. Willian Paraguassu Amorim

Dourados
Mato Grosso do Sul
Novembro - 2021

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
UFGD

Aplicação de Redes Neurais LSTM para Previsão de Séries Temporais Financeiras

Autor(a): Jhonatan Correa Leandro
Orientador: Prof. Dr. Willian Paraguassu Amorim

Trabalho de Conclusão de Curso apresentado para obtenção do grau de Bacharel em Engenharia de Computação, Faculdade de Ciências Exatas e Tecnologia, Universidade Federal da Grande Dourados.

Dourados
Mato Grosso do Sul
Novembro - 2021



MINISTÉRIO DA EDUCAÇÃO
FUNDAÇÃO UNIVERSIDADE FEDERAL DA GRANDE DOURADOS

AVALIAÇÃO DE PROJETO DE TCC OU TCC

TÍTULO DO TRABALHO: Aplicação de Redes Neurais LSTM para Previsão de Séries Temporais Financeiras

NOME DO(S) ESTUDANTE(S): Jhonatan Correa Leandro



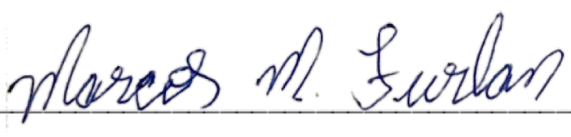
ORIENTADOR: Prof. Dr. Willian P. Amorim

CO-ORIENTADOR(A):

DATA DA APRESENTAÇÃO: 12/11/2021

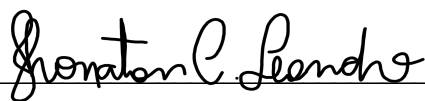
HORÁRIO: 08hs

AVALIAÇÃO DA COMISSÃO EXAMINADORA:

<input type="checkbox"/> Trabalho de Conclusão de Curso I	<input checked="" type="checkbox"/> Trabalho de Conclusão de Curso II
Presidente: Prof. Dr. Willian P. Amorim	
Assinatura: 	
Membro 1: Prof. Me. Carlos Elias Arminio Zampieri	
Assinatura: 	
Membro 2: Prof. Dr. Marcos Mansano Furlan	
Assinatura: 	
Resultado:	<input checked="" type="checkbox"/> Aprovado <input type="checkbox"/> Aprovado condicionado a modificações (especificar no campo observações) <input type="checkbox"/> Reprovado

Observaçõesⁱ:

Eu, Jhonatan Correa Leandro, Orientador Prof. Dr. Willian P. Amorim, e Coordenador do Curso Prof. Dr. Marcos Paulo Moro, declaramos para os devidos fins que estamos de acordo com a defesa do Trabalho de Conclusão de Curso, seja no formato remoto usando Google Meet, e que a mesma será gravada.



Estudante 1 (assinatura)

Estudante 2 (assinatura)

Coordenador(a)

Bacharelado em Engenharia da Computação

ⁱ Conforme **RESOLUÇÃO NÚMERO 106 de 29/06/2020 - Art. 5º** As defesas de Trabalho de Conclusão de Curso (TCC) deverão ocorrer por meio remoto (Google Meet, Skype, Zoom, entre outros) quando houver concordância, por escrito, entre a coordenação de curso, o docente orientador e o estudante.

Resumo

Realizar previsões no mercado financeiro pode trazer um imenso ganho para instituições, governos, investidores, entre outros. Entretanto não é uma tarefa trivial, devido à natureza caótica e imprevisível do mercado financeiro. Várias abordagens já foram estudadas com o propósito de alcançar resultados satisfatórios, como por exemplo, aprendizado de máquina e redes neurais Long Short-Term Memory networks (LSTM) devido a efetividade das mesmas trabalhando com séries temporais. Nesse trabalho, nossa proposta está em usar uma rede neural LSTM e a partir do preço de fechamento usando gráfico renko, e realizar a previsão de alta ou baixa para o próximo movimento do mercado. Resultados mostram que nossa proposta apresenta resultados satisfatórios comparado a técnica tradicional Buy and Hold.

Palavras-chave: aprendizagem profunda, lstm, séries temporais financeiras, mercado financeiro.

