

Econometria e inteligência artificial: criação de portfólio de ações rentáveis**Econometrics and artificial intelligence: creating profitable stock portfolio**

Recebimento dos originais: 26/02/2019

Aceitação para publicação: 28/03/2019

Wagner Igarashi

Doutor em Engenharia e Gestão do Conhecimento pela Universidade Federal de Santa Catarina

Instituição: DIN- Universidade Estadual de Maringá
Endereço: Av. Colombo, 5790 - Zona 07, Maringá - PR, Brasil
E-mail: wigarashi@uem.br

Lucas Fernando Martioli

Bacharel em Informática pela Universidade Estadual de Maringá
Instituição: DIN - Universidade Estadual de Maringá
E-mail: martiolilucas@gmail.com

Deisy Cristina Corrêa Igarashi

Doutora em Engenharia de Produção pela Universidade Federal de Santa Catarina
Instituição: PPA - Universidade Estadual de Maringá
Endereço: Av. Colombo, 5790 - Zona 07, Maringá - PR, Brasil
E-mail: dccigarashi@uem.br

RESUMO

Investidores constantemente se submetem a riscos na bolsa de valores, devido à volatilidade de preço das ações; e buscam apoio em técnicas e ferramentas que minimizem o risco e possam maximizar o lucro. Neste contexto, o objetivo do estudo é a otimização de uma carteira de ações. Para o processo de predição do comportamento do preço de ações foram utilizadas redes neurais artificiais treinadas a partir de indicadores técnicos. Para criação de portfólios foi utilizado um algoritmo genético, utilizando a teoria de Markovitz como função objetivo de modo a maximizar o lucro e minimizar o risco. Foram realizadas 21 simulações, em um conjunto de 57 empresas das 100 maiores empresas, de capital aberto, por valor de mercado, de acordo com a edição especial da revista Exame - Melhores e Maiores (2016). Os dados para as simulações se referem ao período de julho de 2014 e outubro de 2016. Os resultados foram positivos e demonstram que na pior hipótese o modelo tem um rendimento praticamente idêntico ao da poupança.

Palavras chave: Análise Técnica, Redes Neurais, Algoritmo Genético, Markovitz, Portfólio.

ABSTRACT

Investors are constantly exposed to stock market risks due to stock price volatility; and seek support in techniques and tools that minimize risk and maximize profit. In this context, the objective of the study is the optimization of a stock portfolio. For the prediction process of stock price behavior, artificial neural networks trained on technical indicators were used. To

create portfolios, a genetic algorithm was used, using Markovitz's theory as an objective function in order to maximize profit and minimize risk. Twenty-one simulations were carried out in a set of 57 companies of the 100 largest publicly traded companies, by market value, according to the special edition of the magazine Exame - Melhores e Maiores (2016). The data for the simulations refer to the period from July 2014 to October 2016. The results were positive and show that in the worst case, the model has an income almost identical to that of saving.

Key-words: Technical Analysis, Neural Networks, Genetic Algorithm, Markovitz, Portfolio.

1 INTRODUÇÃO

O rápido crescimento e revolução na performance computacional, tem permitido a geração de terabytes de dados e fomentado a aplicação de diversas técnicas computacionais na análise de séries temporais e predição do preço de ações (WU, DIAO, 2015). Tal fato tem tornado cada vez mais popular o uso de análise quantitativa na transação de compra ou venda de ações. Entretanto, prever o comportamento de preço das ações com precisão é uma tarefa desafiadora. Técnicas computacionais tem-se se mostrado eficientes na predição de preço de ações, como Rede Neural Artificial (RNA), Sistema de Inferência adaptativo Neuro-Difuso (SIAND), Mineração de dados (MD), etc. (BILLAH, WAHEED, HANIFA, 2016; LERTYINGYOD, BENJAMAS, 2016; CHEN, CHEN, 2015).

Redes neurais artificiais (RNAs), juntamente com modelos de séries temporais têm sido amplamente aplicadas na previsão de curto prazo (LERTYINGYOD, BENJAMAS; 2016; SETHI, TRELEAVEN, 2015; PAN et al., 2016; WORASUCHEEP, 2016; LEUNG, CHEN, DAOUK, 2000) e têm se mostrado uma ferramenta promissora para a previsão de séries temporais financeiras no direcionamento de investimentos.

