



ANÁLISE COMPARATIVA DE MODELOS DE INDICADORES TÉCNICOS E DE REDES NEURAIS PARA PREDIÇÃO DO PREÇO DE AÇÕES

COMPARATIVE ANALYSIS OF TECHNICAL INDICATORS AND NEURAL NETWORKS MODELS TO STOCK PREDICTION

ÁREA TEMÁTICA: 6 FINANÇAS

Charles Chaclim Esteves Pereira, UEM, Brasil, ra100963@uem.br

Wagner Igarashi, UEM, Brasil, wigarashi@uem.br

Deisy Cristina Corrêa Igarashi, UEM, Brasil, dccigarashi@uem.br

Resumo

O mercado de ações vem se tornando cada vez mais atrativo para novos investidores brasileiros, devido à diminuição dos lucros nos investimentos de renda fixa. Entretanto, para se entrar neste mercado é necessário conhecê-lo a fim de maximizar os lucros e minimizar as perdas. Para isto, os investidores utilizam de diversos modelos de predição do movimento do preço das ações, dentre os quais temos os modelos baseados puramente em indicadores técnicos e os que utilizam redes neurais artificiais baseados em indicadores técnicos. Sendo assim, este trabalho se propõe a desenvolver e analisar comparativamente ambos os modelos com o objetivo de descobrir qual deles tem melhor desempenho, com base nos dados históricos. Após os experimentos foi possível perceber que o preditor que não utiliza rede neural gera em média um aumento de 11,52 pontos percentuais nos ganhos em comparação ao outro previsor num ambiente de baixa volatilidade, por outro lado, num mercado mais volátil o preditor que utiliza RNA se sobressai em 16,97 pontos percentuais, ademais reduz as perdas possíveis para apenas uma.

Palavras chave: mercado de ações, redes neurais, LSTM, indicadores técnicos, predição do preço de ações.

Abstract

The stock market has become increasingly attractive to new Brazilian investors, due to declining profits from fixed income investments. However, to enter this market it is necessary to know it in order to maximize profits and minimize losses. For this, investors use several models to predict the movement of stock prices, among which we have models based purely on technical indicators and those that use artificial neural networks based on technical indicators. Therefore, this work proposes to develop and comparatively analyze both models in order to discover which one has better performance, based on historical data. After the experiments, it was possible to notice that the predictor that does not use a neural network generates, on average, an increase of 11.52 percentage points in gains compared to the other predictor in a low volatility environment, on the other hand, in a more volatile market the predictor that uses RNA excels by 16.97 percentage points, furthermore it reduces the possible losses to just one.

Keywords: stock market, neural networks, LSTM, technical indicators, stock prediction.

1. INTRODUÇÃO

Outrora no nosso país, a taxa básica de juros (SELIC) chegou a atingir um pico de 14,25% ao ano entre julho de 2015 a outubro de 2016 (Subsecretaria de Arrecadação, Cadastros e Atendimento, 2020), que afugentava o investidor amador do mercado de ações, pois era mais atrativo o investimento em aplicações em fundos de renda fixa (CDB, LCI, LCA, LF, tesouro direto, etc.) que apresentam menor risco de perda financeira. Mas, dado a queda desta taxa para o menor patamar histórico de 2% ao ano e pela expectativa de melhora do mercado brasileiro, o nosso país vê uma mudança de cenário ocorrendo no mercado financeiro, onde cada vez mais a população vem investindo no mercado de ações.

Infelizmente, o mercado de ações é um sistema complexo que necessita de um bom conhecimento financeiro, caso deseje obter bons lucros e evitar perda de recursos, ainda mais em mercados emergentes, nos quais, segundo Bekaert e Harvey (1997), existe uma alta volatilidade no preço das ações, ocasionando grandes lucros e perdas. Em contraponto, os mercados de países emergentes possuem uma maior taxa de previsibilidade, algo que se torna útil para os investidores.

No contexto apresentado, este trabalho tem como propósito a comparação de dois modelos de predição de preço: o utilizado atualmente por investidores, que é a predição por meio da análise dos indicadores técnicos; e o modelo com a predição utilizando redes neurais baseadas em indicadores técnicos. Esta comparação se justifica pois ambos os modelos apresentam falhas, o primeiro não aprende novos padrões do mercado e o segundo pode aprender padrões incorretos.

2. FUNDAMENTAÇÃO TEÓRICA

O ato de compra e venda de ações nada mais é que o ato de aquisição e alienação de uma fatia de uma sociedade anônima, no qual o comprador se torna um acionista. Tais ações só podem ser comercializadas publicamente caso a sociedade seja de capital aberto. Esta comercialização pode ocorrer de duas maneiras: por meio do mercado primário, que é quando uma empresa vende seus ativos financeiros diretamente para os investidores, gerando dinheiro para o caixa da empresa; ou por meio do mercado secundário, quando o acionista revende suas ações.

