



Congresso Internacional
de Administração
ADM 2022

24 a 28
de outubro
Ponta Grossa - Paraná - Brasil

**SOBREVIVÊNCIA DAS ORGANIZAÇÕES
EM TEMPOS INCERTOS:**

O papel dos gestores e do ambiente externo
no sucesso e no fracasso organizacional.

ANÁLISE DE PREDIÇÃO DO MOVIMENTO DE PREÇO DE AÇÕES UTILIZANDO REDES NEURAI E UMA TÉCNICA AD-HOC

ANALYSIS OF STOCK PRICE PREDICTION USING NEURAL NETWORKS AND AN AD-HOC TECHNIQUE

ÁREA TEMÁTICA: 6 FINANÇAS

Andre Dias Menegazzo Pereira, Estadual de Maringá, Brasil, andremenegazzo@gmail.com

Wagner Igarashi, Universidade Estadual de Maringá, Brasil, wigarashi@uem.br

Deisy Cristina Corrêa Igarashi, Estadual de Maringá, Brasil, dccigarashi@uem.br

Resumo

O mercado financeiro continua crescendo e se popularizando cada vez mais e com isso os investidores novos e de carreira buscam sistemas de suporte à decisão para aumentar seu rendimento e evitar riscos nos seus investimentos. Com essa ideia, este artigo tem como objetivo avaliar duas técnicas utilizadas em simuladores de investimento, uma técnica *ad-hoc* e uma rede neural usando indicadores técnicos. Para avaliá-los, foram usados dados históricos de preço das ações da empresa CSN negociados na B3. Os simuladores buscavam operações de compra e venda, dia após dia. Os resultados indicam que a rede neural utilizando indicadores técnicos pode ser um eficiente sistema de suporte à decisão para investidores.

Palavras chave: Simulador de investimento; Análise técnica; Rede neural artificial.

Abstract

The financial market continues to grow and become increasingly popular and with that new and career investors are looking for decision support systems to increase their income and avoid risks in their investments. With this idea in mind, this article aims to evaluate two techniques used in investment simulators, an ad-hoc technique and a neural network using technical indicators. To evaluate them, historical data on the price of shares of the company CSN traded on B3 were used. The simulators were looking for buy and sell operations, day after day. The results indicate that the neural network using technical indicators can be an efficient decision support system for investors.

Keywords: Investment simulator; Technical analysis; Artificial neural networks.

1. INTRODUÇÃO

No mercado de ações, as empresas (tomadores) buscam financiamento para seu funcionamento por meio da emissão de ações (frações mínimas da empresa) esperando que investidores se tornem sócios, comprando essas pequenas parcelas. Para realizar estas transações, tanto tomadores quanto investidores buscam a bolsa de valores, que controla e fiscaliza as transações. Além disso, a bolsa de valores traz transparência para as transações.

Os investidores compram as ações visando retorno financeiro no futuro, seja pelo pagamento de dividendos, pelos lucros alcançados ou vendendo estas ações após a valorização da empresa em que investiu. Esta valorização ocorre devido ao desempenho da empresa e ao sentimento do mercado em relação a referida empresa. Por outro lado, caso haja uma venda significativa destes

ativos e conseqüentemente uma maior oferta de ações, pode acarretar a desvalorização da empresa, causando prejuízo aos investidores.

Para potencializar o resultado possível, investidores buscam pela melhor estratégia de acordo com o seu perfil de investimento, a partir do que se conhece e espera do mercado: empresa que mais valoriza (maior retorno no investimento), empresa com mais chances de valorizar (maior segurança no investimento), quando comprar e quando vender as ações, qual carteira montar, etc.

Neste cenário, existem duas classes de análises que podem ser realizadas para entender o comportamento do mercado e assim prevê-lo, a análise fundamentalista e a análise técnica. A análise fundamentalista estuda o contexto da empresa e do mercado, relatórios financeiros, acontecimentos, políticas governamentais. Assim, a análise fundamentalista é mais apropriada para médio e longo prazo. A análise técnica tem foco nos dados de preço e volume de transações, sendo mais apropriada no curto e médio prazo. Todavia o ideal seria unir as duas análises, somando as competências e minimizando as fraquezas de cada uma. Todavia, do ponto de vista prático, observa-se que a análise fundamentalista trata de um universo mais amplo e com informações subjetivas, dificilmente tratadas em modelos matemáticos e computacionais.