Mesmo após ter sido demonstrado por estudos, como os de Markowitz (1952) e Sharpe (1964) e Sharpe, Alexander e (1995), a importância da diversificação nos investimentos, é comum na literatura a apresentação de métodos de detecção de oportunidade de *trading* (transação) utilizando redes neurais para sinalização de compra ou venda de ações individuais (SETHI, TRELEAVEN, 2015; BILLAH, WAHEED, HANIFA, 2016; LERTYINGYOD, BENJAMAS, 2016; WORASUCHEEP, 2016).

Neste contexto, surge a questão de pesquisa: como usar modelos de predição do comportamento do preço de ações e com base nestes modelos criar um portfólio rentável? Com base na pergunta de pesquisa foi estabelecido o objetivo de otimização de um portfólio de ações, a fim de maximizar o lucro e minimizar os riscos, com base em análise técnica, análise de risco, redes neurais e algoritmo genético para ponderação da carteira. Ressalta-se

que o presente trabalho se justifica, pois a formação de carteiras ponderadas a partir de sinalizações de indicadores técnicos, tem recebido pouca atenção na literatura (SETHI, TRELEAVEN, 2015).

2 ANÁLISE TÉCNICA VERSUS FUNDAMENTALISTA

A análise técnica e a fundamentalista são duas das principais ferramentas na área de análise de investimentos em ações, para a predição de sinais de compra e venda de ações (WU, DIAO, 2015). De acordo com Murphy (1999) tais técnicas se distinguem da seguinte forma: a análise técnica está focada no estudo do mercado de ações; a análise fundamentalista está focada nas forças econômicas de oferta e demanda que elevam, baixam ou não alteram a situação dos preços. Ademais Murphy (1999) destaca três premissas bem definidas: o preço das ações representa o impacto de todas as variáveis de mercado; preços se movem em tendências; e a história se repete. Ou seja, a partir de preços já praticados, pode-se tentar realizar a predição de preços e/ou movimentos de tendências.

A Análise Técnica trata-se de uma abordagem racional do mercado financeiro, e sua definição segundo Murphy (1999), Edwards, Magee e BASSETTI (2001), é a ciência de registrar, comumente em gráficos, o histórico atual das transações (trading) relativas a compra e venda de ações (mudanças de preço, volume de transações, etc.) ou em “médias” e em seguida tentar prever uma provável tendência futura. A análise técnica é composta de ferramentas comumente chamadas de indicadores técnicos como Média Móvel (MM ou *Simple Moving Average* - SMA), Índice de Força Relativa (*Relative Strength Index* - RSI), e Convergência e Divergência de Médias Móveis (*Moving Average Convergence Divergence* - MACD), entre outras, que oferecem uma perspectiva diferente sobre a direção e a força de movimento de preços e de modo geral têm a função de: alertar; confirmar e prever. A MM é um seguidor de tendência, sinalizando uma nova tendência começou, uma antiga terminou ou foi revertida, considerando um determinado período n :

$$MM(n) = \frac{\sum_{i=1}^n P_i}{n}, \quad (1)$$

em que P_i é o preço do ativo no momento i .

Quanto maior o período considerado, mais lenta fica a MM. Pode-se utilizar três MMs, para que uma dê suporte a outra. Entretanto, as MMs se adaptam melhor a uma indicação de

tendência forte e podem ser lentas; como alternativa usa-se a Média Móvel Exponencial (MME) (MURPHY, 1999; EDWARDS, MAGEE, BASSETTI, 2001):

$$MME(n) = MME(n - 1) + \left(\frac{2}{n + 1}\right) * (P(n) - MME(n - 1)) \quad (2)$$

em que n é a quantidade de períodos, $P(n)$ é o preço no período n e $n - 1$ representa o período anterior.

O MACD (*Moving Average Convergence/Divergence*) trata-se do uso de três MME de maneira composta, a fim de que suas sobreposições mostrem o sinal de venda ou compra. Um padrão indicado para uso do MACD é o 9-12-26 dias.

$$Linha\ MACD = (MME(12) - MME(26)) \quad (3)$$

$$Linha\ Sinal = MME(9) \quad (4)$$

$$Histograma\ MACD = Linha\ MACD - Linha\ de\ Sinal \quad (5)$$

A análise de sinais é feita da seguinte forma: a) compra, quando a linha mais rápida corta a linha mais lenta vindo de baixo; b) venda, quando o exato oposto ocorre. Além disso, foi especificado que: abaixo de -1.20 é um forte sinal de compra e acima de +1.20 é um forte sinal de venda; e uma escala de ± 2.50 , a fim de definir as áreas de elevada variação em relação ao preço mercado. (EDWARDS, MAGEE, BASSETTI; 2001).

