

PREDIÇÃO VIA MACHINE LEARNING DE SÉRIES TEMPORAIS MULTI-VARIÁVEIS COM APLICAÇÃO EM PORTFÓLIO DE AÇÕES

Fábio Oliveira Guimarães

José Alfredo Ruiz Vargas

Universidade de Brasília – UnB / Brasília – Distrito Federal - Brasil

guimaraes.fabio@aluno.unb.br vargas@ene.unb.br

Resumo: Neste trabalho propõe-se a construção de um sistema de compra e venda de ativos por meio da predição das cotações de ações do mercado financeiro brasileiro, via séries temporais, a partir de um modelo LSTM, avaliando a sua eficácia e desempenho de processamento na utilização do paradigma offline. O Contexto do trabalho é a bolsa de valores brasileira, mais precisamente os ativos que compõe o índice Ibovespa, principal indicador da Bolsa de Valores (BOVESPA). A relevância do trabalho está na pouca literatura existente referente ao mercado acionário brasileiro, na dificuldade dos acionistas na utilização de plataformas de day trade, muitas vezes pagas, e por conta do aumento do número de investidores brasileiros no mercado de renda variável. Por isso, a construção de técnica de negociação de ativos (ações) atrelada a um modelo de Deep Learning ajudará a dar uma maior segurança e, porque não, um maior retorno aos investidores com baixa experiência no investimento de ativos de alto risco.

Palavras-chave: *Aprendizado de Máquina; Séries Temporais; Bolsa de Valores; Predição; Estratégia de Compra e Venda*

1. INTRODUÇÃO

Aprendizado de Máquina ou *Machine Learning* (ML) é um dos campos de estudo da grande área do conhecimento denominada Inteligência Artificial (IA). De acordo com Sage, 1990 IA é o desenvolvimento de algoritmos ou paradigmas utilizando máquinas para soluções de tarefas cognitivas.

A IA possui diversas áreas de estudos como: aprendizado de máquina, processamento de linguagem natural (PLN), sistemas especialistas, robótica, visão computacional, reconhecimento de fala e planejamento. O foco deste artigo é apresentar uma aplicação de aprendizado de máquina no ramo das finanças, onde o produto do artigo é o desenvolvimento de um sistema de compra e venda de ativos usando ML.

Dentre as variadas definições de ML pode-se citar que Aprendizado de Máquina é a utilização de algoritmos que possibilitem extrair padrões ou conhecimentos de um grande volume de dados. A partir dessa definição recaímos na definição de aprendizado e como ensinar uma máquina a aprender.

O processo de aprendizagem em ML é dividido em 4 abordagens: Supervisionado, Não-Supervisionada, Semi-Supervisionado e Aprendizagem por Reforço, como apresentado em Machado *et al.* (2020). Na aprendizagem Supervisionada o algoritmo utiliza informações prévias fornecidas pelo cientista/desenvolvedor para ensinar o computador.

Na abordagem Não-Supervisionada o algoritmo utiliza técnicas matemáticas, como a teoria da distância euclidiana entre as amostras, para identificar quais os dados mais próximos entre si. Na abordagem Semi-Supervisionada utiliza-se um misto de Supervisionada e Não-Supervisionado, ou seja os rótulos são utilizados para identificação de padrão combinado com informações sem rótulos. Já na abordagem por Reforço o algoritmo bonifica ou penaliza a resposta dependendo do acerto ou erro em relação a resposta, levando o algoritmo a aprender com o seu erro ou acerto.

Todas as quatro abordagens podem ser utilizadas no mercado financeiro para operar compras e vendas de diversos tipos de ativos como ações, commodities, ETFs, índices de bolsas e etc. Como o intuito é utilizar sistemas automatizados via algoritmos para realizar as transações de compras e vendas de ativos financeiros que só seriam possíveis serem realizadas por um humano, mas especificamente um profissional especializado na área de finanças.

A operação de compra e venda de ativos utilizando Machine Learning não impede que o usuário do algoritmo não tenha perda financeira, o que o algoritmo faz, de acordo com a utilização de uma das quatro abordagens, ou até mesmo a combinação delas, é avaliar como um especialista trabalharia, sem a necessidade de conhecimentos prévios por parte do usuário em mercado financeiro.

O artigo de Rundo *et al.* (2019) apresenta várias técnicas quantitativas ML na área aplicada à finanças. Dentre as técnicas citadas no artigo tem-se a ARIMA (séries temporais clássicas), Máquina de Vetor de Suporte (SVM), K Vizinhos mais próximos (KNN), entre outras.