Neste caso, uma estratégia mais prática para se tentar tomar decisões de compra e venda de ações seria a de se construir um modelo que utilize análise técnica, simule o mercado e assim preveja o comportamento das ações. Além da análise técnica, há ainda a possibilidade de se utilizar Redes Neurais Artificiais, que podem aprender a partir de indicadores financeiros a como realizar a predição do movimento de preço de uma ação. Uma outra forma de análise que pode ser utilizada é a personalização de modelos instruídos a partir de concepções empíricas sobre práticas de investimento no mercado de ações (modelo *ad-hoc*). O modelo *ad-hoc* tem seu funcionamento calibrado para um único período e realidade de mercado. O modelo *ad-hoc* poderá ser ajustado após algumas simulações de investimento considerando uma ação específica. Em contraponto, um sistema baseado em redes neurais pode aprender e se adaptar às novas realidades, capacidade de realizar computação distribuída, tolerar entradas ruidosas, todavia pode estar sujeito a identificar falsos padrões, seja pelo acaso ou pelo treinamento (Russel e Norvig, 2021).

A partir do exposto esta pesquisa visa avaliar duas técnicas utilizadas em simuladores de investimento, uma técnica *ad-hoc* e uma rede neural usando indicadores técnicos. E busca responder ao seguinte questionamento de pesquisa: técnicas personalizadas (*ad-hoc*) podem ter melhor resultado do que técnicas tradicionais como indicadores técnicos e redes neurais na predição do movimento de preço de ações? Cabe ressaltar que a predição do movimento de preços de qualquer ativo é uma atividade complexa e abre espaço para a realização de uma grande quantidade de estudos experimentais, combinando diferentes técnicas e teorias.

2. ANÁLISE FUNDAMENTALISTA E ANÁLISE TÉCNICA

A análise fundamentalista estuda as forças econômicas de oferta e demanda que afetam o preços no mercado, dentre elas, a situação econômica do país, inflação, taxa de juros, política cambial e fiscal e a situação da própria empresa, estrutura societária, seus balanços contábeis, demografia da clientela, situações dos concorrentes, etc. Ao avaliar estes fatores busca-se o

valor real de um ativo, se este valor encontrado não condiz com o valor negociado no mercado, então o fundamentalista, pode agir de acordo para se antever ao resto do mercado e lucrar na operação. Contudo, as informações da análise fundamentalista não são facilmente tratadas computacionalmente e por isso não estão no escopo deste estudo.

Com relação a análise técnica Murphy (1999) pondera três premissas para a abordagens: (a) **o mercado assimila tudo** – todos os elementos e fatos que podem afetar o preço estão refletidos no preço. Por isso, entender e analisar os preços é o suficiente para compreender o comportamento do mercado; (b) **Preços seguem tendências** – traçando o paralelo com a primeira lei de Newton, Murphy (1999) explica que os preços seguem tendências e uma vez em movimento, tendem a seguir aquele movimento. A análise deve buscar identificar as tendências em seus primeiros sinais; (c) **a história se repete** - o mercado antes de ser cifras e gráficos é composto por pessoas e seus comportamentos e a história nos mostra que muitos dos grandes acontecimentos são ecos de acontecimentos anteriores. Assim, para entender e prever o futuro é preciso entender o passado.

De acordo a teoria de Murphy (1999), diversos indicadores técnicos foram criados ao longo dos anos. Parte destes indicadores podem ser classificados como do tipo *Leading* e *Lagging*, os quais são utilizados para avaliar a força do mercado. Os indicadores *leading* indicam mudança de movimento, pois eles mudam antes de uma nova tendência de mercado. Por outro lado, os indicadores *lagging* fornecem sinais depois que uma tendência já está em andamento, daí o nome “lag” (atraso), eles explicam o passado ou a causa de uma tendência. Alguns destes indicadores técnicos estão apresentados no quadro 1.

Indicador	Descrição
Média móvel simples (MMS)	<p>A média móvel simples (MMS ou <i>Simple Moving Average - SMA</i>) é um indicador do tipo <i>lagging</i> que agrega um intervalo de resultados num valor suavizado. Consequentemente não antecipa tendências, confirma a tendência atual. Apresenta problemas quando o mercado não tem tendência definida. E é representado pela fórmula:</p> $MMS(n) = \frac{\sum_{i=1}^n P_i}{n}$ <p>P_i = preço de fechamento do dia i, e n = período em dias</p>
Média móvel exponencial (MME)	<p>A média móvel exponencial (MME ou <i>Exponential Moving Average - EMA</i>) é um indicador <i>lagging</i>. Elimina uma fraqueza da Média móvel simples ao atribuir maior peso aos resultados mais recentes. A MME tem uma configuração de cálculo baseada nas médias móveis exponenciais dos dias anteriores para o seu cálculo. Entretanto, por causa da definição recursiva, é necessário definir o caso base, para que não realize a recursão indefinidamente. Sendo assim, para o primeiro dia utiliza-se uma MMS. Para o cálculo da MME, calcula-se primeiramente um fator de ponderação k</p> $k = \frac{2}{n+1}$ <p>Com base no fator k, pode-se calcula a MME a partir da fórmula:</p> $MME(n) = (P_i - MME(i - 1)) * k + MME(i - 1)$