O indicador RSI (*Relative Strength Index*) é outro indicador que sinaliza momentos de compra ou venda de ações. A escala do RSI varia entre 0 e 100, e identifica a máxima da tendência de alta com seu valor acima de 70 e a máxima da tendência de queda abaixo de 30. (EDWARDS, MAGEE, BASSETTI, 2001). A fórmula do RSI é definida como:

$$RSI(n) = 100 - \frac{100}{1 + RS(n)} \quad (6)$$

$$RS(n) = \frac{MME(n)\ dos\ fechamentos\ em\ tendencia\ de\ ALTA}{MME(n)\ dos\ fechamentos\ em\ tendencia\ de\ BAIXA} \quad (7)$$

n representa a quantidade de dias utilizada para a análise.

3 PORTFÓLIO DE AÇÕES E TEORIA DE RISCO

A Teoria de Markowitz (1952) tem como foco a seleção de portfólios que maximizem os retornos esperados, dado um nível de risco. Para a construção de um portfólio eficiente, admite-se que o investidor seja avesso ao risco, ou seja, tendo-se dois investimentos com o mesmo retorno esperado e com riscos diferentes, o investidor irá optar pelo de menor risco. (MARKOWITZ, 1952; DAMODARAN, 2012). Assim, para o retorno de uma ação têm-se

$$retorno_{ação} = \frac{P_{esperado} - P_i}{P_i} \cdot 100 \quad (8)$$

onde P_i é o preço inicial da ação no período a ser calculado e $P_{esperado}$ é o preço final esperado. Para o retorno de um portfólio têm-se:

$$retorno_{portfólio} = \sum_{i=1}^N w_i r_i \quad (9)$$

onde N representa a quantidade de ações no portfólio, w_i o peso da ação no portfólio desde que $\sum_{i=1}^N w_i = 1$ e r_i é o retorno esperado de cada ação i .

Braga (2008) exemplifica utilizando duas ações (A e B), calculando o retorno:

$$retorno_{portfólio} = w_A r_A + w_B r_B \quad (10)$$

e após, a variância do retorno esperado do portfólio:

$$\sigma_{portfólio}^2 = \underbrace{w_A^2 \sigma_A^2 + w_B^2 \sigma_B^2}_{\text{Riscos isolados}} + \underbrace{2 w_A w_B Cov(AB)}_{\text{Risco combinado}} \quad (11)$$

onde os dois primeiros termos representam os riscos isolados, e o terceiro termo o risco dos ativos combinados dois a dois.

4 REDES NEURAIAS ARTIFICIAIS

McCulloch e Pitts (1943) descrevem o modelo artificial de neurônio (MCP) o qual permite a classificação de dados em problemas que sejam linearmente separáveis. (BRAGA, CARVALHO, LUDERMIR, 2000). O MCP trata-se de um modelo de n variáveis de entrada (x_1, x_2, \dots, x_n) e uma variável de saída (y), a qual é determinada pela (12), em que n é o número de entradas, w_i é o peso associado respectivamente à cada entrada x_i e θ é o limiar de ativação do neurônio. Caso a soma ponderada das entradas e pesos seja superior ao limiar

de ativação θ a função retornar o valor 1, caso contrário 0. (BRAGA, CARVALHO, LUDERMIR, 2000).

$$y = f(in) \quad \begin{cases} 1, \text{ se } i \geq \theta \\ 0, \text{ se } i < \theta \end{cases} \quad in = \sum_{i=1}^n x_i w_i \quad (12)$$