O autor Rundo *et al.* (2019) cita as estratégias para desenvolvimento de aplicações financeiras segue uma linha de evolução temporal, conforme figura 1. Os primeiros algoritmos testados são os Autorregressivos (Séries Temporais), depois vieram os algoritmos de Machine Learning (SVM, KNN), posteriormente para algoritmos de Deep Learning

(LSTM), depois vieram uma fusão de técnicas, denominadas de Modelos híbridos e por fim os modelos de aprendizado por reforço.




Figura 1. Evolução das Técnicas de Predição de Séries Temporais aplicadas em finanças (Rundo *et al.*, 2019)


Entre o levantamento de estudos sobre o tema o Rundo *et al.* (2019) levantou a tabela 1 com a presença de diversos artigos e suas respectivas técnicas e abordagens na temática de *Machine Learning*.

Tabela 1 – Levantamento de artigos baseados em ML levantados por Rundo *et al.* (2019).

Article	Techniques	Main Goal	Dataset
Patel et al. (2014) [14]	Fusion approach involving ANN, RF and SVR models	Stock prices prediction	Indian Stock market indices
Chen et al. (2015) [15]	LSTM model	Stock returns prediction	China Stock Market data
Hafezi et al. (2015) [16]	bat-neural network multi-agent system (BNNMAS)	Stock price prediction	DAX stock price
Fischer et al. (2017) [17]	LSTM model	Large-scale financial market prediction	S&P 500 (1992–2015)
Yümlü et al. (2005) [21]	Global, recurrent and smoothed-piecewise neural models	Financial time series prediction	Istanbul Stock Exchange (1990–2002)
Selvin et al. (2017) [22]	LSTM-RNN-CNN sliding window-ARIMA	Short term future prediction	NSE listed companies' data (2014–2015)
Samarawickrama et al. (2017) [23]	RNN model	Daily stock prices prediction	Sri Lankan Stock Exchange
Siarni-Namini et al. (2018) [24]	LSTM vs. ARIMA	Comparison	N225, IXIC, HIS, GSPC, DJ
Rundo et al. (2019) [25]	LSTM model	Forecasting	ENEL.MI ISP.MI UCG.MI CVAL.MI MPS.MI
Rundo et al. (2019) [26]	Grid algorithmic trading system (Non-linear Regression Network)	Forecasting	FX market (EUR/USD)

No artigo de Mintarya *et al.* (2022) também foram levantados quais os algoritmos de ML mais utilizados para predição de ativos, dentre eles pode-se citar SVM e LSTM, como uma maioria de percentual de 19,5% de LSTM.

Tabela 2 – Levantamento de artigos baseados em ML levantados por Mintarya *et al.* (2022).



Para avaliar se o algoritmo está conseguindo acompanhar bem os valores das cotações das ações utilizá a métrica bem conhecida em sistemas de regressão que é o RMSE – Root Mean Squared Error que calcula a raiz quadrática média dos erros, conforme equação 1.

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (1)$$

A volatilidade é uma medida de extrema importância quando trata-se de mercado financeiro, e faz parte do rol de indicadores de risco dos ativos financeiros. A volatilidade mede a taxa de variação da data atual comparada com a data anterior, sendo P_i o preço ajustado do ativo hoje. A equação 2 mostra o calculo de r e a equação 3 apresenta a volatilidade.

$$r = \ln \left(\frac{P_i}{P_{i-1}} \right) \quad (2)$$

$$Vol = \sqrt{\frac{\sum |r - \bar{r}|^2}{n}} \quad (3)$$

O índice de Sharpe é a medida que relaciona o risco com o retorno, ou seja, quanto maior o índice melhor é o retorno do ativo comparado com o RF que é o retorno financeiro calculado em percentual subtraído do índice Bovespa, tudo dividido pela volatilidade, conforme equação 4.

$$Sharpe = \frac{RF - Ibovespa}{(Vol)} \quad (4)$$

Após escolher as métricas de sucesso do modelo, falta escolher qual o algoritmo para o artigo, conforme comentado o LSTM foi o escolhido, ele se enquadra nos algoritmo de Redes Neurais recorrentes e a sua tradução seria Redes de Memória de Curto Prazo Longo, tal algoritmo foi proposto por Hochreiter, Schmidhuber (1997).