<p>Indicador de Força Relativa (IFR)</p>	<p>O indicador de força relativa (IFR ou <i>Relative Strength Index - RSI</i>) é um indicador <i>leading</i>. Mostra a velocidade da mudança nos preços e o status de ‘sobrecomprado’ e ‘sobrevendido’, isto é, estão sendo negociadas fora da situação entendida como dentro do padrão de transações, acima e abaixo do valor entendido, respectivamente.</p> $IFR = 100 - 100 / (1-RS)$ <p>Sendo que RS = Ganho médio no Período / Perda média no Período</p>
<p>Média Móvel Convergente/Divergente (MACD)</p>	<p>A média móvel convergente/divergente (<i>Moving Average Convergence/ Divergence - MACD</i>) é um indicador <i>leading</i>. Construído utilizando dois indicadores EMA que ao se cruzarem dão sinal de compra/venda. É comum na indústria se usar EMA de 12 e 26 dias no cálculo, sintetizando a movimentação de 2 semanas e 1 mês. Outros valores podem ser utilizados de acordo com a necessidade. A fórmula do MACD é mostrada a seguir:</p> $MACD = EMA(12) - EMA(26)$
<p>Taxa de Variação (ROC)</p>	<p>A taxa de variação (<i>Rate of Change - ROC</i>) mede o deslocamento percentual dos preços analisando o preço de fechamento de n dias passados. Esta taxa mede o otimismo e pessimismo do mercado, e para isso utiliza a taxa ROC</p> $ROC = (\text{PreçoDeFechamento} - \text{PreçoDeFechamento}(n)) / \text{PreçoDeFechamento}(n)$

Quadro 1: Indicadores técnicos e descrição

Fonte: Oriani e Coelho (2016), Sachetim (2006) e Lemos (2015).

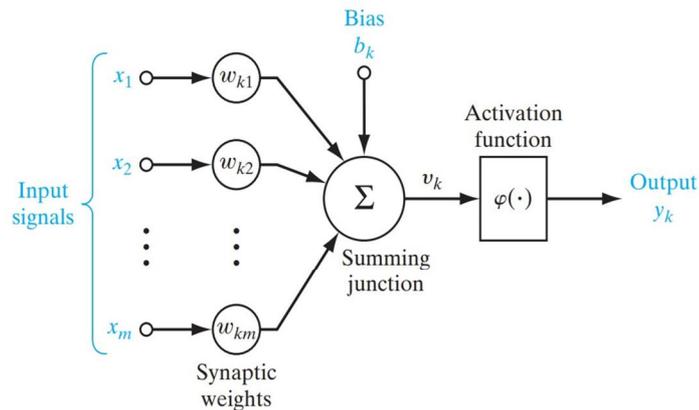
A partir desses conceitos a análise técnica busca calcular indicadores extraídos de resultados passados para estimar o comportamento e força dos movimentos futuros no preço. Como pode ser observado no quadro 1, os indicadores podem ser categorizados em *leading* e *lagging* (Oriani & Coelho, 2016), o primeiro indica mudança enquanto o segundo, confirma uma tendência já existente.

3. REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais são sistemas que imitam o comportamento e estrutura do cérebro humano e de seus componentes mínimos, os neurônios. Os neurônios são células especializadas na transmissão de informação e são compostos simplificada por dendritos, núcleo e axônio. Os dendritos são como entradas de dados dos neurônios que recebem impulsos de outros neurônios e se passarem de um limiar de ativação o repassam, combinando a outros impulsos que o neurônio tiver recebido e validado, para os próximos neurônios pelas sinapses, químicas ou elétricas, em seu axônio. Estas ligações quando frequentes se fortalecem e de mesma forma enfraquecem quando não ativadas. Este comportamento sugerido por Donald O. Hebb em 1949, é uma das bases para a aprendizagem em Redes Neurais Artificiais (RNAs) (Haykin, 2009).

Como no cérebro humano, estes componentes mínimos realizam processamento limitado, mas graças ao grande número de componentes e associação entre eles de forma paralelamente distribuída em larga escala, o todo é capaz de realizar tarefas complexas. Ainda como no cérebro humano, o sistema é capaz de se adaptar e responder a entradas diversas. Essa qualidade torna as RNAs versáteis para uso em diversas áreas do conhecimento (Müller & Kramer, Ai et al., Goyal & Raj, 2022).

O segredo da “aprendizagem” estaria na calibração da ponderação entre as entradas de acordo com a verificação entre o resultado produzido e o resultado esperado. Na figura 1 é apresentado de modo esquemática um neurônio artificial.



Sendo: x_i : Entrada i omega w_{ki} : Peso para a entrada i
 Σ : Função de transferência $\varphi(\cdot)$: Função de ativação
 b_k : Limiar de ativação y_k : Saída

Figura 1 – Esquema de um neurônio artificial

Fonte: Haykin (2009, p.11)

De acordo com a figura 1 um elemento importante que define o comportamento de um neurônio artificial é a função de ativação $\varphi(\cdot)$. A escolha desta função deve considerar o tipo de problema a ser modelado pela rede neural: regressão linear, regressão logística, classificação, etc. Na sequência são apresentados alguns tipos de funções comumente utilizados.