Em 1958, Frank Rosenblatt apresentou o conceito de aprendizagem e a topologia de redes neurais *perceptron*, composta pelas variáveis de entrada, uma camada de neurônios MCP, e uma variável de saída. O peso de cada entrada é definido antes da aprendizagem da rede. A aprendizagem é realizada atualizando o peso das ligações dos neurônios com os nós de saída a partir da equação:

$$w(t + 1) = w(t) + \eta \cdot e \cdot x(t) \quad (13)$$

Rumelhart, Hinton e Williams (1985) apresentaram o Perceptron multicamadas (*Multi Layer Perceptron* - MLP) e o método de aprendizagem *backpropagation*. As redes MLP possuem a capacidade de lidar com problemas não linearmente separáveis, sendo bastante utilizadas em diversos tipos de problemas de classificação e previsão. O *backpropagation* é um algoritmo de aprendizado supervisionado que utiliza pares de entrada e saída esperada, para ajustar os pesos da rede. O treinamento ocorre em duas fases: a fase *forward* - fornece a saída com base nos valores de entrada e pesos da rede; e a fase *backward* - compara a saída fornecida pela rede e a saída esperada para atualizar os pesos de suas conexões. (BRAGA; CARVALHO e LUDERMIR, 2000).

5 EXPERIMENTO

O experimento foi realizado a partir de um protótipo construído utilizando linguagem Java e as bibliotecas: Framework Neuroph de Redes Neurais Artificiais (versão 2.92), sob licença de uso livre Apache 2.0; Biblioteca Yahoo Finance (versão 3.5.0) - que permite o acesso a uma base de dados de vários mercados financeiros, com informações históricas de transações em bolsa de valores; e a Biblioteca Ta4j (versão 0.9) de código aberto para a realização de análise técnica.

Os dados de transações de ações foram coletados compreendendo o período de 01/07/2014 à 01/10/2016, com base na seleção de 57 das 100 maiores empresas, de capital aberto, por valor de mercado, de acordo com a edição especial da revista Exame - Melhores

e Maiores (2016). Os dados foram normalizados para valores entre 0 e 1. Com os dados normalizados, foram utilizados os indicadores técnicos RSI, SMA e MACD e os dados das ações (preço de abertura, preço de fechamento, menor preço, maior preço, *Bearish*) para treinar uma rede neural MLP com aprendizagem *backpropagation*.

No total foram criadas 3 sub-redes MLP de 3 camadas, uma para cada indicador técnico utilizado. Cada uma dessas sub-redes alimenta então uma rede agregadora que indica se o preço da ação possui uma tendência de alta, baixa ou lateralidade. Na sub-rede do indicador MACD, a análise é de curto prazo, com base nos valores de 5 e 35 dias para a linha MACD e de 5 dias para linha de sinal. Na sub-rede SMA, foi utilizado o padrão 4-9-18. Na sub-rede do indicador de RSI utiliza-se o padrão de 14 dias, a partir do dia corrente, e de dois dias anteriores. Uma quarta rede MLP agregadora recebeu todos os dados: 1 - indicação da rede RSI; 2 - indicação da rede SMA; 3 - indicação da rede MACD; 4 - preço de abertura; 5 - preço de fechamento; 6 - menor preço; 7 - maior preço; 8 - *bearish* (preço de fechamento menor que o preço de abertura).

Nos experimentos, dois anos que correspondem a 88% dos dados foram utilizados para o treinamento das redes MLP, com os 12% restantes realizou-se testes. O período de testes foi subdividido em dois momentos, sendo que 6% do período (01/07/2016 a 12/08/2016) corresponde ao uso das redes, já treinadas, para predição dos valores semanais das ações e 6% do período (15/08/2016 a 01/10/2016) para o cálculo da precisão da rede de cada ação, comparando valores previstos com os valores reais. Os valores de predição e as taxas de acerto serviram de insumo para a etapa da montagem de portfólio.

Para a montagem de portfólios optou-se pelo uso do algoritmo genético, por ser uma solução reconhecida na área de otimização (MITCHELL, 1998). Para o algoritmo genético foram utilizados os seguintes parâmetros: a) - Disponibilizada uma lista de ativos (ações) com os valores de previsão já calculados e também a precisão da rede de cada um; b) - Cada portfólio gerado pelo algoritmo pode ter no máximo 10 ativos em sua composição e cada ativo pode ter uma representatividade dentro do portfólio também de 10 papéis; c) - Sua população tem cinco portfólios e a cada iteração, utilizando membros de sua população, são gerados 20 filhos, com um limite de 1000 iterações; d) A função fitness (ou função objetivo) é a função que direciona a busca do AG, é a função que dita a distância entre um candidato a solução e outro, dentro do espaço de busca, sendo definida pela equação:

$$\text{FunçãoObjetivo} = \text{RetornoEstimadoPortfólio} + \text{PrecisãoPortfólio} - \text{VariânciaPortfólio} \quad (14)$$