2.1 Análise técnica

Segundo Kirkpatrick e Dahlquist (2010) os primeiros relatos da utilização da análise técnica são do século XVIII, onde o rico comerciante Sokyo Honma utilizou-a para acumular sua fortuna. Desde então, o mercado de ações, o de câmbio, e mais recentemente, o de criptomoedas vêm sendo estudados por milhares de analistas sob o escopo da análise técnica.

Este tipo de estratégia se baseia no estudo de dados de mercado, como volume e preço do ativo que está sendo negociado, a fim de conseguir prever seu movimento, podendo assim encontrar a melhor hora para a compra ou venda de ativos. Para que isto seja possível, são utilizados diversos cálculos matemáticos sobre estes dados, que são definidos como indicadores técnicos, que podem ser classificados de diversas maneiras. Segundo Oriani e Coelho (2016), a classificação de indicadores técnicos pode se dar pelas seguintes nomenclaturas: **Leading**: são indicadores que antecipam o movimento do mercado, em teoria eles podem prever o mercado, entretanto, isto não é realidade porque nenhum deles é 100% preciso. Um exemplo disto será explicado mais à frente quando falarmos sobre o indicador RSI; **Lagging**: eles são úteis para os acionistas confirmarem uma tendência dos preços antes de entrar em uma negociação ou até mesmo para se manterem em uma negociação, em outras palavras eles não servem para mostrar o futuro, mas sim para confirmar que uma tendência está ocorrendo.

Complementarmente, para Liu e Song (2017) e Blau (1993) os indicadores técnicos podem ser classificados por suas funções: **Momentum**: servem para a mensuração da força e da velocidade

da mudança do preço. Quando uma ação tem uma rápida valorização em certo ponto ela será considerada sobrecomprada, já quando ela rapidamente é desvalorizada ela será considerada sobrevendida; **Volatility**: indicam a volatilidade do mercado, algo importante, pois se um mercado é pouco volátil, ele é menos interessante para um investidor porque há menos chances de mudanças nele, ou seja, de haver grandes lucros; **Volume**: servem para medir a força de uma tendência e sua direção, e assim como os de volatilidade, eles são úteis para indicar oportunidades, pois, com menos ações negociadas, mais difícil se torna para conquistar melhores preços.

Nas subseções seguintes são elencados os indicadores utilizados nos modelos de predição desenvolvidos, os quais foram selecionados com base no artigo de Vaiz e Ramaswami (2016).

2.1.1 Average Directional Index (ADX)

ADX é um indicador do tipo *Lagging* que serve para determinar a força de uma tendência, ele foi criado em 1978 por J. Welles Wilder Jr. Segundo Bruni (2017), o ADX é calculado da seguinte forma:

$$ADX_t(n) = 100 (EMAt(n, | +DI - -DI|) (+DI + -DI))$$

onde n é o número de períodos, que geralmente é 14, t é o período atual e $+DI$ e $-DI$ são:

$$+DI_t(n) = (100 \times EMA_t(n, +DM)) \div (ATR_t(n))$$

$$-DI_t(n) = (100 \times EMA_t(n, -DM)) \div (ATR_t(n))$$

ATR é a Average True Range; se $up_t > dw_t$ e $up_t > 0$ então $+DM_t = up_t$ caso contrário $+DM_t = 0$; se $dw_t > up_t$ e $dw_t > 0$ então $-DM_t = dw_t$ caso contrário $-DM_t = 0$. O up_t é a máxima atual menos a máxima do período anterior e dw_t é a mínima do período anterior menos a mínima atual.

Este indicador tem como resultado um valor com variação entre 0 e 100, onde os números altos indicam uma tendência mais forte e números baixos indicam uma tendência fraca. ADX abaixo de 20: não existe uma tendência no mercado; ADX cruzando 20 no movimento ascendente: está sendo formado uma nova tendência, os investidores talvez devam começar a vender ou comprar ações de acordo com a tendência; ADX entre 20 e 40: significa que a tendência está se confirmando; ADX acima de 40: a tendência está forte.

2.1.2 Simple Moving Average (SMA)

Este indicador, assim como o anterior, é do tipo *Lagging* que serve para indicar a direção da tendência e gerar potenciais sinais de vendas e compras. Seu cálculo é dado pela seguinte expressão matemática:

$$SMA_t = \left(\sum_{i=0}^{n-1} P_{t-i} \right) \div n$$

onde p é o preço, t é o período atual e n é o número de períodos.

Em geral o SMA é utilizado por meio do cálculo deste indicador várias vezes com períodos diferentes (Baba, Wang, Kawachi, Xu & Deng, 2003, Lauren & Harlili, 2014). Segundo Baba et al. (2003) a sua interpretação pode ser feita por meio dos termos cruz de ouro e cruz da morte. A cruz de ouro é gerada quando uma SMA inferior cruza uma SMA superior ascendentemente, estas mostram um sinal de compra. Já a cruz da morte ocorre quando este cruzamento é descendente, que mostra um sinal de venda.