Abstract

Making forecasts in the financial market can bring huge gains for institutions, governments, investors, among others. However, it is not a trivial task, due to the chaotic and unpredictable nature of the financial market. Several approaches have already been studied in order to achieve satisfactory results, such as machine learning and neural networks Long Short-Term Memory networks (LSTM) due to their effectiveness working with time series. In this work, our proposal is to use an LSTM neural network and from the closing price using renko chart, and perform the bullish or bearish forecast for the next market movement. Results show that our proposal presents satisfactory results compared to the traditional Buy and Hold technique.

Keywords: deep learning, lstm, financial time series, financial market.

Aplicação de Redes Neurais LSTM para Previsão de Séries Temporais Financeiras

Jhonatan Correa Leandro, Willian Paraguassu Amorim

¹Universidade Federal da Grande Dourados (UFGD)
Dourados – MS – Brasil

jleandroweb@gmail.com, paraguassuec@gmail.com

Abstract. *Making forecasts in the financial market can bring huge gains for institutions, governments, investors, among others. However, it is not a trivial task, due to the chaotic and unpredictable nature of the financial market. Several approaches have already been studied in order to achieve satisfactory results, such as machine learning and neural networks Long Short-Term Memory networks (LSTM) due to their effectiveness working with time series. In this work, our proposal is to use an LSTM neural network and from the closing price using renko chart, and perform the bullish or bearish forecast for the next market movement. Results show that our proposal presents satisfactory results compared to the traditional Buy and Hold technique.*

Resumo. *Realizar previsões no mercado financeiro pode trazer um imenso ganho para instituições, governos, investidores, entre outros. Entretanto não é uma tarefa trivial, devido à natureza caótica e imprevisível do mercado financeiro. Várias abordagens já foram estudadas com o propósito de alcançar resultados satisfatórios, como por exemplo, aprendizado de máquina e redes neurais Long Short-Term Memory networks (LSTM) devido a efetividade das mesmas trabalhando com séries temporais. Nesse trabalho, nossa proposta está em usar uma rede neural LSTM e a partir do preço de fechamento usando gráfico renko, e realizar a previsão de alta ou baixa para o próximo movimento do mercado. Resultados mostram que nossa proposta apresenta resultados satisfatórios comparado a técnica tradicional Buy and Hold.*

1. Introdução

Mercado financeiro é o espaço utilizado para possibilitar que a negociação de produtos financeiros, como por exemplo ações, fundos de investimentos, títulos, câmbio e afins, seja realizada entre investidores e instituições. Todos os dias um grande número de ações de companhias é comprado e vendido ao redor do mundo. De acordo com o Banco Mundial no ano de 2018 o mercado de ações movimentou um montante de 68.212 trilhões de dólares americanos¹.

Podemos perceber que há um grande valor na análise e predição do comportamento do mercado financeiro, mas por outro lado, essa não é uma tarefa trivial, pois os mercados financeiros tendem a ser complexos, caóticos e não-lineares. Como um resultado direto disso ao longo dos anos houveram muitas pesquisas

¹<https://data.worldbank.org/indicator/CM.MKT.TRAD.CD>

nesse campo utilizando técnicas tradicionais com foco na análise técnica, análise fundamentalista, bem como outros tipos de previsão de séries temporais financeiras [Samarawickrama and Fernando 2017]. Na análise técnica os mercados são analisados através de gráficos e dados são obtidos para as previsões dos ativos. Já na análise fundamentalista os investidores se atentam para os aspectos financeiros e econômicos que podem influenciar nos valores do ativo e mais recentemente, tem havido um aumento na utilização de técnicas de aprendizado de máquina.

Métodos tradicionais como: *autoregressive integrated moving average* (ARIMA)[Asteriou and Hall 2011], *support vector machines* (SVM) e *random forest* [Ho 1995], normalmente são utilizados em previsões de séries temporais. Entretanto os altos níveis de ruídos nas séries temporais do preço das ações limitam a eficácia de métodos estritamente estatísticos [Du et al. 2019]. No entanto, existem métodos usando aprendizado profundo, especificamente RNN/LSTM [hoc], cujas características os tornam mais adequados para esse tipo de previsão de séries temporais.