Na equação são somados três valores que definem a direção da montagem dos portfólios: a) 'RetornoEstimadoPortfólio' para maximizar o retorno estimado do portfólio; b) 'PrecisãoPortfólio' para priorizar ações que tenham redes com maior precisão para a composição do portfólio; c) subtração da 'VariânciaPortfólio' para minimizar a variância do portfólio, ou seja, minimizar o risco do portfólio. O cálculo desses valores por ativo é apresentado na equação 15.

$$\text{RetornoEstimadoAtivo} = \frac{\text{ValorEstimado} - \text{ValorRealAnterior}}{\text{ValorRealAnterior}} \quad (15)$$

A equação 16 apresenta o cálculo da precisão da rede para um ativo, em que 'AcertoTendência' representa a quantidade de vezes em que a previsão acompanhou a tendência do valor real praticado e 'TotalAvaliado' é a quantidade de vezes que esse teste foi executado.

$$\text{PrecisãoRede} = \frac{\text{AcertoTendência}}{\text{TotalAvaliado}} \quad (16)$$

Na equação 17, P_i representa o preço do ativo no momento i , n representa o tamanho do período sendo utilizado para o cálculo da variância e \bar{P} é o valor da média aritmética de P_i no período n .

$$\bar{P} = \frac{\sum_{i=1}^n P_i}{n} \quad (17)$$

$$\text{VariânciaAtivo} = \frac{\sum_{i=1}^n (P_i - \bar{P})^2}{n - 1} \quad (18)$$

Por fim, para a aplicação da equação 14, são utilizados os valores isolados de cada ativo derivados a partir das fórmulas 15, 16, 17 e 18 para, então, calcular os valores ponderados pela participação de cada ativo no portfólio a partir das equações 19, 20 e 21:

$$\begin{aligned} \text{RetornoEstimadoPortfólio} \\ = \sum_{i=1}^n \text{RetornoEstimadoAtivo}_i * \text{ParticipaçãoPortfólio}_i \end{aligned} \quad (19)$$


$$\text{VariânciaPortfólio} = \frac{\sum_{i=1}^n \text{VariânciaAtivo}_i * \text{ParticipaçãoPortfólio}_i}{n} \quad (20)$$

$$\text{PrecisãoPortfólio} = \frac{\sum_{i=1}^n \text{PrecisãoRede}_i * \text{ParticipaçãoPortfólio}_i}{n} \quad (21)$$

Utilizando-se de tais parâmetros, o algoritmo gera sua população inicial, compondo os portfólios de maneira aleatória, tanto para quais ativos utilizar quanto para a representatividade de cada um no portfólio. Já durante as iterações, para a composição de cada geração, é selecionado o melhor membro da população de acordo com a função objetivo do algoritmo (equação 14) em conjunto com um outro membro aleatório da população. Assim, conforme as gerações vão sendo acopladas à população, tem-se indivíduos cada vez melhores. Por fim, quando atingido o limite de iterações, é retornado o melhor indivíduo da população, de acordo com a função objetivo.

6 RESULTADOS

Cada rede neural foi treinada para prever o comportamento do preço de uma única ação cinco dias à frente (uma semana), entretanto, seu comportamento nos resultados não foi preciso quanto à previsão do valor de uma ação, mas obteve resultados significativos com relação as tendências, pois o treinamento foi direcionado por indicadores técnicos de tendência de variação de preço. O comportamento da rede, aliado à estimativa de precisão, trouxe uma combinação que permitiu a montagem de portfólios rentáveis. Para exemplificar, a Figura 2 apresenta a previsão de preços da ação da empresa TOTS3.




Fonte: dados primários

Figura 1: Simulação de previsão de tendência TOTS3 e SMLE3 - 5 trades

No resultado da simulação para a ação TOTS3 (Figura 2), como o valor calculado se comporta variando em três situações: a) tendência de baixa; b) tendência lateral; c) tendência de alta. Nessa simulação, a rede teve uma precisão de 75% com relação a tendência. Outra simulação apresentada é da ação para a empresa SMLE3, Figura 2. No resultado da simulação da SMLE3, Figura 2, pode-se observar uma melhor convergência com relação aos valores reais e a manutenção da convergência dos valores de tendência, se comparada com

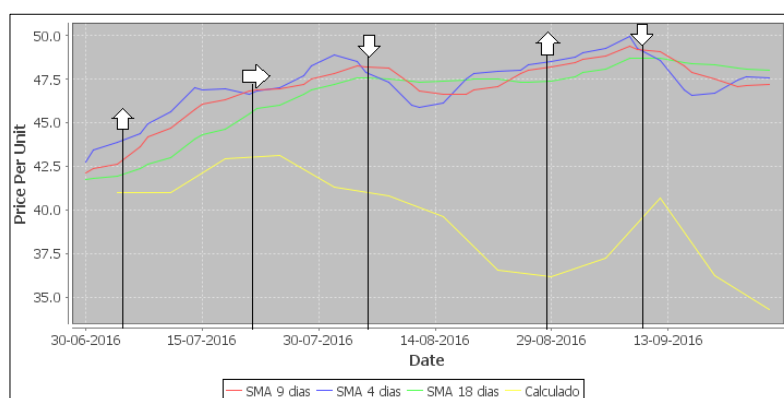
resultados da TOTS3. No caso da SMLE3 a precisão da rede foi de 84%. Em ambas as simulações (TOTS3 e SMLE3) as tendências foram comparadas em curto prazo, ou seja, uma precisão de reação para a tendência do preço futuro de cinco trades (uma semana). Um comparativo com relação a precisão de todas as redes é apresentado na Figura 3.



Fonte: dados primários

Figura 3: Precisão das redes - 5 trades

Na Figura 3 as simulações de TOTS3 e SMLE3 entregam uma precisão de tendência da rede acima da média (54.79%), ou seja, essas redes têm uma convergência melhor a curto prazo, apresentando uma menor lentidão para responder aos “estímulos” de tendência. Essa característica podem estar associadas ao período de treinamento (exposição das redes a situações) ou ao comportamento dos preços em relação aos indicadores técnicos utilizados. Para contrastar com os exemplos apresentados, a Figura 4 apresenta o resultado da simulação que utilizou-se de uma rede com precisão abaixo da média.



Fonte: dados primários

Figura 4: Simulação da rede VIVT4 em relação SMA - 5 trades

Para os casos de simulação em que a rede entrega uma taxa menor que a média, como é o caso da ação VIVT4 com precisão de 38%, o qual não é um resultado ruim. Como pode ser

visto na Figura 4, a curva do valor calculado segue as tendências apresentadas pelas curvas de indicador SMA no padrão 4-9-18, apresentado anteriormente, em que a seta para cima indica tendência de alta, a seta para a direita indica tendência lateral e a seta para baixo indica tendência de baixa.

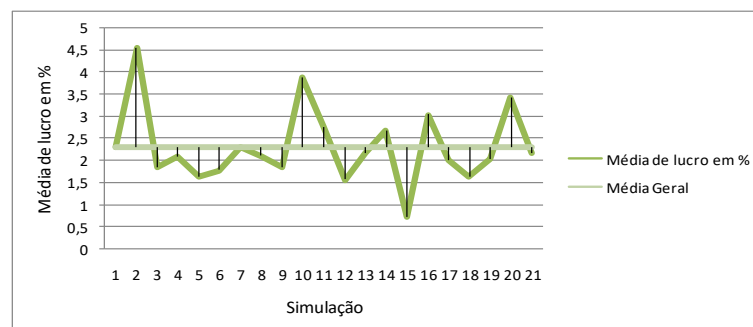
Dado que o algoritmo de montagem de portfólios tem a componente aleatória associada à forma como a abordagem genética procede na busca de soluções, se fez necessário um conjunto estatístico quanto aos resultados do algoritmo. Para suprir essa necessidade foram realizadas 21 simulações. Em cada simulação foram gerados 4 portfólios, em um período de um mês, ou seja, com datas de compra e venda a cada sete dias (cinco trades). As datas de compra/venda dos portfólios apresentados em cada conjunto de portfólios nas simulações estão apresentadas no Quadro 2:

Compra	Venda
1/7/2016	8/7/2016
8/7/2016	15/07/2016
15/07/2016	22/07/2016
22/07/2016	29/07/2016

Fonte: dados primários

Quadro 2: Datas de compra e venda de portfólio

A partir da análise das 21 simulações foi calculado o percentual de lucro caso a compra e a venda desses portfólios ocorressem nas datas especificadas no quadro 2. Uma representação da média de lucro nas simulações é apresentada na Figura 5.




Fonte: dados primários

Figura 5: Média de lucro dos portfólios simulados

Conforme Figura 5 média geral de lucro bruto dos portfólios, gerados nas simulações, é de 2,29% no período, em que apresentou a menor média de 0,71% (Simulação 15) e a maior

de 4,55% (Simulação 2). Ainda o pior caso pode ser comparado diretamente com a taxa de rendimento da poupança, para o mesmo período (0,7053%). Na Figura 6 e Quadro 3 são apresentados os dados do melhor caso, Simulação 2.



Fonte: dados primários

Figura 6: Percentual de lucro do caso 2

A Figura 6 apresenta o percentual de lucro da venda de cada portfólio da Simulação 2, em suas respectivas datas de venda. No Quadro 3, podem ser avaliadas quais as ações foram efetivamente transacionadas, suas quantidades, preços de compra e venda.

Portfólio 1

Ação	Qtd	Preço de Compra	Preço de Venda
CPFE3	6	20.56	22.46
BBDC4	1	25.62	26.51
PETR3	6	12.06	12.3
LAME4	9	16.76	17.5
CTIP3	1	43.42	43.7
CGAS5	1	47.01	48.83

Portfólio 2

Ação	Qtd	Preço de Compra	Preço de Venda
BBSE3	3	27.75	29.22
ODPV3	2	13.42	13.51
NATU3	2	26.94	28.27
TIMP3	3	7.14	7.72
GGBR4	1	6.16	6.94

Portfólio 3

Ação	Qtd	Preço de Compra	Preço de Venda
DTEX3	7	9.06	9.6
MRVE3	3	12.24	13.1
GGBR4	6	6.94	7.29
BRFS3	1	50.41	51.65


Portfólio 4

Ação	Qtd	Preço de Compra	Preço de Venda
QUAL3	1	21.42	21.5
GRND3	6	16.6	17.19

Fonte: dados primários

Quadro 3: Portfólios do melhor caso (Simulação 2)

Para fins de comparação, foi elaborado, utilizando o mesmo algoritmo de montagem de portfólio, uma simulação em que a função objetivo tratava da busca por lucro real, ou seja, a montagem dos portfólios com conhecimento do preço real praticado no período. O comportamento dessa simulação pode ser observado na Figura 7.



Fonte: dados primários

Figura 7: Percentual de lucro de uma simulação de retorno real

A média de lucro bruto mensal da simulação apresentada na Figura 7 foi de 11,20%, em que, se comparada diretamente com a média de lucro bruto mensal geral dos casos apresentados (2,29%), as simulações geradas pelo protótipo atingem 20,28% do potencial de maior lucro que poderia ser praticado no período analisado.

7 CONCLUSÃO

O mercado financeiro é um ambiente com elevado número de variáveis (algumas subjetivas), em que a análise de informações têm relevância para a tomada de decisão. Por se tratar de um mercado de risco, tende a trazer inseguranças no momento dos investimentos e a necessidade de ferramentas que deem suporte a esse processo. Neste contexto, a pesquisa focou o processo de criação de portfólio de investimentos em ações.

Do ponto de vista econômico, diversas tipos de indicadores de análise técnica podem ser utilizados na sinalização da compra ou venda de uma ação. Contudo, tais indicadores somente permitem a análise individual de ações, e para um processo decisório de investimento pode ser complementado pela teoria do portfólio de Markowitz.

Nos experimentos realizados, as redes neurais foram utilizadas para aprender o movimento dos preços de ações a partir de indicadores técnicos, estimando seu comportamento futuro; e o algoritmo genético permitiu a montagem de portfólios, no qual a função objetivo foi baseada em fundamentos da teoria do portfólio de Markowitz. No total 21 simulações foram realizadas em virtude da componente aleatória do algoritmo genético. Para as simulações e análises foram coletados os dados de 57 das 100 maiores empresas, de

capital aberto, por valor de mercado, de acordo com a edição especial da Revista Exame - Melhores e Maiores (2016) de capital aberto da bolsa BM&FBovespa.