O LSTM tem o objetivo de evitar o problema de dependências de longo prazo das séries temporais, sua estrutura possui uma cadeia onde cada estrutura possui quatro camadas de repetição, interagindo de forma particular, exemplificado na figura 2.




Figura 2. Módulo de Repetição da rede LSTM contendo as quatro camadas (Júnior, 2019)

2. MATERIAIS E MÉTODOS

Esta seção apresenta os passos realizados para construção do sistema de recomendação de compra e venda de ativos financeiros da Bovespa, todas as etapas realizadas foram desenvolvidas na linguagem de programação Python via IDE Visual Studio Code. Os passos realizados, em ordem, foram: aquisição dos dados, preparação dos dados, treinamento do modelo LSTM, construção da estratégia de compra e venda de ativos e análise da performance.

2.1. Aquisição dos Dados

Na aquisição dos dados utilizou-se a biblioteca `pandas-datareader`, entre as opções de fonte de dados para download das cotações foi selecionado a origem Yahoo Finanças. Os dados vieram no formato `dataframe` contendo as informações: data do pregão, cotação mais alta do dia, cotação mais baixa do dia, cotação de abertura, cotação de fechamento, volume de ativos negociados no dia e valor de fechamento ajustado.

Para o artigo foram selecionados as 5 ações com os maiores percentuais de participação no índice Bovespa, conforme tabela 1, além do próprio índice Bovespa que será utilizado como referência de desempenho. As cotações baixadas são de 01/01/2017 até 30/06/2022, conforme tabela 2.

Tabela 2. As 5 ações com maior percentual de participação índice Bovespa (Bovespa, 2022)

Código	Ação	Tipo	Part. (%)
VALE3	VALE	ON NM	15,379
PETR4	PETROBRAS	PN N2	6,716
ITUB4	ITAUUNIBANCO	PN EJ N1	6,526
BBDC4	BRADESCO	PN EJ N1	4,994
PETR3	PETROBRAS	ON N2	4,418

2.2. Preparação de Dados

Na preparação dos dados selecionou-se apenas a coluna valor de fechamento ajustado e a data de referência. Para centralizar todos os dados, os `dataframes` com as cotações foram unidos de forma que o nome da coluna valor da cotação ajustado foi substituído pelo nome do ativo, conforme figura 3.

	VALE3	PETR4	ITUB4	BBDC4	PETR3
Date					
2017-01-02	16.782001	7.383342	17.800673	11.674997	8.719831
2017-01-03	17.525337	7.806397	18.554541	12.169475	9.273719
2017-01-04	17.210592	7.806397	18.634171	12.092397	9.162943
2017-01-05	17.866873	7.932308	18.888994	12.226262	9.368674
2017-01-06	17.391403	7.886983	18.952700	12.303338	9.226244

Figura 3. Cotações de fechamento ajustado dos 5 principais ativos do índice Bovespa

Com os dados escolhidos o próximo passo é normalizar os dados com a função `MinMaxScaler` que normaliza as cotações de fechamento entre 0 e 1, tal procedimento é indispensável para o modelo utilizado o LSTM. Outro passo importante é o `reshape` do dataset, onde transforma-se o dado, já normalizado, que está em coluna para um array em linha para a termos uma entrada específica para o LSTM.

Uma boa prática em toda criação de modelos de Machine Learning ou Deep Learning é a quebra da base em treinamento e teste, a fim de garantir que o modelo não está com `overfitting`, no caso desse artigo a quebra utilizada foi 2/3 para treinamento e 1/3 para teste, sendo que os dados foram segmentados em ordem cronológica, ou seja, dos dados capturados no item 2.1 os primeiros 2/3 foram utilizados apenas para o treinamento.

2.3. Treinamento do Modelo LSTM

O modelo escolhido para previsão da Série Temporal foi o LSTM devido ao seu baixo RMSE, conforme mencionado em Rundo *et al.* (2019). Para o artigo, customizou-se os parâmetros de treinamento com o otimizador Adam, a função de perda Mean Squared Error e o look back de 1, ou seja, a partir do fechamento do dia anterior se prediz o valor do fechamento do papel de hoje, evidenciado na figura 4.

```
# create and fit the LSTM network
model = Sequential()
model.add(LSTM(4, input_shape=(1, look_back)))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer='adam')
model.fit(trainX, trainY, epochs=100, batch_size=1, verbose=2)
```