2.1.3 Exponential Moving Average (EMA)

O indicador EMA, assim como o anterior, é do tipo *Lagging*, desenvolvido na década de 60 por P. N. “Pete” Hauran. Este indicador pode ser calculado da seguinte forma:

$$EMA_t = (p_t - EMA_{t-1}) \frac{2}{n+1} + EMA_{t-1}$$

onde p é o preço, t é o período atual, n é o número de períodos e o EMA_{t-1} inicial é a soma dos n primeiros períodos divididos por n .

O EMA é utilizado da mesma forma que o SMA, no entanto, a EMA tem melhor adaptação às mudanças ocorridas em mercados voláteis, todavia ela tem maior suscetibilidade a geração de *whipsaw* (sinais incorretos). Os parâmetros de utilização do EMA podem ser identificados nos trabalhos de Eng, Shukor, Ismail, & Halim (2017) e Klinker (2011).

2.1.4 Relative Strength Index (RSI)

O Relative Strength Index (RSI) é um indicador do tipo *Momentum*, que assim como o ADX também foi concebido e publicado por J. Welles Wilder Jr. em 1978 no seu livro *New Concepts in Technical Trading Systems*. A fórmula matemática do RSI se dá pela seguinte expressão:

$$RSI = 100 - \left(\frac{100}{1+RS} \right)$$

onde RS é dado pela seguinte fórmula para o primeiro período:

$$RS = \frac{(\text{ganho médio em } n \text{ períodos})/n}{(\text{perda média em } n \text{ períodos})/n}$$

e para os subsequentes períodos o cálculo utiliza a fórmula:

$$RS = \frac{(\text{ganho médio anterior} \times (n-1) + \text{ganho atual})/n}{(\text{perda média anterior} \times (n-1) + \text{perda atual})/n}$$

onde n é o número de períodos que por padrão é 14.

Segundo Drakopoulou (2016) este indicador, cujos valores variam entre 0 e 100, tem como propósito a indicação de quando uma ação está em sobrecompra (com o valor do índice acima de 70 ou 80, indicando um bom momento de venda), em sobrevenda (com o valor do índice abaixo de 30 ou 20, indicando um bom momento de compra) ou em um mercado lateralizado (com o valor entre 20 e 80 ou 30 e 70, indicando a manutenção dos ativos).

2.1.5 On-Balance Volume (OBV)

O indicador OBV foi o único do tipo volume selecionado, que serve para medir a força de uma tendência, sinalizar uma nova tendência e uma possível reversão da atual. Sua formulação foi realizada por Joe Granville na década de 60, ela é dada pela seguinte expressão matemática:

$$OBV_t = OBV_{t-1} + k$$

onde t é o período atual e k é o volume de negociação no momento do fechamento da bolsa de valores no dia anterior se este valor for maior que o volume atual, caso seja menor então é o valor negado deste valor, e caso contrário é zero.

A identificação do sinal de reversão de tendência e do surgimento de uma nova tendência utilizando o indicador OBV se dá por meio da análise do mesmo em conjunto com o preço da ação, a reversão ocorre quando o preço do ativo está em queda ou em alta, mas o indicador OBV não acompanha este movimento da mesma maneira. Já o do surgimento de uma nova

tendência ocorre quando há uma reversão da tendência e quando há uma perda do suporte do indicador.

2.1.6 Bollinger Bands

O Bollinger Bands é um indicador de volatilidade, desenvolvido por John Bollinger (1992):

$$UBand = SMA \text{ com } n \text{ períodos} + (\text{desvio padrão de } n \text{ períodos} \times 2)$$

$$MBand = SMA \text{ com } n \text{ períodos}$$

$$LBand = SMA \text{ com } n \text{ períodos} - (\text{desvio padrão de } n \text{ períodos} \times 2)$$

Sua interpretação pode ser dada por meio dos toques na banda superior, sinal de venda é gerado, e inferior, sinal de compra, e por intermédio do cruzamento da banda intermediária pelo preço da ação, caso isso ocorra ascendentemente significa que existe uma tendência de alta, caso contrário é uma tendência de baixa. Entretanto, segundo Umbarkar e Student (2014) ele também pode ser utilizado para verificar a volatilidade do ativo, algo que pode ser visto através do estreitamento, indicando baixa volatilidade, e o alargamento, indicando alta volatilidade.

2.1.7 Redes Neurais

A utilização de redes neurais é um dos meios para se realizar a predição do movimento de preços a fim de se obter um bom indicativo para a compra ou venda de ações. Segundo Haykin (2007), uma rede neural artificial (RNA) é formada por um conjunto de neurônios artificiais que tentam simular o funcionamento dos neurônios biológicos. Depois de treinadas, elas podem realizar ações inteligentes sobre algum novo dado, com base em padrões aprendidos.

Segundo Zanini (2004) é possível distinguir três classes fundamentais de arquiteturas implementadas por redes neurais: Redes *feedforward* de uma única camada; Redes *feedforward* de múltiplas camadas; e Redes recorrentes. Entre as três classes, uma rede recorrente pode ser considerada as mais complexa, pois segundo Segatto e Coury (2006) ela contém pelo menos um laço de recorrência (*feedback*), em outras palavras, temos que os dados de entrada da célula são uma composição dos dados de saída com os de entrada, algo que possibilita que a célula obtenha memória.