- Função Linear

$$\varphi(\cdot) = x \quad (1)$$

- Função Degrau

$$\varphi(\cdot) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (2)$$

- Função Degrau bipolar

$$\varphi(\cdot) = \begin{cases} 1, & \text{se } x \geq 0 \\ -1, & \text{se } x < 0 \end{cases} \quad (3)$$

- Função Rampa

$$\varphi(\cdot) = \begin{cases} 1, & \text{se } x \geq a \\ x, & \text{se } -a < x < a \\ -1, & \text{se } x \leq -a \end{cases} \quad (4)$$

- Função Sigmóide

$$\varphi(\cdot) = \frac{1}{1 + e^{-x}} \text{ ads} \quad (5)$$

- Função Tangente hiperbólica

$$\varphi(\cdot) = \tanh(x) \quad (6)$$

Ao associar mais destes neurônios em camadas de nós, a capacidade e velocidade do aprendizado aumentam, e o resultado é uma rede neural artificial (figura 2). A figura 2 apresenta uma rede neural artificial com uma camada de entrada, que recebe os sinais das variáveis de um problema a ser modelado, 2 camadas intermediárias e uma camada de saída. O número de camadas intermediárias é variável, no entanto, com o aumento de camadas, se aumenta o tempo necessário para o treinamento da rede.

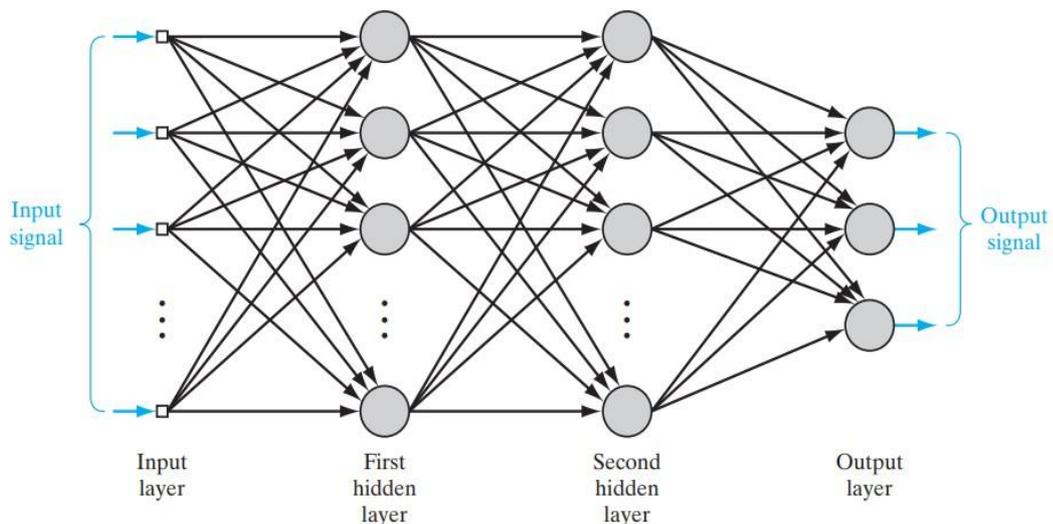


Figura 2 – Rede neural multilayer perceptron

Fonte: Haykin (2009, p.124)

Durante o desenvolvimento deste estudo, foram observados outros trabalhos desenvolvidos nos mesmos moldes. Dentre eles são apresentados a seguir os trabalhos de Marangoni (2010), Martins, Mette & Macedo (2008) e Girioli e Ribeiro (2009).

Marangoni (2010) buscou verificar se redes neurais artificiais são capazes de prever o preço futuro de fechamento de uma ação, para isso utilizou dados da ação da Petrobras (PETR4), dados da IBOVESPA (atual B3) e indicadores técnicos extraídos dos dados como entradas para a rede neural artificial. Os autores obtiveram resultados positivos, com previsões muito próximas da realidade para um período de até 20 dias no futuro.

Martins et al. (2008) verificaram a qualidade da predição de preço dado por uma rede neural artificial para a ação da Petrobras (PETR4). Ele utilizou o erro quadrado médio (EQM ou *Mean Square Error - MSE*) para mensurar o erro e tiveram resultados com alta aderência com a realidade para períodos curtos. Martins et al. (2008) alerta para a necessidade de testar a técnica em outros períodos e outras empresas com comportamento mais divergentes do mercado.

Girioli e Ribeiro (2009) estudou a tomada de decisão a partir da predição de mercado dada por redes neurais artificiais, para isso fez uso de dados da IBOVESPA (B3) e da *Dow Jones Industrial Average* (DJIA), obtendo taxas de acerto de 59%.