Figura 4. Parâmetros de treinamento da LSTM

Com uma camada LSTM e uma camada densa no modelo, totalizando 101 parâmetros, conforme figura 5.

```
Model: "sequential_16"

```

Layer (type)	Output Shape	Param #
lstm_16 (LSTM)	(None, 4)	96
dense_16 (Dense)	(None, 1)	5

```

Total params: 101
Trainable params: 101
Non-trainable params: 0
```

Figura 5. Camadas do modelo LSTM

2.4. Construção da Estratégia de Compra e Venda de Ativos

A estratégia desenvolvida neste artigo tem com premissa a identificação de viés, tanto de alta quanto de baixa, funcionando com duas abordagens. Para tanto, o sistema de compra e venda de ativos começa com um valor específico de dinheiro em caixa para inicialização das comercializações, nas simulações foi escolhido o valor de R\$ 1.000,00 por ativo.

A primeira coisa que o sistema faz é identificar o valor de fechamento do ativo no dia 0 e no primeiro dia, comprar metade do caixa em ativos, deixando um valor aproximado de R\$ 500,00 para futuras compras, o valor é aproximado pois depende do valor do ativo de cada empresa.

Em seguida, quando o algoritmo identificar uma previsão de alta para o dia, maior que 0,3%, em relação ao fechamento do ativo no dia anterior o sistema irá comprar o ativo na abertura do pregão para a posteriormente vender pelo preço previsto do ativo até o fechamento do dia, caso a ação não seja comercializada devido ao comportamento de baixa do ativo para o dia, o sistema identificará que há um papel que não teve a sua venda realizada, informando que há uma ordem de venda em aberto.

Agora, caso o algoritmo identifique uma previsão de baixa para o dia, baixa menor que 0,3%, em relação ao fechamento do ativo no dia anterior o sistema irá vender um dos seus ativos em estoque, ou os comprados no dia 0 ou os que tiveram ordem de venda em aberto, e posteriormente irá recomprar o ativo ao valor previsto pelo algoritmo até o final do dia, caso isso não ocorra devido uma alta do ativo, o sistema identificará que temos um ordem de compra em aberto para futuro acerto.

Com isso, o algoritmo tentará ganhar dinheiro tanto na alta do ativo quanto na baixa, caso a sua previsão não se concretize o sistema identifica que há ordens pendentes e acumula para quando o cenário estiver favorável. Idealmente, se houver sequências de alta e de baixa o sistema conseguirá se manter em harmonia, sempre preservando o valor de metade do dinheiro em caixa para próximas compras e metade do valor investido para próximas vendas.

Como não pode-se contar com a sorte o sistema tem limitadores programados, onde não é possível vender ativos que não se tenha e não poderá realizar compra de ativos se o valor ultrapassar o dinheiro em caixa, para não entrar em estagnação, caso não seja possível comprar ou vender ativos por algum tipo de limitação o sistema tentará ou comprar menos papéis até o limite do dinheiro em caixa ou vender os ativos até o limite que se possua.

Na figura 6 apresenta-se um fluxograma para melhorar a compreensão do sistema desenvolvido para compra de ativos.




Figura 6. Fluxo do Sistema de Compra de Ativos

Para facilitar o acompanhamento das transações, foi criado um sistema de log que informa qual tipo de transação foi realizada e se houve algum atingimento de limite, conforme apresentado na figura 7.

```

Compras Pendentes: 1
Tentou comprar, mas ninguém vendeu pelo preço solicitado
Dia com Projeção de Subida: 1
Projeção para Hoje: 23.0413
Cotação no Fechamento do dia Anterior: 22.895586013793945
Cotação no Fechamento de Hoje: 23.45171546936035
Ganho Real: 0.2914276123046875
Percentual: 0.6364275020720382
Caixa: 496.2971076965332
Investido: 503.7028923034668
Quantidade de Ativos: 22
Compras Pendentes: 1
Tentou comprar, mas ninguém vendeu pelo preço solicitado
Compras Pendentes: 2
Tentou comprar, mas ninguém vendeu pelo preço solicitado
Compras Pendentes: 3
Tentou comprar, mas ninguém vendeu pelo preço solicitado
Compras Pendentes: 4
Tentou comprar, mas ninguém vendeu pelo preço solicitado
Compras Pendentes: 5
    
```

Figura 7. Registro de log do funcionamento do sistema de Compra e Venda de ativos