Moghar et al. [Moghar and Hamiche 2020] propõe o uso de LSTM para a previsão de ações da GOOGL e NKE. O modelo treinado, foi capaz de identificar as evoluções nos preços de abertura das duas ações. Em Yadav et al. [Yadav et al. 2020] apresentaram uma otimização em LSTM para previsões no mercado financeiro indiano. Para isso, realizam dois experimentos em que são comparados *stateful* e *stateless* LSTM para quatro diferentes companhias. Os autores concluem que para problemas de previsão de séries temporais o *stateless* LSTM é o mais indicado devido a sua maior estabilidade, com a recomendação de trabalhar com apenas uma camada, além de ser menos complexa para treinar e com menos riscos de sobreajuste.

Em [Du et al. 2019] propõe uma rede LSTM usada para prever os preços de fechamento das ações da Apple, comparando duas abordagens: univariada, onde a entrada é apenas o histórico do preço de fechamento das ações (últimos 20 dias); e multivariada, onde os insumos incluem preço mais alto, preço mais baixo, preço de abertura, volumes de negociação e vários indicadores técnicos. Como esperado, concluiu que a abordagem multivariada possui MAE (Erro Absoluto Médio) menor, em comparação com o método univariado.

Outros trabalhos também foram apresentados, no uso da LSTM na previsão do mercado financeiro. Por exemplo, [Sarode et al. 2019] propõe um sistema de recomendação para ações, usando LSTMs, que combina não apenas dados financeiros da negociação, mas também análise de texto de artigos de notícias relacionados à empresa específica, que são combinados para fazer uma previsão sobre o preço das ações e uma recomendação. No trabalho [Siami-Namini et al. 2019] realizam uma análise e comparação entre ARIMA, LSTM e LSTM bidirecional (BiLSTM) na previsão de séries temporais financeiras. A análise concluiu tanto o LSTM unilateral quando os bilaterais tiveram melhores resultados que o ARIMA. Além de que o BiLSTM consegue apresentar melhores resultados de previsão em relação ao LSTM.

O foco deste artigo será, portanto, investigar a eficácia dos LSTMs, quando aplicados aos dados do mercado de ações, na previsão de preços futuros de ações ou índices, bem como comparar o desempenho de possíveis parâmetros e layouts diferentes da rede.

Estaremos usando como dados de entrada, o gráfico de Renko², usado no mercado financeiro para indicar variações de preço desconsiderando tempo e volume de negociação. Uma de suas vantagens, é padronização do movimento do mercado, e eliminação de dados de lateralidade, muito encontrado nos gráficos de *Candle*.

Este artigo está organizado da seguinte forma. Na Seção 2, estaremos apresentando a fundamentação teórica sobre mercado financeiro. Na Seção 3, apresentaremos as redes long-short term memory. Na Seção 4, experimentos realizados e resultados obtidos. Por fim, na Seção 5, apresenta a conclusão e trabalhos futuros.

2. Mercado Financeiro

O mercado financeiro é um ambiente que possibilita a compra e venda de ações, títulos, câmbio e mercadorias. Para isso temos instituições que são facilitadoras, fiscalizadoras e regulamentadoras dessas negociações. Os dois principais personagens são os investidores e os tomadores. Os tomadores são instituições, empresas que precisam de recurso investido e os investidores são aqueles que injetam dinheiro nas mesmas. Os investidores contam com diversos tipos de análise para que possam desembolsar seus investimentos com uma margem de segurança, entre elas: análise técnica, análise fundamentalista e o trade quantitativo.

2.1. Análise técnica

Na análise técnica acredita-se que os preços possuem movimentos baseados nas frequentes mudanças de atitudes de investidores, mudanças essas que são causadas pela ação de diferentes forças. Os dados geralmente utilizados são: preços, volumes, além de outras características. Todavia a previsão do comportamento de ações é realizado ignorando fatores externos [Roque 2009].

Portanto, o trabalho dos investidores é buscar identificar irregularidades e tendências utilizando gráficos para o estudo. Isso se dá devida a crença de que essas tendências possuem um comportamento cíclico além de serem baseadas nas leis de oferta e procura. A partir dessa análise são obtidos vários indicadores técnicos, indicadores que são utilizados para saber regras de aplicação e entradas, como por exemplo, indicadores de momento, médias móveis, análise de padrões, indicadores de volume, indicadores de filtro, análise de curva de tendência, entre outros.