4. MATERIAIS E MÉTODOS

Em um primeiro momento foi feito um levantamento teórico sobre os mercados de ações, indicadores técnicos e redes neurais. Em relação ao mercado de ações verificou-se que havia duas teorias mais utilizadas para a predição do movimento de preços de ações: análise técnica e análise fundamentalista.

Verificou-se que a análise fundamentalista é complexa e envolve diversos elementos abstratos que são de difícil mensuração. Então, selecionamos a teoria *Down*, a qual depende apenas do preço da ação e se utiliza da análise técnica para o cálculo de indicadores que auxiliam no processo de predição. Entretanto, cabe ressaltar que é possível obter dezenas de indicadores técnicos.

Sendo assim, analisou-se na literatura quais eram os indicadores técnicos mais utilizados, bem como foram identificadas as parametrizações mais utilizadas. A partir desta seleção de indicadores, foram então iniciados alguns ensaios para testar a utilização conjunta destes indicadores para o treinamento de uma rede neural. Verificou-se que a utilização de uma grande quantidade de indicadores trazia uma piora para a rede neural. Então foram selecionados um subconjunto que tivesse melhores resultados.

A partir de então foi analisado um estudo, aqui denominado de modelo *ad-hoc*, de uma universidade do noroeste do estado do Paraná, como base comparativa para o modelo de rede neural. O modelo é considerado *ad-hoc*, porque não utilizou os conceitos tradicionais de indicadores técnicos e nem de redes neurais para predição de preço. O modelo *ad-hoc* foi construído de modo personalizado a tentar simular transações de compra e venda de modo a obter lucro.

Na sequência, foram então extraídos dados históricos de preços das ações da CSNa (Companhia Siderúrgica Nacional) a partir da B3. Com estes dados foram então realizadas simulações de investimentos partir do modelo de redes neurais e o *ad-hoc*, utilizando-se como base um valor inicial de R\$ 100.000,00. Por fim, foram realizadas análises e comparações com os dois modelos utilizados nas simulações.

5. EXPERIMENTOS

O experimento consistiu em utilizar dados históricos de cinco períodos de precificação de ações para comparar as previsões entre dois sistemas de predição. Aos dois sistemas que estão sendo comparados foram alimentados com dados dos primeiros quatro anos da série histórica. Para a

comparação utiliza-se um modelo *ad-hoc* construído anteriormente, o qual está sendo operacionalizado neste estudo. Utiliza-se também de um modelo que utiliza redes neurais com indicadores técnicos e que está sendo proposto nesta pesquisa.

Para comparar o desempenho financeiro das simulações de investimentos nos dois modelos foram realizadas movimentações idênticas em cada um dos dois modelos. Além disso, utilizou-se de um modelo de *benchmarking*. Para isso, foi utilizado, adicionalmente um modelo oráculo. O oráculo se utiliza dos dados históricos dos cinco períodos, ou seja, ele dispõe das informações de todo o período, inclusive das informações que os sistemas *ad-hoc* e de redes neurais não utilizam para amparar suas previsões. Por tanto, o oráculo apresenta um desempenho financeiro ótimo (ideal) em comparação aos outros dois sistemas em estudo.

Para a simulação junto aos modelos foram utilizados os dados históricos da maior indústria siderúrgica da América Latina, a Companhia Siderúrgica Nacional (CSN), criada em 1941 por decreto do então Presidente Getúlio Vargas e foi privatizada em 1993 no governo de Itamar Franco. A CSN tem sede na cidade de Volta Redonda no Rio de Janeiro, mas conta com instalações por todo Brasil, em Portugal e na Alemanha, O Grupo CSN além da siderurgia, trabalha nos setores de mineração, logística, cimento e energia.

Na figura 3 é possível observar a cotação da ação da empresa, CSN, entre o período 2013 e 2018.

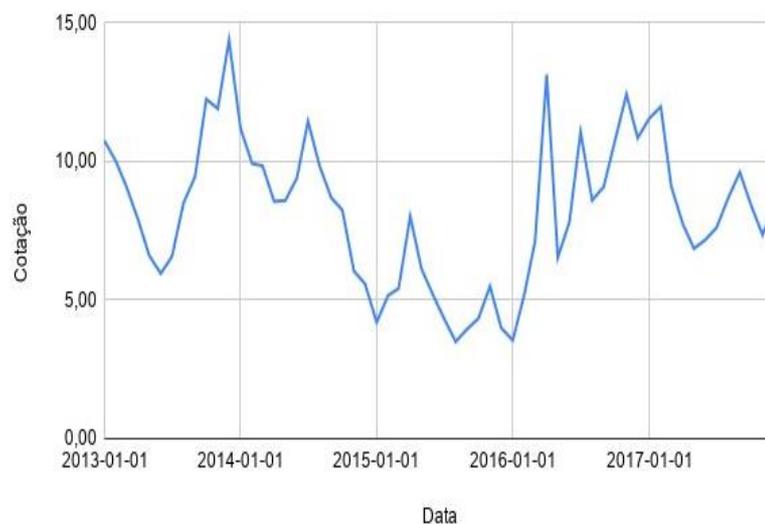


Figura 3 – Cotação da CSN entre 2013 e 2018

Para o desenvolvimento da pesquisa foram utilizadas das informações da CSN de 2013 a 2017.

5.1 Simulador *ad-hoc*

O modelo *ad-hoc* utilizado nesta pesquisa foi desenvolvido previamente por um aluno de uma universidade do noroeste do Paraná. O modelo usa um portfólio de 10 empresas negociadas na [B]3, as quais foram selecionadas dentre 20 empresas listadas pela revista Exame na edição

Melhores e Maiores de 2015. O período de análise do modelo foi referente ao período de 2013 a 2017.

O algoritmo de compra e venda do modelo *ad-hoc* é simples e utiliza como estratégia de compra ou venda quando o valor da ação no dia é menor ou maior que uma porcentagem sobre a média simples de n dias de cada empresa, e as negocia proporcionalmente esta diferença sobre a média e é avaliado sobre o lucro obtido no período de um ano com um investimento inicial de R\$100.000,00.

Mesmo simples e se aproximando muito de um sistema de regras de produção, a técnica *ad-hoc* tem um bom desempenho. Por isto o interesse em comparar este modelo *ad-hoc* com outros modelos mais elaborados, tanto em funcionamento como nas entradas utilizadas. Nesta pesquisa o modelo *ad-hoc* foi alterado de modo a utilizar somente os dados históricos financeiros da CSN.

5.2 Simulador utilizando redes neurais

Em contraposição à simplicidade do modelo *ad-hoc*, foi estruturado um simulador utilizando aprendizagem de máquina na forma de uma rede neural. Além disso, foram utilizados indicadores técnicos como variáveis de entrada para seu treinamento.

Para preparo dos dados de entrada da rede neural foi utilizado a *IDE Jupyter Notebook*, foi implementado um processo de leitura dos dados históricos financeiros da CSN na Yahoo *Finance* por meio da biblioteca *Pandas*. Estes dados foram carregados em dois *DataFrames*, de acordo com o período de cada um, um de treinamento e teste abrangendo o ano de 2000 até o ano $n-1$ e o ano n a ser utilizado como simulação de investimentos. Por exemplo, para simulações de investimento no ano de 2013, foram utilizados os dados de 2000 a 2012 para treinamento da rede neural. Para simulações de investimento no ano de 2014, foram utilizados os anos de 2000 até 2013 para treinamento da rede neural, e assim sucessivamente até o ano de simulação de 2017. A título de ilustração, são apresentados alguns dados no quadro 1.

Date	Valor da ação diário					
	High	Low	Open	Close	Volume	Adj Close
2000-01-03	4.05417	3.83333	3.88750	4.05417	1461600	2.011579
2000-01-04	4.13750	3.88750	4.05417	4.11250	1504800	2,040521
2000-01-05	4.44583	4.05417	4.05417	4.33333	1116000	2.150091
2000-01-06	4.58333	4.38750	4.52917	4.52917	2210400	2.247262
2000-01-07	4.61250	4.50000	4.58333	4.50000	17690400	2.232788
...

Quadro 1 – Dados históricos de preços da CSNa

O quadro 1 mostra 5 linhas de dados, cada uma correspondendo aos dados da CSN. Com base nos dados brutos foram então calculados os valores referentes aos indicadores técnicos, descritos no quadro 2.

Fechamento no dia anterior;
Variação, a diferença entre o preço de fechamento e o de abertura para um dia;
Variação do dia anterior;
Volume do dia anterior;
EMA de 5 dias;

EMA de 10 dias;
EMA de 20 dias;
EMA de 12 dias;
EMA de 26 dias;
SMA de 5 dias;
SMA de 10 dias;
SMA de 20 dias;
MACD;
Decisão interpretada a partir do MACD. Se negativo, -1 (venda), se positivo 1 (compra);
RSI de 14 dias;
Decisão interpretada a partir do RSI de 14 dias. Se menor que 40, -1 (venda), se maior que 60, 1 (compra);
Decisão, se a variação for positiva, 1 (compra), se negativa, -1 (venda);
Decisão do dia anterior.

Quadro 2 – Dados históricos de preços e indicadores técnicos da CSN

A razão de utilizar os valores relativos ao dia anterior é para poder ser calculado se houve um incremento ou decremento do preço da ação com o passar do tempo e servir de base para que a simulação do oráculo saiba se a melhor decisão é a compra ou a venda do ativo. Enquanto nos outros simuladores a informação é desconsiderada para que os modelos de rede neural e *ad-hoc* possam ser testados em relação ao seu poder de previsibilidade.

Para a fase de treinamento foram separados os conjuntos de treinamento e testes, em que foram avaliadas diversas configurações de camadas e entradas, diferentes *seeds*, diferentes critérios para decisão nos indicadores com limiares, diferentes períodos de treinamento. Cada configuração testada teve matrizes de confusão e desempenho econômico. Os modelos testados variaram menos na matriz de decisão e mais no desempenho financeiro. Contrariando a intuição, configurações com mais entradas, incluindo mais indicadores técnicos, tiveram desempenho piores quando comparadas às configurações com menos indicadores técnicos para treinamento do modelo de rede neural.

Ter um critério simples e objetivo como o lucro alcançado pelo simulador em vez de um critério que combinasse critérios estatísticos e próprios da aprendizagem de máquina como a matriz de confusão, facilitou a decisão do modelo de rede neural que foi comparado ao simulador *ad-hoc*. Por fim, a configuração de camadas da rede que gerou o modelo que será comparado com a técnica *ad-hoc* tinha uma camada de entrada com seis neurônios, uma camada oculta com treze neurônios e uma camada de saída com um neurônio. As entradas utilizadas foram: o valor de abertura, o valor de fechamento no dia anterior, a variação no dia anterior, decisão vinda da variação no dia anterior, decisão vinda do RSI de 14 dias e a decisão vinda do MACD.

5.3 Comparação

Nos experimentos foi utilizado também um modelo oráculo, um simulador em que os valores de preços do dia seguinte serviram como base para se tomar a melhor decisão de compra e venda de ações na simulação. Este oráculo serviu como *benchmark* comparativo do desempenho financeiro dos outros simuladores comparados: o modelo proposto (utilizando rede neural e indicadores técnicos) e o modelo *ad-hoc*.

Ao serem realizados os experimentos nos diversos simuladores, foi possível obter o desempenho em reais e em porcentagem, conforme o quadro 3. Vale ressaltar que nesta primeira bateria de experimentos, o valor inicial voltava a R\$100.000,00 a cada ano.

Ano	<i>ad-hoc</i>		rede neural		oráculo	
	R\$	%	R\$	%	R\$	%
2013	113.597,78	13,60	932.173,93	41,35	141.346,68	832,17
2014	52.797,34	-47,20	744.980,30	-9,82	90.175,74	644,98
2015	71.134,59	-28,87	5.022.391,13	8,47	108.471,84	4922,39
2016	163.889,72	63,89	6.043.160,03	47,23	147.231,21	5943,16
2017	113.224,34	13,22	1.607.994,10	3,21	103.206,79	1507,99

Quadro 3 – Desempenho financeiro (R\$) e em percentual (%) dos simuladores

No quadro 3 pode-se visualizar que os valores financeiros do modelo oráculo representam qual seria o montante final caso fosse possível prever o futuro, servindo de limite superior para a comparação com os outros modelos, sendo o menor ganho de 644,98%. Cabe apontar que tanto o modelo *ad-hoc* quanto o modelo com rede neural apresentaram resultado financeiro negativo em alguns anos. Isto é, perderam dinheiro, e como era de se esperar, quando obtiveram ganhos, estes foram menores do que o do simulador oráculo. Contudo, de modo geral o de rede neural foi mais consistente que o modelo *ad-hoc*.

Foi realizada também uma segunda simulação junto aos modelos. Nesta simulação o valor resultante do ganho com o investimento inicial (100.000,00) é reinvestido no período seguinte, ano após ano, de 2013 até 2017, correspondendo a um investidor que faz transações durante 5 anos seguidos (quadro 4).

Ano	<i>ad-hoc</i>	rede neural	oráculo
2013	113,60%	141,35%	932,17%
2014	59,98%	127,46%	6.944,51%
2015	42,66%	138,26%	348.780,56%
2016	69,92%	203,56%	21.077.367,50%
2017	79,17%	210,09%	338.922.825,84%

Quadro 4 – Desempenho dos simuladores em porcentagem acumulada

Nesta simulação os repetidos ganhos são potencializados ao longo do tempo e o simulador que apresentar maior consistência se sobressai. Deste modo, de acordo com os dados apresentados no quadro 4, e desconsiderando os valores do oráculo, por ele se tratar de um valor de *benchmarking*, pode-se verificar que o modelo de rede neural apresenta melhor desempenho do que o modelo *ad-hoc*.

6. CONSIDERAÇÕES FINAIS

Os investidores compram as ações visando retorno financeiro no futuro, seja pelo pagamento de dividendos, pelos lucros alcançados ou vendendo estas ações após a valorização da empresa em que investiu. Para alcançar o melhor resultado possível, o investidor deve procurar definir

uma melhor estratégia de acordo com o seu perfil de investimento, a partir do que conhece e espera do mercado, tentando prever qual empresa irá valorizar mais.

Dentro do contexto apresentado, o presente trabalho teve como objetivo avaliar dois modelos diferentes em simulações de investimento, uma técnica *ad-hoc* e uma rede neural usando indicadores técnicos. A rede neural utilizada foi um *perceptron* multicamadas, testada com vários parâmetros diferentes. Um modelo adicional foi utilizado como parâmetro de limite superior como *benchmark*, o modelo oráculo, o qual sempre sabia se a ação iria valorizar ou desvalorizar, tomando melhores decisões dia a dia.

Foram realizados 2 conjuntos de experimentos principais, um considerando experimentos independentes ano após ano e o outro considerando investimentos sequenciais durante 5 anos. Ao se avaliar os experimentos verificou-se que o modelo de rede neural artificial obteve um desempenho relativo maior que a técnica *ad-hoc*, contudo bastante distante do desempenho de um oráculo. No investimento sequencial, durante 5 anos, o modelo de rede neural foi 265% mais eficiente que a técnica *ad-hoc*.

É importante ressaltar que, prever o comportamento do mercado financeiro, mesmo numa situação controlada ainda está longe de ser algo simples, mas ainda assim pode-se demonstrar que modelos de redes neurais com base em indicadores técnicos podem ser uma alternativa viável para auxiliar um possível investidor. Mais especificamente, foi observado que mais informações não resultavam necessariamente em melhores previsões, no melhor simulador avaliado neste trabalho, foram utilizados menos de um terço dos indicadores levantados.

Os melhores indicadores foram os que já simplificavam e agregavam outros indicadores, e que comumente são citados e interpretados em vários estudos científicos sobre previsão de preço, sob a ótica e experiência de pesquisadores da área de economia.

Desta forma, os resultados obtidos aqui indicam que simuladores com redes neurais e indicadores técnicos podem ser um sistema eficiente de suporte à decisão para investidores. Contudo, o estudo delimita-se em experimentos com uma única ação, do mercado nacional, apresentado como possibilidades de trabalhos futuros: a realização de experimentos em outras ações e períodos históricos, bem como em mercados internacionais; a realização de experimentos com outras configurações de redes neurais; e a implementação de simuladores com modelos personalizados para a compra ou para a venda que possam ter desempenho mais adequado para cada situação.

REFERÊNCIAS

- Ai, Y., Ling, Z. H. W. Wu, L. & Li, A. (2022). Denoising-and-Dereverberation Hierarchical Neural Vocoder for Statistical Parametric Speech Synthesis. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*.
- GIRIOLI, L. S., RIBEIRO, E. M. S. (2009). Utilização de Redes Neurais Artificiais para Análise Técnica no Mercado de Ações: Estudo dos Índices IBOVESPA e Dow Jones Industrial Avarage (DJIA). *Revista EPeQ/FAFIBE*, v. 1, n. 1, p. 150-155.

- Goyal, V. & Raj, R. R. (2022). Using LSTM, DNN, and ARIMA approaches to predict the trends in the Stock Market. *8th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2022, pp. 918-922, doi: 10.1109/ICACCS54159.2022.9785150.
- Haykin, S. S. (2009). *Neural networks and learning machines*. India: Pearson Education.
- Historical Quotes. B3. (2020). Disponível em <http://www.b3.com.br/en_us/market-dataand-indices/data-services/market-data/historical-data/equities/historical-quotes/>; Acessado em 14 de Julho de 2020.
- Lemos, F. (2015). *Análise técnica dos mercados financeiros: um guia completo e definitivo dos métodos de negociação de ativos*. São Paulo : Saraiva Educação.
- Marangoni, P. H. (2010). *Redes Neurais Artificiais para Previsão de Séries Temporais no Mercado Acionário*, 2010. 80 f. Monografia (Especialização) - Curso de Ciências Econômicas, Universidade Federal de Santa Catarina – Ufsc, Florianópolis.
- Martins, M. A. S., Mette, F. & Macedo, G. R. de. (2008). A Utilização de Redes Neurais Artificiais para a Estimção dos Preços da Petrobrás PN na Bovespa. *ConTexto – Contabilidade em Texto*, v. 8, n. 14.
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill.
- Müller, D., Soto-Rey, I. & Kramer, F. (2022). An Analysis on Ensemble Learning optimized Medical Image Classification with Deep Convolutional Neural Networks. *IEEE Access*, 2022, doi: 10.1109/ACCESS.2022.3182399.
- Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. EUA: New York Institute of Finance.
- Oriani, F. B., Coelho, G. P. (2016). Evaluating the impact of technical indicators on stock forecasting. *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE, p. 1-8.
- Russel, S. & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach*. Pearson Education Limited, Fourth Edition.
- Sachetim, H. M. (2006). *Análise técnica: estudo da confiabilidade dos principais indicadores de análise técnica, aplicados as ações mais negociadas na Bovespa no período de 1995 a 2005*. Dissertação de mestrado, UFPR, Curitiba.