2.5. Análise de Performance

Ao final de cada dia o sistema calcula os parâmetros básicos de quanto se lucrou nas transações de Day Trade, quantos dias em operação o sistema está executando, o valor de dinheiro em caixa, o somatório de quanto foi pago em todas as compras já realizadas dos ativos em estoque, a quantidade de ativos em estoque, o valor atual do estoque considerando o preço atual, o valor total somando caixa mais ativos, o ganho/perda desde o início da operação, o rendimento total, o comparativo do índice Bovespa para o período e a valorização da ação desde o início da operação (modelo *buy and hold*). Esses dados, mostrado na figura 7, apresenta um direcionador para o investidor.

```
+++++
Ganho nas Compras e Vendas de Ativos: 88.52847862243652
Rendimento no Day Trade: 386.6617721385275
Dias de Operação: 449
Dinheiro em Caixa: 496.2971076965332
Valor Investido: 503.7028923034668
Quantidade de Ativos: 22
Valor dos Ativos: 500.33874130249023
Valor Total (Caixa + Ativos): 996.6358489990234
Ganho Total (Caixa + Ativos): -3.3641510009765625
Rendimento Total (Caixa + Ativos): -0.33641510009765624
Rendimento Ibov -2.666877382904328
Rendimento da Ação -0.6678839951845574
```

Figura 7. Painel resumo das transações realizadas para o ativo ITUB4.SA

3. RESULTADOS E DISCUSSÕES

Agora, serão apresentados os resultados do sistema de compra e vendas de ativos das 5 ações selecionadas (VALE3, PETR4, ITUB4, BBDC4 e PETR3). Após o treinamento dos modelos LSTM observa-se que para o papel VALE3, figura 8, é possível notar que nos primeiros 3 meses a predição é bem próxima do valor real, mas após os meses iniciais a predição não consegue acompanhar a curva, apenas as tendências de altas e baixas.




Figura 8. Valores Reais, Predições em Treino e Predições em Teste do papel VALE3

Nos modelos treinados para a PETR4, figura 9, e PETR3 na figura 12 temos um desempenho superior ao observado no ativo VALE3, onde os modelos conseguem acompanhar as curvas reais por quase um ano. Nos modelos treinados do ativo ITUB4, figura 10 e no ativo BBDC4 na figura 11 observa-se um desempenho melhor que os 3 anteriores, acompanhando muito bem a variação dos ativos por quase 2 anos.




Figura 9. Valores Reais, Predições em Treino e Predições em Teste do papel PETR4




Figura 10. Valores Reais, Predições em Treino e Predições em Teste do papel ITUB4




Figura 11. Valores Reais, Predições em Treino e Predições em Teste do papel BBDC4




Figura 12. Valores Reais, Predições em Treino e Predições em Teste do papel PETR3

Analisando os dados da tabela 3 é possível verificar que apenas no ativo ITUB4 o sistema de compras e vendas teve prejuízo (0,34%) e nos outros 4 ativos obteve lucro, com destaque para o ativo PETR3 com 64,7% de valorização. Em todas os 5 ativos a performance do indicador Sharpe foi positiva apresentando um desempenho do sistema de compra e venda de ativos superior ao índice Bovespa.

Tabela 3. Indicadores de performance dos 5 ativos

	VALE3	PETR4	ITUB4	BBDC4	PETR3
RMSE % (Treino)	7,45	0,68	0,58	0,40	0,79
Sharpe %	21,78	22,74	1,11	3,62	25,58
Ganho nas transações R\$	91,56	137,47	87,34	38,84	167,77
Dias de Operação	449	449	449	449	449
Dinheiro em Caixa	635,69	655,57	496,30	504,09	677,27
Quantidade de Ativos	11,00	40,00	22,00	31,00	38,00
Valor dos Ativos	853,98	914,61	500,34	542,86	970,68
Valor Total (Caixa + Ativos)	1459,67	1570,18	996,63	1046,96	1647,95
Ganho Total	459,67	570,18	-3,37	46,96	647,95
Rendimento Bovespa %	-2,66	-2,66	-2,66	-2,66	-2,66
Valorização do Ativo %	63,52	84,72	-0,67	9,14	94,86

4. CONCLUSÕES

Assim, pode-se concluir que o sistema automatizado de compra e venda de ativos performou melhor que o índice Bovespa do período, o que pode ser visualizado pelo indicador Sharpe. O modelo LSTM conseguiu manter um bom acompanhamento da curva real após o treinamento, entretanto percebe-se um descolamento da curva em alguns ativos após um certo tempo de uso, o que demanda um retreino em um período menor que 6 meses.