2.1.8 Long Short Term Memory (LSTM)

Estas classes de redes possuem diversas variações, a RNA que foi selecionada para ser desenvolvida neste trabalho foi a LSTM, que foi proposta por Hochreiter e Schmidhuber (1997), e está contida na classe de redes recorrentes. Ela é adequada para o estudo por ser capaz de guardar longos períodos de memória e esquecer estados “irrelevantes” utilizando a sua porta de esquecimento. Sua estrutura pode ser dividida entre três partes, a porta de esquecimento, porta de entrada e porta de saída (Figura 1).




Figura 1 - Célula LSTM

Fonte: Colah's blog

A porta de esquecimento (*forget gate* - Figura 2-a)) é responsável pelo esquecimento de estados “irrelevantes”, para isto a rede neural LSTM utiliza-se de uma função sigmóide que é aplicada na seguinte expressão matemática.

$$\sigma(W_f * [h_{t-1}, x_t] + b_f)$$

onde W_f , h_{t-1} , x_t e b_f são respectivamente uma matriz de pesos, o valor de saída do estado oculto anterior, o vetor de entrada e o *bias*. O resultado produzido por esta função é entre zero e um, onde quanto mais próximo do zero significa maior esquecimento e mais perto de um maior permanência de memória.




Figura 2 – Portas de uma Célula LSTM

Fonte: Colah's blog

A porta de entrada (*input gate* – Figura 2-b)) é responsável pela seleção das informações que serão armazenadas na célula, para isto também é utilizado uma função sigmoide em conjunto com uma tangente hiperbólica, onde a primeira é formulada da mesma forma que na porta de esquecimento e a segunda é dada pela seguinte expressão matemática.

$$\tanh(W_c * [h_{t-1}, x_t] + b_c)$$

onde W_c , h_{t-1} , x_t e b_c tem o mesmo significado que na expressão anterior, mas diferentemente gera valores entre -1 e 1 que serve para a normalização da rede. Em seguida ocorre a multiplicação do resultado de ambas as funções que posteriormente é somado com o resultado da multiplicação da função sigmoide da porta de esquecimento pelo valor do estado da célula anterior, e então é gerado o valor do estado da célula atual.

Por último, a porta de saída (*output gate* – Figura 2-c)) é responsável tanto para a geração da entrada do estado posterior, assim como para a geração do resultado final da previsão da rede neural, para isto é realizada uma multiplicação entre o valor de uma função sigmoide, que é igual às anteriores, pela função tangente hiperbólica do valor do estado atual da célula.

3. MÉTODO

Para a realização dos experimentos foram utilizados dados históricos de preços de ações para criação dos modelos, os quais foram testados nos dados históricos do último ano, em simulações de investimento a partir de um montante hipotético de U\$\$ 100.000. Diversos parâmetros de ambos os protótipos foram modificados e testados a fim de se obter os melhores resultados, depois destes testes foi percebido que, em geral, os melhores retornos para o modelo que utiliza redes neurais eram obtidos quando se previa o preço da ação para seis *trades* futuras (6 dias úteis), já a versão que é baseada apenas em indicadores técnicos era a previsão para a próxima *trade*, e quando se selecionava um período de 1305 dias úteis de dados históricos (empresas mais antigas na bolsa) ou desde o início da série histórica para as ações com menos de 1305 dias úteis nas bolsas de valores (empresas mais recentes na bolsa).

Entretanto, esta seleção variável de dados históricos se mostrou complicada quando precisamos realizar uma avaliação dos resultados obtidos, pois precisamos definir um período de testes que não se sobrepõe ao período de treinamento de nenhuma ação. Tendo isto em mente foi definido uma porcentagem fixa de treinamento de oitenta por cento da base de dados e um tempo fixo

de um ano de testes que não sobrepõe nenhum tempo de treinamento das ações, sendo assim temos os tempos de treinamento e teste conforme a ilustração da Figura 3 com uma lacuna entre estes tempos.




Figura 3 - Definição dos tempos de treinamento e teste

Para a realização de simulações na bolsa de valores brasileira, B3, foram selecionados as vinte ações com maior participação no principal indicador da B3, o IBOVESPA, já para os testes na bolsa de valores americana, NASDAQ, as vinte ações selecionadas foram com base na sua participação no indicador Nasdaq-100, que é composto pelas cem maiores empresas não financeiras listadas na bolsa de valores NASDAQ. Uma versão resumida das ações escolhidas pode ser vista no Quadro 1.

Símbolo	Razão Social	Tipo
AAPL	Apple	Common Stock
ABEV3	Ambev	Ação Ordinária
ADBE	Adobe	Common Stock
AMGN	Amgen	Common Stock
AMZN	Amazon.com	Common Stock
...