De modo a responder a pergunta de pesquisa: Como usar modelos de predição do comportamento do preço de ações e com base nestes modelos criar um portfólio rentável? Foi criado um modelo utilizando indicadores técnicos e redes neurais, aliado à teoria de Markovitz para ponderação de portfólios utilizando algoritmo genético, o qual permitiu obter portfólios com uma rentabilidade média, superior a apresentada pela poupança no mesmo período, 2,29% contra 0,7053% da poupança. Tal resultado permitiu responder positivamente a pergunta de pesquisa:

Como possível aprofundamento da pesquisa, sugere-se: a integração de novos indicadores técnicos, com propriedades diferentes dos aqui utilizados; estudo sobre a utilização de outros algoritmos para a montagem de portfólio, como o *Simulated Annealing*; dinamização do treinamento das redes quanto ao período de análise, a fim de que tenham melhores resultados preditivos; implementação de mais de uma arquitetura de rede, para uso dinâmico da que melhor se adapta para cada ação; realizar estudo para viabilizar a adição de técnicas fundamentalistas de análise de mercado, a fim de que combinada com a análise técnica aprimore os resultados obtidos, como por exemplo, a adição da análise de sentimento com base em notícias e seu impacto no mercado, ou a utilização de indicadores macroeconômicos como entrada das redes neurais.

REFERÊNCIAS

BILLAH, M.; WAHEED S.; HANIFA, A. *Stock market prediction using an improved training algorithm of neural network*. In: 2nd International Conference on Electrical, Computer & Telecommunication Engineering (ICECTE), Rajshahi, 2016.

BRAGA, A. de P.; CARVALHO, ACPLF; LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. Ed. LTC, 2000.

DAMODARAN, A. *Investment valuation: Tools and techniques for determining the value of any asset*. John Wiley & Sons, 2012.

EDWARDS, R. D.; MAGEE, John; BASSETTI, W. H. C. *Technical Analysis of Stock Trends*. AMACOM Div American Mgmt Assn, 2001.

LERTYINGYOD W.; BENJAMAS N. *Stock price trend prediction using Artificial Neural Network techniques: Case study: Thailand stock exchange*. In: International Computer

Science and Engineering Conference (ICSEC), Chiang Mai, 2016, pp. 1-6, 2016.

LEUNG, M. T.; Chen, A-S.; DAOUK. H. Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, V. 27, I 11–12, September 2000, Pages 1093-1110.

MARKOWITZ, H. Portfolio selection. *The journal of finance*, v. 7, n. 1, p. 77-91, 1952.

MCCULLOCH, W. S.; PITTS, W. *A logical calculus of the ideas immanent in nervous activity*. The bulletin of mathematical biophysics, v. 5, n. 4, p. 115-133, 1943.

MITCHELL, M. *An introduction to genetic algorithms*. MIT press, 1998.

MURPHY, J. J. *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. New York Institute of Finance, 1999.

CHEN M.; CHEN, B., C. *A hybrid fuzzy time series model based on granular computing for stock price forecasting*. Information Sciences, v. 294, feb., p. 227-241, 2015.

PAN, J.; TAMG, Y.Y.; WANG. U.; ZHENG, X. LUO, H.; YUAN, H.; WANG, P.S.P. *A hybrid swarm optimization for neural network training with application in stock price forecasting*. In: IEEE International Conference on Systems, Man, and Cybernetics (SMC), Budapest, 2016, , 2016.

REVISTA EXAME. *Maiores e Melhores*. São Paulo, ed 2016.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. *Learning internal representations by error propagation*. California Univ San Diego La Jolla Inst For Cognitive Science, 1985.

SETHI, M.; TRELEAVEN, P. *A graphical model framework for stock portfolio construction with application to a Neural Network based trading strategy*. In: International Joint Conference on Neural Networks (IJCNN). IEEE, 2015. p. 1-8, 2015.

SHARPE, W. F. *Capital asset prices: A theory of market equilibrium under conditions of risk*. Journal of Finance, set., p. 425-443, 1964.

SHARPE, W. F.; ALEXANDER, G. J.; BAILEY, J. V. *Investments*. New Jersey: Prentice Hall. 5 ed. 1995.

WORASUCHEEP, C. A. *Stock price forecasting application using neural networks with multi-optimizer*, In: IEEE 9th International Workshop on Computational Intelligence and Applications (IWCIA), Hiroshima, 2016, pp. 63-68, 2016.

WU, M.; DIAO, X. Technical analysis of three stock oscillators testing MACD, RSI and KDJ rules in SH & SZ stock markets. In: 4th International Conference on Computer Science and Network Technology ICCSNT), Volume: 01, Pages: 320 - 323, 2015.