Segundo os resultados obtidos foi possível notar que mesmo em um período conturbado economicamente (pandemia da COVID-19, retomada da atividade econômica pós-pandemia e guerra na Ucrânia) houve um rendimento positivo na somatória dos 5 ativos.

Pensando em trabalhos futuros o sistema poderia ser evoluído para escolher o papel que mais tivesse variação de alta ou baixa para realizar a transação, de forma a ter uma carteira de ativos mais ampla melhorando os ganhos totais. Além disso, a construção de mais dois módulos de ativos seria interessante, um módulo que escolhesse os melhores ativos a longo prazo, considerando indicadores fundamentalista, a fim de utilização da técnica *buy and hold* para longo prazo e um módulo de comercialização de ativos usando a técnica de ativo valorizado e ativo barato a fim de usar uma abordagem de médio prazo.

Um sistema que integrasse as três abordagens (curto prazo – *Day Trade*, médio prazo – Valorização do Ativo e longo prazo – Fundamentalista) traz uma diversidade maior de transações e uma possibilidade de diminuição do risco e volatilidade do ativo com um ganho a mais de dividendos e juros sobre o capital próprio.

5. AGRADECIMENTOS

Agradeço à minha mãe Eliana, ao meu pai Arquimedes, aos meus irmãos Felype e Fabrício e em especial a companheira de jornada Adryelle que sempre estiveram ao meu lado.

Agradeço ao meu orientador, professor Dr. José Alfredo Ruiz Vargas, pelos seus ensinamentos que vão além do conteúdo acadêmico.

6. REFERÊNCIAS

- F. Rundo, F. Trenta, A. Stallo and S. Battiato, "Machine Learning for Quantitative Finance Applications: A Survey," Applied Sciences 2019.
- BOVESPA, Site da Bovespa, 2022. Índice Bovespa. Disponível em: https://www.b3.com.br/pt_br/market-data-e-indices/indices/indices-amplos/indice-ibovespa-ibovespa-composicao-da-carteira.htm. Acesso em 04 out. 2022.
- JUNIOR, Site do Medium, 2019. Redes Neurais Recorrentes - LSTM. Disponível em: <https://medium.com/@web2ajax/redes-neurais-recorrentes-lstm-b90b720dc3f6>. Acesso em 10 out. 2022.
- Machado, Eduardo Jabbur, Carlos Alberto Silva De Assis, and Adriano Cesar Machado Pereira. "Modelagem, Implementação E Avaliação De Estratégias De Negociação Baseadas Em Algoritmos De Aprendizado De Máquina Para O Mercado Financeiro." Revista Brasileira De Computação Aplicada. 12.1 (2020): 16-31. Web
- Sepp Hochreiter, Jürgen Schmidhuber: Long Short-Term Memory. Neural Comput. 9(8): 1735-1780 (1997)
- L. Mintarya, J. Halim, C. Angie, S. Achmad and A. Kurniawan. "Machine learning approaches in stock market prediction: A systematic literature review", 7th International Conference on Computer Science and Computational Intelligence 2022

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.

PREDICTION VIA MACHINE LEARNING OF MULTIVARIABLE TIME SERIES WITH APPLICATION IN SHARE PORTFOLIO

Fábio Oliveira Guimarães

José Alfredo Ruiz Vargas

University of Brasília – UnB / Brasília – Federal District - Brazil

guimaraes.fabio@aluno.unb.br vargas@ene.unb.br

Abstract. *This work proposes the prediction of stock prices in the Brazilian financial market via time series from the LSTM model, evaluating its efficiency and processing performance when using the offline paradigm. The context of the work is the Brazilian stock exchange, more precisely the assets that make up the Ibovespa index, the main indicator of the Stock Exchange (BOVESPA). The relevance of the work is in the little existing literature referring to the Brazilian stock market and due to the increase of Brazilian investors in the variable income market. The refore, the construction of an asset (stock) trading technique linked to a Deep Learning model will help to provide greater security and, why not, a greater return to investors with little or even low experience in investing in high-risk assets..*

Keywords: *Machine Learning; Time Series; Stock Exchange; Prediction; Buying and Selling Strateg.*

RESPONSIBILITY NOTICE

The authors are the only responsible for the printed material included in this paper.