Quadro 1 - Lista resumida das empresas selecionadas

4. RESULTADOS OBTIDOS

Nesta seção são apresentados os resultados obtidos por meio da aplicação dos modelos desenvolvidos sobre as ações selecionadas na bolsa de valores americana NASDAQ e na brasileira B3.

4.1 Análise do modelo de indicadores técnicos

O primeiro modelo implementado, tem como base a utilização de indicadores técnicos apenas, sem a utilização de redes neurais. Entretanto, ainda foi utilizado um algoritmo genético (Fernández-Blanco, Bodas-Sagi, Soltero & Hidalgo, 2008) na otimização da porção de investimentos quando se identificava bons momentos de compra/venda. Foram realizadas 10 simulações com o modelo, sendo possível extrair o percentual de acertos na tomada de decisão (Figura 4).




Figura 4 - Porcentagem de acertos na tomada de decisões do preditor sem rede neural para as ações da NASDAQ

A partir da Figura 4, é possível perceber que a utilização do preditor baseado em indicadores técnicos sem rede neural tem em média uma taxa de 64,48% de acerto na tomada do conjunto de decisão venda e compra nas ações selecionadas na bolsa de valores NASDAQ. Dentre elas com exceção das ações APPL, MSFT, CSCO e COST, todas as outras estão contidas em uma faixa que varia em mais ou menos 30 pontos percentuais, e surpreendente para as ações APPL e MSFT foi obtido uma taxa de 100% de acerto entretanto, em busca de explicações para este resultado, foi percebido que o retorno obtido não é nenhum pouco surpreendente, pois para ambas as ações foram feitas menos de dez aplicações e a sua variação é quase contínua de alta. A Figura 5 apresenta os dados das simulações do modelo de indicadores técnicos na B3.




Figura 5 - Porcentagem de acertos na tomada de decisões do preditor sem rede neural para as ações da B3

Com base nas Figuras 4 e 5 é possível perceber que a utilização do preditor nas ações da bolsa de valores brasileiras tem uma porcentagem de acerto consideravelmente inferior, sendo este em média de 52,83% de acertos, sendo assim, 11,65% menor que sua utilização na bolsa americana, NASDAQ.

A partir da Figura 6 é possível verificar que em média o retorno obtido pelo previsor na NASDAQ é de 111,20% de lucro. Entretanto, ressalta-se que a variação do preço dos ativos no período de análise foi de 92,46%, ou seja, a técnica obteve um lucro adicional de 18,74%.




Figura 6 - Resultado obtido com o preditor sem rede neural para as ações da NASDAQ

Além disso, dentre as vinte ações da bolsa de valores americana, apenas nas ações AVGO e QCOM o preditor parece realmente ter realizado uma previsão que muda-se consideravelmente o resultado que poderia ser obtido através de uma aplicação de longo prazo que se iniciaria na compra no primeiro dia de teste e terminaria na venda no último dia de testes, nestas aplicações a diferença relativa de retorno do investimento foi de 66,68% e 54,84% respectivamente.

A partir da análise do gráfico contido na Figura 7, é possível constatar que diferentemente da utilização do preditor para a predição do preço nas ações da NASDAQ, a utilização do preditor para as ações da B3 traz com maior frequência, resultados que variam substancialmente dos retornos que seriam obtidos por meio de uma aplicação de longo prazo, que consumiria todo o tempo de testes. Dentre as ações em que isto ocorreu, vale ressaltar as que mesmo com a queda do preço do ativo, a aplicação utilizando o preditor conseguiu obter lucro, e os ativos VALE3 e GNDI3 onde a variação do preço da ação respectivamente foi de 36,73% e 56,29%, enquanto o resultado obtido pela utilização do preditor foi de 134,05% e 115,52% respectivamente.




Figura 7 - Resultado obtido com o preditor sem rede neural para as ações da B3

4.2 Análise do Preditor que utiliza RNA

Como dito anteriormente, todas as redes foram treinadas da mesma maneira, com os mesmos parâmetros, sendo eles selecionados de modo que o desempenho em média fosse maximizado e que as perdas fossem minimizadas, algo que fez com que nenhuma rede neural alcançasse o seu máximo de desempenho pois o mesmo implicaria em grandes perdas para outras RNAs.

Este fenômeno foi notado com frequência durante o desenvolvimento do protótipo, pois quando se tentava melhorar os retornos alcançados com a utilização da rede neural nas ações da NASDAQ, via o aumento da quantidade de épocas e diminuição do tamanho dos lotes, as ações da B3 sofriam grandes prejuízos na diminuição dos ganhos obtidos.

Por meio dos gráficos contidos nas figuras 8 e 9, é possível notar que a utilização das redes neurais baseadas nos indicadores técnicos selecionados, obtiveram resultados em média de 62,77% na bolsa de valores americana e 59,55% na brasileira. E em geral se obteve uma porcentagem de acerto acima de 50%, com exceção das ações ITUB4, BBAS3, JBSS3 e BBDC3, algo que se torna um pouco compreensível quando observamos o gráfico de variação de preço das ações, pois com exceção da ação JBSS3 todas as outras tiveram uma variação acima de trinta por cento de queda no preço da ação. Todavia, uma análise similar vale para as ações com mais de 75% de acerto, pois quase todas elas tiveram variação de mais de 100% de alta no preço da ação, com exceção da ADBE que teve uma alta de 86,76%.