2.2. Análise Fundamentalista

Em contraposição com a análise técnica, na análise fundamentalista procura-se utilizar não somente as informações sobre histórico de preços, mas também complementar com fatores externos, como por exemplo, questões macro e microeconômicas, patrimônio, capital humano, sua perspectiva setorial, entre outros.

O acréscimo dessas informações faz com que esse modelo tenha vantagem sobre o anterior, tendo em vista que antes mesmo que as mudanças aconteçam ele pode nos proporcionar a previsão das mesmas através dos gráficos. Assim, pode se usar uma empresa na comparação com outra dentro do ambiente econômico, deixando assim os investidores mais cientes do aspecto geral do mercado e da empresa.

²Renko é um tipo de gráfico usado no mercado financeiro para indicar variações de preço desconsiderando tempo e volume de negociação.

Porém por aspectos como: complexidade da análise, subjetividade dos dados e até mesmo a presença de fatores desconhecidos pelos analistas aliados a uma possível lentidão do mercado para interpretar os dados da mesma forma, fazem com que a automatização desse tipo de abordagem utilizando técnicas de inteligência artificial se torne mais complexa.

2.3. Trade Quantitativo

Modelos de trader quantitativo, utiliza algoritmos de inteligência artificial para possibilitar uma avaliação estratégica e estatística visando aumentar os lucros em investimentos. Para isso são extraídos diversos dados dos ativos, organizados em modelos matemáticos, buscamos identificar padrões e através deles realizar uma análise sobre os ativos geralmente integrados com sistemas automatizados. É importante pontuar que o trade quantitativo se difere de um trade algoritmo comum, pois o modelo pode aprender com os padrões encontrados e não ficando estritamente preso as regras estabelecidas previamente na criação do modelo.

3. Redes Long-Short Term Memory

No aprendizado profundo, as Redes Neurais Recorrentes (RNNs) são Redes Neurais Artificiais, que, diferentemente das redes neurais *feedforward*, usam conexões reversas, onde os nós podem se conectar a outros nós nas camadas anteriores, ou a si mesmos, formando um ciclo direcionado. Como resultado, essas arquiteturas têm capacidade de memória, onde o valor passado do neurônio, juntamente com a entrada da camada anterior, são a entrada do neurônio/camada. Portanto, os valores de saída passados do neurônio, são determinados pelas entradas passadas, influenciando sua saída atual. Na Figura 1, X_0 para X_t representa entradas em diferentes etapas de tempo, onde $X_0, X_1, X_2 \dots$ representam 1, 2, 3, ... entradas e X_t é a entrada atual.




Figure 1. Arquitetura básica da rede neural recorrente.

As RNNs são frequentemente usadas para reconhecimento de padrões quando os resultados anteriores influenciam os resultados atuais, como dados de séries temporais ou processamento de linguagem natural. Apesar disso, as RNNs simples, com a arquitetura exibida acima, sofrem com o problema de gradiente de fuga, o que significa que a rede só pode se lembrar de entradas recentes e rapidamente esquece mais entradas de longo prazo. Para lidar com esse problema, foi introduzida uma variante do RNN conhecida como redes de memória de longo prazo, ou LSTMs [Hochreiter and Schmidhuber 1997].

Os LSTMs alcançam capacidade de memória de longo prazo com uma nova arquitetura que é ilustrada na Figura 2. Nesta arquitetura, cada módulo repetitivo (neurônio)

mantém um estado e possui 3 portas, cada uma das quais afeta o estado da célula de uma maneira diferente:

- **Input Gate:** decide quanto atualizar cada valor no estado da célula com os novos valores de entrada;
- **Output Gate:** filtra a saída com base no estado da célula;
- **Forget Gate:** decide quanto esquecer (apagar) cada valor no estado da célula.




Figure 2. Arquitetura de rede de memória de longo prazo

Esses portões são geralmente compostos por uma função de ativação sigmoide, que gera um valor entre 0 e 1, descrevendo o nível de ativação do portão (onde 0 está completamente fechado e 1 está completamente aberto). Devido à sua eficácia, os LSTMs tornaram-se muito populares, bem como a forma dominante de RNN usada em propósitos práticos, particularmente no processamento de dados de sequência e séries temporais.

4. Experimentos

Nessa seção, estaremos apresentando os experimentos que foram realizados durante esse trabalho. Foram selecionadas 6 ações, sendo elas: GOLL4, CSNA3, ELET3, B3SA3, PETR4 e VALE3. O critério para a escolha dessas ações foram a volatilidade das mesmas nos últimos meses e o fato de serem ações de empresas que atuam em setores distintos no mercado, como por exemplo, mineração, bancário, energia e aviação.

Nossa base de dados é formada pelo preço de fechamento de cada uma das ações selecionadas. Iremos usar como base do preço de fechamento referente ao gráfico de renko. O gráfico de renko é um modelo de gráfico utilizado no mercado financeiro para indicar variações de preço das ações sem levar em conta o volume e tempo de negociação. O nome “renko” deriva-se da palavra em japonês para “tijolo”, dado sua semelhança visual com os elementos do gráfico. Para configurar o gráfico renko é necessário definir o tamanho de cada renko, de maneira que, um novo renko só será criado quando ocorrer a variação de preço programada. Esse valor necessário para a inserção de um novo renko no gráfico é o que chamamos de valor de r (faixa de preços cada candle do renko).

A partir de cada base de dados gerada utilizamos o indicador *true range*, que mede a amplitude de variação do ativo em um determinado período. Através desse indicador buscamos encontrar um valor de r para o gráfico renko que fosse mais próximo ao gráfico usando candles no período de 60 minutos, pois percebemos a partir de várias estratégias

que eram apresentadas na literatura que o gráfico de 60 minutos é muito utilizado para operações de *day trade* e *swing trade*. Com isso, a partir da média de volatilidade encontrada, buscamos encontrar o valor de r que mais se aproximasse dessa volatilidade. Sendo: GOLL4 15r, CSNA3 24r, ELET3 22r, B3SA3 10r, PETR4 16r e VALE3 25r.

Com base no valor de r de cada gráfico e as ações selecionadas, utilizamos a ferramenta MetaTrader 5³ para poder fazer a importação das ações a partir do gráfico de renko selecionado. Os dados históricos que foram capturados são de janeiro 2019 até julho de 2021. Essa curta janela de aproximadamente 3 anos de dados se dá pelo fato que os dados anteriores a 2019 estavam danificados, na geração do renko, então para garantir uma maior consistência nos resultados optamos por utilizar os dados após 2019.

Para a técnica LSTM, utilizamos a arquitetura apresentada na Figura 3: consistindo em uma rede neural recorrente, composta por:

- **Camada de entrada:** os dados utilizados no treinamento foi o preço de fechamento do gráfico de renko;
- **Dropout:** método de regularização onde as conexões de entrada e recorrentes para unidades LSTM são probabilisticamente excluídas da ativação e atualizações de peso durante o treinamento de uma rede;
- **Camada densa:** camada onde cada neurônio é conectado a todos os neurônios da próxima camada;
- **Camada de Ativação:** primeira classificação dos dados;
- **Segunda camada densa.**
- **Última camada de ativação:** que realizará a classificação final dos dados.




Figure 3. Arquitetura da rede neural recorrente utilizada

A partir dos dados históricos selecionados estabelecemos a seguinte configuração: 30% para treinamento e 70% para teste. Os dados de treinamento e teste são fixos, pois a

³<https://www.metatrader5.com/>

sequência dos dados precisa ser mantida para garantir consistência nos resultados já que o LSTM usa as informações passadas para realizar as previsões, por isso não utilizamos dados aleatórios. Também fixamos o número de janelas e épocas 50 e 1000 respectivamente para todos os experimentos.

A seguir, iremos apresentar os gráficos gerados comparando com a estratégia de *buy and hold*, que consiste na compra do ativo e na venda do mesmo após um certo período de tempo, com a previsão do nosso modelo LSTM no período de 2019 a 2021. Iremos apresentar também para cada experimento a precisão da estratégia LSTM com base nas operações realizadas de compra e venda, isto é, à medida que a estratégia sinalize uma opção de compra quando a mesma sinalizar uma opção de venda iremos verificar se de fato houve um lucro. No caso de lucro a estratégia acertou a previsão e no caso de perda significa que houve um erro. Dessa forma, iremos calcular a taxa de precisão da LSTM para cada um dos ativos.

Os resultados da previsão LSTM é calculado com base no ganho acumulativo. Dado um patrimônio investido, o modelo utilizará todo o valor disponível no momento da transação para realizar as operações de compra e venda. A ordem das operações é importante, pois, nossa estratégia só poderá realizar uma operação de venda caso uma operação de compra tenha sido executada previamente. Isto é, a estratégia LSTM só irá vender ativos se ela já possuir os mesmos. A Figura 4 apresenta os resultados.

4.1. Análises

Analisando os gráficos apresentados, a nossa estratégia LSTM se comporta de maneira superior com relação a estratégia *buy and hold*, pois dado um capital inicial foi possível obter uma supervalorização realizando operações no formato de *swing trade*. Mesmo que a taxa de precisão não ultrapasse a casa dos 61% a técnica se destaca no longo prazo, e o lucro obtido no acerto é regularmente maior do que a perda no erro.

Como podemos ver na Figura 4(b), mesmo com uma precisão de 60.11% o lucro obtido com as operações de compra e venda do modelo chegou a 2099.97% resultado superior comparado aos -0.78% da estratégia *buy and hold* no mesmo período. Podemos destacar também o comportamento representado na Figura 4(c) que demonstra como uma perda considerável no capital pode afetar a recuperação do mesmo na estratégia *buy and hold*, enquanto nosso modelo conseguiria amenizar significativamente essa perda de capital.

Comportamento esse que é também encontrado na Figura 4(a), pois embora no início o *buy and hold* apresente uma melhor performance. A desvalorização da ação, mesmo que por um curto período de tempo, faz com que o capital acumulado tenha pouca valorização. Já o modelo LSTM consegue um melhor desempenho nesse acumulo.

5. Conclusão

O objetivo do nosso trabalho foi utilizar a técnica de LSTM na previsão de séries temporais financeiras, comparando o desempenho com a técnica de *buy and hold*. Pelos resultados conseguimos perceber que a proposta apresentou resultados animadores em todas as ações analisadas. Como trabalhos futuros, pensamos em utilizar uma abordagem multivariada utilizando outros fatores além do preço de fechamento no treinamento do modelo, como preço de abertura, máxima e mínima do renko, indicadores técnicos como média

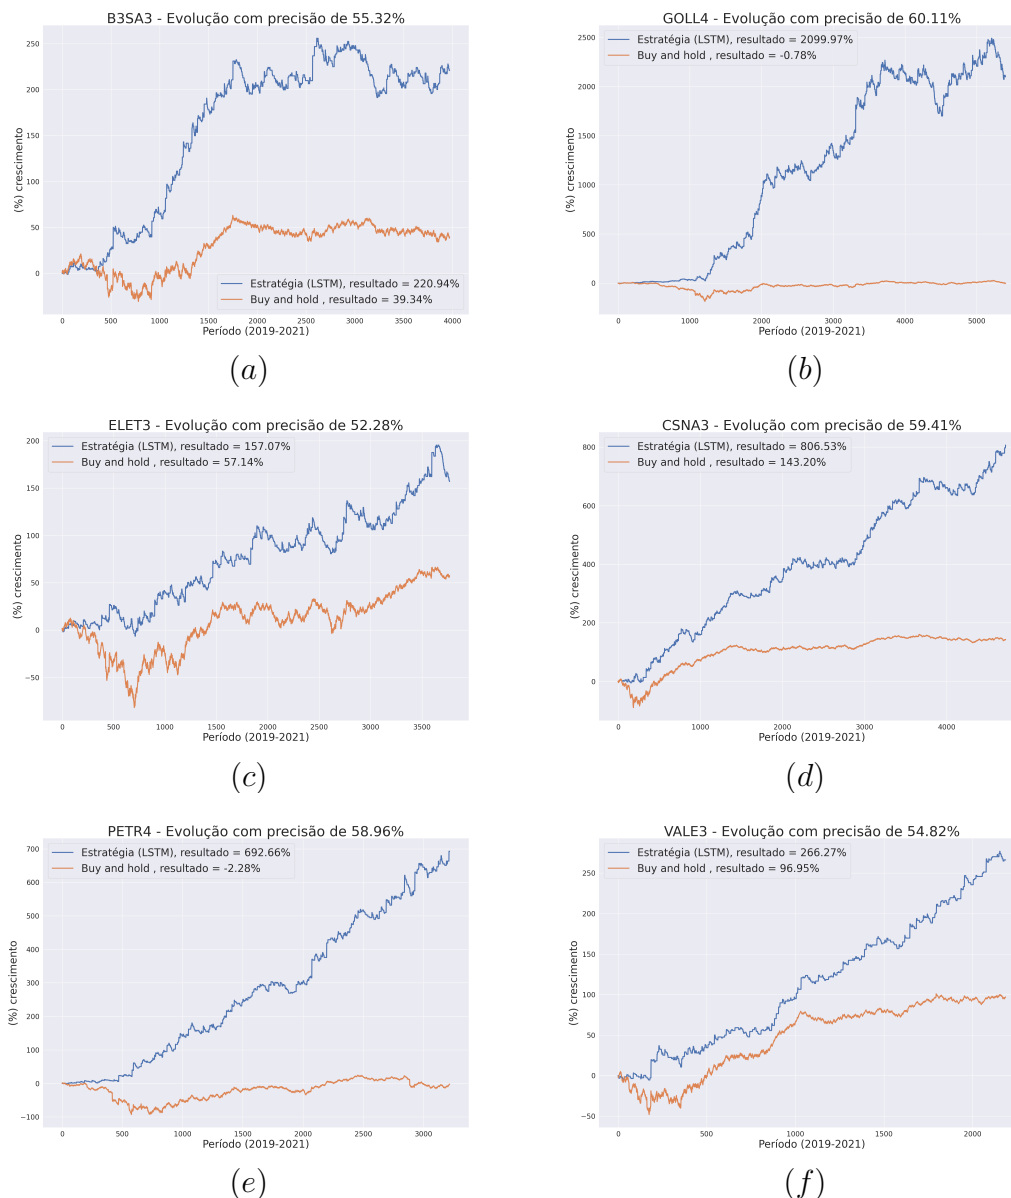


Figure 4. Resultados estratégia LSTM vs Buy and Hold.

móvel, juntamente com um *stop loss*, limite de perda adicionando assim uma margem de segurança para o investidor. Pretendemos também realizar experimentos em ativos do mercado futuro como índice e dólar, além de validar a técnica LSTM no mercado de criptomoedas, a qual vem crescendo muito nos últimos anos.

References

- Asteriou, D. and Hall, S. G. (2011). Arima models and the box–jenkins methodology. *Applied Econometrics*, 2(2):265–286.
- Du, J., Liu, Q., Chen, K., and Wang, J. (2019). Forecasting stock prices in two ways based on lstm neural network. In *2019 IEEE 3rd Information Technology, Networking,*

- Electronic and Automation Control Conference (ITNEC)*, pages 1083–1086.
- Ho, T. K. (1995). Random decision forests. In *Proceedings of 3rd international conference on document analysis and recognition*, volume 1, pages 278–282. IEEE.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Moghar, A. and Hamiche, M. (2020). Stock market prediction using lstm recurrent neural network. *Procedia Computer Science*, 170:1168–1173.
- Roque, R. d. C. (2009). Estudo sobre a empregabilidade da previsão do índice bovespa usando redes neurais artificiais.
- Samarawickrama, A. J. P. and Fernando, T. G. I. (2017). A recurrent neural network approach in predicting daily stock prices an application to the sri lankan stock market. In *2017 IEEE International Conference on Industrial and Information Systems (ICIIS)*, pages 1–6.
- Sarode, S., Tolani, H. G., Kak, P., and Lifna, C. S. (2019). Stock price prediction using machine learning techniques. In *2019 International Conference on Intelligent Sustainable Systems (ICISS)*, pages 177–181.
- Siarni-Namini, S., Tavakoli, N., and Namin, A. S. (2019). A comparative analysis of forecasting financial time series using arima, lstm, and bilstm. *arXiv preprint arXiv:1911.09512*.
- Yadav, A., Jha, C., and Sharan, A. (2020). Optimizing lstm for time series prediction in indian stock market. *Procedia Computer Science*, 167:2091–2100.