Figura 8 - Porcentagem de acertos na tomada de decisões do preditor com rede neural para as ações da NASDAQ




Figura 9 - Porcentagem de acertos na tomada de decisões do preditor com rede neural para as ações da B3

Com o auxílio do gráfico da Figura 10 pode-se perceber que mesmo com uma boa taxa de acerto na tomada de decisões, a rede neural só foi capaz de alcançar um desempenho maior que a variação da ação no período de tempo da realização do teste em apenas seis ações. Neste período, as ações que a rede neural mais se destacou foram na ação da Cisco (CSCO), onde ela

conseguiu reverter uma pequena baixa de 9,19% em uma pequena alta de 2,16% e na ação da Tesla (TSLA) onde ela foi capaz de superar alta da ação da Tesla em 197,97 pontos percentuais, algo que influenciou fortemente para a rede neural conseguir um desempenho médio de 4,86% a mais em média de lucro, caso contrário a rede neural sem a ação da Tesla teria desempenho de 5,3% a menos em média de lucro.




Figura 10 - Resultado obtido com o preditor que utiliza rede neural para as ações da NASDAQ

A partir do gráfico ilustrado na Figura 11, fomos capazes de constatar que dentre as vinte ações, apenas em três o preditor utilizando redes neurais baseadas em indicadores técnicos, obteve um desempenho menor que a variação do preço do ativo no período de predição. Entretanto, este baixo desempenho só se torna notável quando observamos a ação SUZB3, que teve uma variação do preço da ação de 67,83% no período; enquanto que o preditor obteve um ganho de 9,33%; em média a variação do valor do ativo foi de 23,05% enquanto a média do resultado obtido usando o preditor foi de 59,46%.

Também foi possível perceber que em quase todas as ações que tiveram uma variação de queda no preço, com exceção da JBSS3, o resultado obtido foi de lucro modesto; com exceção das ações PETR4 e PETR3 em que se obteve um lucro de 67,85% e 126,15% respectivamente, enquanto a queda foi de 13,37% e 18,27%.

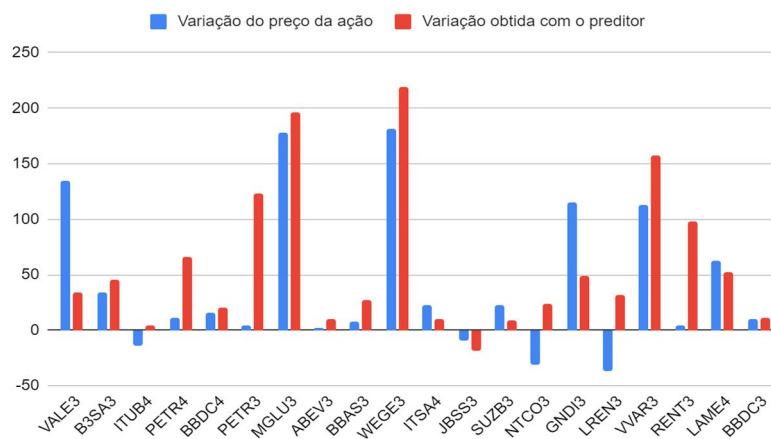


Figura 11 - Resultado obtido com o preditor que utiliza rede neural para as ações da B3

Com o auxílio do gráfico da Figura 12, junto a outros gráficos da bolsa de valores NASDAQ, contido no apêndice A, é possível perceber que o preditor que utiliza redes neurais, mesmo gerando lucros, comete erros que geram grandes prejuízos no decorrer do período da aplicação, algo que ocorre justamente devido à compra quando há queda maior de 5% no valor do ativo.

Todavia, ao desenvolver o preditor foi constatado que a não inclusão desta condição, realmente gera menos perdas de grande magnitude. Contudo, também há uma diminuição da quantidade de oportunidades de ganho, gerando assim um retorno menor no final do período de aplicação, por isso mesmo com as perdas, foi decidido manter a condição.

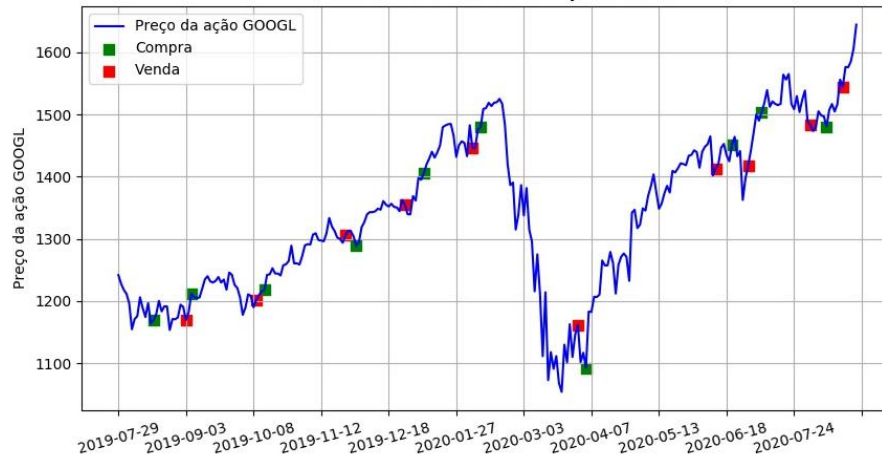


Figura 12 - Gráfico de tomada de decisões para a ação GOOGL

4.3 Análise comparativa dos preditores

Por meio do gráfico contido na Figura 13, gerado a partir da combinação dos dados obtidos através da aplicação de ambos os preditores, podemos notar que ambos os previsores obtiveram resultados próximos a variação do preço do ativo no período de teste. Entretanto, vale ressaltar o desempenho do preditor que utiliza RNA nas ações da TSLA e ADBE, que deslocou-se deste segmento da oscilação do valor da ação e além disso obteve resultados que se sobressaíram do outro preditor, assim como os resultados do previsor que não utiliza RNA nas ações AVGO e QCOM se sobressaíram do outro algoritmo. Todavia, mesmo que a utilização da RNA obtenha bons resultados nos ativos TSLA e ADBE, sua utilização gera retornos humildes que em média são apenas 4,86% maiores que a variação do preço da ação, por outro lado o algoritmo que não utiliza RNA alcança retornos que são em média 11,52% superiores a oscilação do valor do ativo.




Figura 13 - Gráfico comparativo do resultado de ambos os preditores para as ações da NASDAQ

Diferentemente dos resultados que fomos capazes de observar com o auxílio da ilustração contida na Figura 14, pode-se perceber que embora a variação obtida a partir dos preditores, ainda esteja conectada com a variação do preço da ação, isto tornou-se mais tênue. Todavia, esta atenuação se mostrou positiva, pois, em ambos os algoritmos esta mudança apenas apresentou-se negativa através da variação obtida da ação SUZB3, onde o valor do ativo variou positivamente 67,83% enquanto o resultado alcançado pelos preditores com e sem RNA foi de 23,19% e 9,01% respectivamente. Sendo assim, por meio da análise isolada desses retornos gerados para a ação SUZB3, poderíamos dizer que o preditor que não utiliza RNA apresenta os melhores resultados, todavia, em apenas seis ações este algoritmo superou o que utiliza RNA, que apresentou uma média maior em 16,97 pontos percentuais que o outro preditor.




Figura 14 - Gráfico comparativo do resultado de ambos os preditores para as ações da B3

CONCLUSÃO

O mercado de ações é um ambiente complexo que proporciona aos acionistas a possibilidade de conseguir gerar ganhos de capital, entretanto, isto está atrelado a riscos de perda. Deste modo, o objetivo deste trabalho se baseou na comparação de dois modelos baseados em indicadores técnicos para auxiliar na predição do movimento dos preços de ações.

Para atingir o objetivo do trabalho, foram analisados vários estudos sobre a predição do preço de ações para operações *swing trade*, a partir dos quais foram selecionados os seguintes indicadores técnicos: Average Directional Index, Simple Moving Average, Exponential Moving Average, Relative Strength Index, On-Balance Volume e Bollinger Bands.

A partir dos indicadores técnicos selecionados, foram então desenvolvidos dois modelos, um modelo que realiza a predição do preço de ações a partir dos indicadores técnicos e outro que utiliza redes neurais treinadas com base em indicadores técnicos”. Para o preditor que não utiliza RNA foi ainda aplicado um algoritmo genético, com o objetivo de otimizar o vetor de pesos para ponderar a importância das regras de investimento.

Por fim, foi realizada uma análise comparativa dos resultados obtidos por meio da aplicação de ambos os modelos em dados históricos de um mercado altamente volátil e de outro menos volátil. Descobrimos que para mercados de baixa volatilidade, como o da bolsa americana, NASDAQ, no período de testes, a realização de predição sem utilizar redes neurais obtém um aumento de 11,52 pontos percentuais na média de ganhos quando comparado com o outro preditor. Já num mercado mais volátil como o brasileiro, no período analisado, a utilização do preditor que utiliza RNA, auxilia no aumento de 16,97 pontos percentuais na média dos ganhos

em comparação ao outro, e simultaneamente reduz a quantidade de perdas que enquanto no outro previsor há quatro perdas, e o que utiliza RNA sofre apenas uma perda de capital.

Com base nos resultados analisados nesta pesquisa, pode-se perceber que a utilização de redes neurais para a realização da predição do preço das ações, gera uma diminuição das perdas e concomitantemente um aumento dos ganhos, enquanto a não utilização gera bons resultados caso o mercado de ações não esteja muito volátil.

Para a realização de trabalhos futuros pode-se citar as seguintes possibilidades: seleção e parametrização de outros indicadores técnicos; mudar o formato das entradas, ao invés da utilização dos dados diários, utilizar os dados do *intraday* para realizar a predição dos próximos seis trades ou até mesmo para a *trade* seguinte; explorar a combinação de dados de diversas ações, tendo em vista que a RNA aplicada para ações menos voláteis carece de certos padrões; aplicar um algoritmo genético na seleção dos parâmetros da rede neural, entretanto, para isto é necessária a utilização de *hardware* de alto desempenho.

REFERÊNCIAS

- Baba, N., Wang, Y., Kawachi, T., Xu, L. & Deng, Z. (2003). Utilization of AI & GAs to Improve the Traditional Technical Analysis in the Financial Markets. In: Palade, V., Howlett, R.J., Jain, L. (eds) *Knowledge-Based Intelligent Information and Engineering Systems*. KES 2003. Lecture Notes in Computer Science, v. 2773. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-45224-9_147.
- Bekaert, G. & Harvey, C. R. (1997). Emerging equity market volatility. *Journal of Financial Economics*, V. 43, N. 1, Pages 29-77, ISSN 0304-405X, [https://doi.org/10.1016/S0304-405X\(96\)00889-6](https://doi.org/10.1016/S0304-405X(96)00889-6).
- Blau, W. (1993). Stochastic Momentum. *Technical Analysis of Stocks and Commodities*, V. 11, N. 1, 26-32.
- Bollinger, J. (1992). Using bollinger bands. *Stocks & Commodities*, 10(2), 47-51.
- Bruni, R. (2017). Stock market index data and indicators for day trading as a binary classification problem. *Data in brief*, V. 10, p. 569-575.
- Colah's blog. (2015). *Understanding LSTM Networks*. Disponível em: <<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 17 dez. 2020.
- Drakopoulou, V. (2016). A review of fundamental and technical stock analysis techniques. *Journal of Stock & Forex Trading*.
- Eng, W. K., Shukor, N. E. S. A., Ismail, N. R. & Halim, S. A. (2017). Golden cross as Buying Indicator for Stock Investment in Bursa Malaysia. *Terengganu International Finance and Economics Journal (TIFEJ)*, V. 2, N. 2, p. 94 - 102, ISSN 2232-0539.
- Fernández-Blanco, P., Bodas-Sagi, D. J., Soltero, F. J., & Hidalgo, J. I. (2008). Technical market indicators optimization using evolutionary algorithms. *Proceedings of the 10th annual conference companion on Genetic and evolutionary computation* (pp. 1851-1858). ACM.
- Haykin, S. *Redes neurais: princípios e prática*. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2007.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, V. 9, N. 8, 1735-1780.
- Kirkpatrick II, Charles D., & Dahlquist, Julie A. (2010). *Technical analysis: the complete resource for financial market technicians*. Editora FT press.
- Klinker, F. (2011). Exponential moving average versus moving exponential average. *Mathematische Semesterberichte*, V. 58, N. 1, 97-107.

- Lauren, S., & Harlili, S. D. (2014). Stock trend prediction using simple moving average supported by news classification. *2014 International Conference of Advanced Informatics: Concept, Theory and Application (ICAICTA)* (pp. 135-139). IEEE.
- Liu, H., & Song, B. (2017). Stock trends forecasting by multi-layer stochastic ANN bagging. *2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI)* (pp. 322-329). IEEE.
- Oriani, F. B., & Coelho, G. P. (2016, Dezembro). Evaluating the impact of technical indicators on stock forecasting. *2016 IEEE Symposium Series on Computational Intelligence (SSCI)* (pp. 1-8). IEEE.
- SUBSECRETARIA DE ARRECAÇÃO, CADASTROS E ATENDIMENTO. Taxa de Juros Selic. Receita Federal, 2020. Disponível em: <<http://receita.economia.gov.br/orientacao/tributaria/pagamentos-e-parcelamentos/taxa-de-juros-selic>>. Acesso em: Janeiro 2020.
- Segatto, E. C., & Coury, D. V. (2006). Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, V. 17, N. 4, 424-436.
- Umbarkar, S. S., & Student, P. G. (2014). Stock Market Prediction From Financial News: A survey. *International Journal of Engineering Research and General Science*, V. 2, N. 6, October-November, 2014
- Vaiz, J. S., & Ramaswami, M. (2016). A Study on Technical Indicators in Stock Price Movement Prediction Using Decision Tree Algorithms. *American Journal of Engineering Research*, V. 5, N. 12, pp-207-212, e-ISSN: 2320-0847 p-ISSN: 2320-0936.
- Wilder, J.W. (1978). *New Concepts in Technical Trading Systems*. Trend Research. USA: Editora Hunter Publishing Company.
- Zanini, A. (2004). *Regulação econômica no setor elétrico brasileiro: uma metodologia para definição de fronteiras de eficiência e cálculo do fator X para empresas distribuidoras de energia elétrica*. 170p. Tese, Doutorado em Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro.