

SISTEMA DE TRADING NO MERCADO DE AÇÕES IMPLEMENTADO POR REDES NEURAS ARTIFICIAIS

Jarbas Aquiles Gambogi

Depto. Eng. de Telecomunicações e Controle/EPUSP
gambogi@usp.br

Oswaldo Luiz do Valle Costa

Depto. Eng. de Telecomunicações e Controle/EPUSP
oswaldo@lac.usp.br

Resumo – Este trabalho apresenta um sistema de trading implementado por redes neurais artificiais multicamadas com propagação para frente que toma decisões de compra e de venda do índice Standard & Poor's 500, na modalidade seguidor de tendência, no período de 5 anos, encerrado na última semana do primeiro semestre de 2012. O critério usual de escolha de redes neurais nas estimativas de preços de ativos financeiros é o do menor erro quadrático médio entre as estimativas e os valores observados, entre outras métricas similares. A adoção, neste trabalho, do critério do menor erro quadrático médio, ou métrica equivalente, nas amostras de teste, entre as redes neurais que apresentaram taxas de acertos nas previsões das oscilações semanais do índice Standard & Poor's 500 acima de 60% nessas amostras de teste, possibilitou ao sistema de trading superar a taxa anual de retorno das redes neurais selecionadas pelo critério usual e, por larga margem, a estratégia de compre-e-segure no período. As variáveis de entrada das redes neurais foram escolhidas entre as que capturam o efeito momento dos preços do mercado de ações no curto prazo.

Palavras-chave – Redes Neurais, Mercado de Ações, Sistema de Trading.

Abstract – This work presents a trend follower system that makes decisions to buy and sell short the Standard & Poor's 500 Index, by using of multilayer feedforward neural networks in the period of 5 years ending at the last week of the first half of 2012. Usually the choice criterion of neural networks to forecast prices of financial assets is the least mean square error between the estimated and observed prices in the test samples, among other similar metrics. The adoption in this work of the criterion of the least mean square error in the test sample among those neural networks that had hit rates in the test sample above 60% of the Standard & Poor's 500 Index weekly change proved to be appropriate. The annual rate of return of the trading system surpassed those selected by the usual criteria and beat by wide margin the strategy of buy-and-hold. The input variables of neural networks were chosen among those technical indicators that capture the short-horizon momentum of prices.

Keywords – Artificial Neural Network, Stock Market, Trading System.

1. INTRODUÇÃO

Sistemas de *trading* têm constantemente atraído a atenção da comunidade financeira, pois eles podem proporcionar elevados retornos sem que seja necessário absorver e interpretar uma colossal massa de informações micro e macroeconômicas. O presente trabalho tem o objetivo de apresentar um sistema de *trading* seguidor de tendência (*trend follower*) para o principal índice do mercado de ações norte-americano, Standard & Poor's 500, mediante o emprego de redes neurais artificiais, cujas estimativas dos preços desse índice (saídas das redes neurais) com uma semana de antecedência serviram como variáveis para o estabelecimento de regras nas implementações das operações na frequência semanal.

Martinez et al. (2009) afirmaram que avaliar a contribuição de uma rede neural para um investidor pela acurácia na predição de preços de ativos financeiros não é o caminho adequado, sendo que o mais recomendado seria através de um sistema de *trading*. Um sistema consistente nem sempre é o que apresenta uma elevada taxa de retorno em determinado período em que é avaliado, embora rentabilidade seja um requisito necessário. As principais métricas empregadas na área financeira para avaliar um sistema de *trading*, que foram usadas neste trabalho, é o viés de alta da curva do capital empregado (*equity line*) durante o período de avaliação do sistema, a taxa de acerto nas operações, o *payout* (valor absoluto entre os lucros e prejuízos), a perda máxima infringida pelo sistema (*maximum drawdown*), a qualidade da gestão do risco medida pelo índice Sharpe - o índice Sortino também é empregado - e a volatilidade anual dos retornos (Varga (2001) e Jones (1999)).

Há uma vasta literatura sobre previsão de preços de ativos financeiros mediante o emprego de redes neurais artificiais (ver, por exemplo, Dase e Pawar (2010), Dutta (2006), Tilakaratne et al. (2009)), porém até recentemente ela era escassa sobre sistemas de *trading*. Na maioria dos trabalhos as métricas de desempenho dos sistemas não incluem as usualmente utilizadas na indústria financeira. Recentemente o interesse em sistemas de *trading* tem sido despertado como se pode observar pelos

trabalhos de Gomide e Milidiú (2010) e Martinez et al. (2009). Um dos trabalhos objeto de muitas referências na década de 90 foi apresentado por Kimoto et al. (1990) em que é descrito um sistema de *trading* do tipo seguidor de tendência, constituído por um conjunto de redes neurais com saídas binárias, com variáveis de entrada compostas por indicadores macroeconômicos e técnicos e com o emprego da técnica do janelamento móvel. Nesse estudo somente foi apresentada a taxa de retorno obtida, que foi confrontada com a estratégia de compre-e-segure (*buy-and-hold*). Gomide et al. (2010) empregou a taxa de retorno e a perda máxima para avaliar o sistema proposto na arbitragem entre 2 ações (*pair trading*), com posição comprada em uma delas e vendida a descoberto em outra, e utilizou regras de gerenciamento de risco com mecanismo de perda máxima (*stop loss*) e de proteção dos lucros (*trailing stop*).

Nos trabalhos sobre estimativas de preços de ativos os índices de desempenho mais empregados para apurar a acuidade nas previsões de uma rede neural são o MSE (*mean squared error*), MAPE (*mean absolute percentage error*), a Estatística U de Theil (*U of Theil Statistics*) e, mais recentemente, o POCID (*Prediction of Change in Direction*) ou a taxa de acerto nas previsões da direção do preço do ativo (Ferreira et al., (2008)). Em trabalhos mais recentes combinações desses critérios foram também empregados na seleção de redes neurais como preditoras de preços de ativos financeiros, mediante o emprego de algoritmos genéticos, como pode ser visto em Araújo (2007, 2011, 2012) e Lima et al. (2010). Embora bons resultados obtidos pelos critérios mencionados sejam desejáveis, a taxa de acerto é o fator decisivo para um sistema de *trading* lucrativo.

Neste trabalho propõe-se para a seleção da rede neural o critério da menor raiz quadrada do erro quadrático médio relativo (RMSE.R), métrica similar ao MSE, pertencente ao subconjunto das redes neurais que registraram taxas de acerto das oscilações semanais do índice Standard & Poor's 500 superiores a 60% nas amostras de teste. No período estudado de 5 anos, encerrado na última semana do 1º semestre de 2012, esse critério sugerido apresentou resultado financeiro superior ao do menor MSE e bateu por larga margem a estratégia de compre-e-segure. Até meados da segunda metade da década de 2000, a maioria dos trabalhos acadêmicos empregava o MSE, ou métricas congêneres, com variações que incluíam modificações para a correção dos parâmetros livres (pesos e vieses) pelo acerto nas previsões da direção do preço do ativo financeiro (Tilakaratne et al., (2009)).

Yao e Tan (2001) comentam que não há consenso sobre as variáveis de entrada de redes neurais nos experimentos sobre previsões dos preços de um ativo financeiro e que a maioria dos modelos se baseia em tentativas e erros na escolha dessas variáveis. Segundo a Hipótese do Mercado Eficiente (HME) todas as informações públicas estão embutidas nos preços dos ativos financeiros e, por essa razão, nenhum sistema de *trading* seria capaz de obter retornos consistentes (Fama, 1970). Todavia, Fama e Litterman (2012) reconhecem que o efeito momento nos preços no horizonte de curto prazo é o que mais tem embaraçado a HME. Esse fenômeno se caracteriza pela inércia da tendência dos preços que uma vez instalada é mais provável que ela se mantenha em seu curso do que seja revertida. Jegadeesh e Titman (1993), pesquisadoras do ramo das Finanças Comportamentais, se referem à anomalia do efeito momento ao constatar uma diferença de 1,5% ao mês entre os retornos médios das ações com elevados e baixos momentos medidos nos 12 meses precedentes. No longo prazo, contudo, esse efeito desaparece e é revertido. Por essa razão, neste trabalho, as previsões das redes neurais que integram o sistema de *trading* se restringiram ao curto prazo (horizonte de 1 semana) e a escolha das entradas recaiu exclusivamente sobre variáveis que capturam a anomalia do efeito momento, posto que ela é amparada na literatura financeira. Desde meados da última década o emprego de técnicas estatísticas, como a Análise de Componentes Principais (Raposo e Cruz, (2002)) e algoritmos genéticos passaram a ser utilizados na seleção das variáveis de entrada das redes neurais (Ferreira et al., 2008)). Neste último estudo os autores também usaram algoritmo genético para otimizar a arquitetura da rede, na escolha do algoritmo e dos atrasos (*lags*) das variáveis de uma série temporal de preços do ativo objeto de estimativas pela rede neural.

Este trabalho está dividido em 5 seções incluindo essa introdução. A segunda seção descreve de forma sumária uma rede neural artificial. A terceira discorre sobre a metodologia empregada nos experimentos. A quarta seção expõe os resultados dos experimentos e a quinta as conclusões.

2. REDES NEURAS ARTIFICIAIS

Uma rede neural artificial supervisionada é um processador não linear constituído por neurônios artificiais interligados entre si através de conexões sinápticas, com capacidade de aprendizagem sob supervisão mediante a interação com o meio ambiente. Uma rede neural com múltiplas camadas escondidas pode ser vista como um ninho de funções de ativação (Haykin, 2009), expresso pela equação abaixo, cujos pesos e vieses sinápticos são obtidos por um algoritmo no treinamento:

$$y = \varphi\left(\sum_k w_{ok}\varphi\left(\sum_s w_{ks}\varphi\left(\dots\varphi\left(\sum_j w_{lj}x_j\right)\right)\right)\right) \quad (1)$$

em que y é a saída da rede neural, $\varphi(\cdot)$ são funções de ativação contínuas, monotônicas, crescentes e limitadas, x_j são os sinais de entrada, incluído o viés, w_{ok} é o peso sináptico entre o neurônio k da última camada escondida e o neurônio o da camada de saída, e assim por diante. No presente trabalho foram utilizadas funções de ativação tangentes hiperbólicas em uma **única camada escondida** e linear na camada de saída. Neste trabalho y é a estimativa da rede neural do índice Standard & Poor's 500 com uma semana de antecedência. Portanto, a saída da rede neural não é binária como, por exemplo, +1 para a compra e -1 para a venda. As estimativas da rede neural serviram como variáveis no estabelecimento das regras do sistema de *trading*.

O algoritmo utilizado foi o *Bayesian Regularization* e as normalizações das amostras foram feitas pela função *mapminmax* da plataforma MATLAB® ,versão R2009b, utilizada nos experimentos, que limita os valores dos sinais de entrada e as saídas correspondentes no intervalo [-1,+1]. A métrica de desempenho usada na amostra de teste foi o RMSE.R (*relative root mean*

square error), equivalente ao MSE (*mean square error*), dado por:

$$RMSE_R = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{d_i - y_i}{d_i} \right)^2} \quad (2)$$

em que y_i e d_i são a i -ésima saída da rede neural, conforme equação (1), e a saída desejada correspondente, respectivamente, e N a quantidade da amostra. Embora o algoritmo empregado prescindia da validação cruzada, essa técnica foi empregada para reforçar a capacidade de generalização da rede neural. A amostra de treinamento foi subdividida em **treinamento propriamente dito**, **validação** e **teste**, que representaram 60%, 20% e 20% (*default* do MATLAB) de toda a amostra, respectivamente. Para efeito deste trabalho denomina-se **atributos** (*features*) os valores de entrada x_j , com exceção do viés. O número de neurônios testados na camada escondida obedeceu a regra $n/2$ ou $(n - 1)/2$, em que n é o número de atributos do vetor de entrada.

3. METODOLOGIA

Denomina-se **configuração**, para efeito deste trabalho, o conjunto dos atributos dos sinais de entrada da rede neural e o número de neurônios da única camada de entrada. Neste trabalho foram usados os dados dos fechamentos semanais do índice Standard & Poor's 500 entre as semanas findas em 06/04/1990 e 29/06/2012, totalizando 1160 semanas. Na pré-seleção das configurações as amostras de treinamento, validação e teste ficaram compreendidas entre as semanas findas entre 06/04/1990 e 06/07/2007, totalizando 900 semanas. O **período de verificação**, definido como sendo o espaço de tempo durante o qual são feitas as estimativas dos fechamentos semanais do índice Standard & Poor's 500 pelas redes neurais, utilizadas nas regras para as implementações das operações pelo *trading system*, ficou compreendido entre as semanas findas entre 13/07/2007 e 29/06/2012, totalizando 260 semanas ou cerca de 5 anos. A primeira operação foi realizada no último pregão da semana finda em 06/07/2007.

3.1 Implementações das operações

O sistema de *trading* consiste em regras de transação de uma carteira que emula o índice Standard & Poor's 500 com a finalidade de obter lucros de forma contínua e consistente. As regras do sistema de *trading* são as seguintes: as operações de compra e venda da carteira, sempre equivalentes a 1 contrato no valor da cotação do índice, são realizadas somente na frequência semanal, implementadas no final do último pregão de cada semana pelo preço de fechamento do índice, o sistema está sempre exposto ao mercado, porém inativo durante a semana, e uma operação de compra é sucedida por uma de venda e vice-versa. A apuração semanal do resultado a preços de mercado, mesmo que ainda não realizado, do sistema de *trading* entre a i -ésima semana e a seguinte é dada por V_{i+1} :

$$V_{i+1} = s_i |d_{i+1} - d_i| \quad (3)$$

em que d_i é a pontuação do índice Standard & Poor's 500, no valor equivalente a 1 contrato, no fechamento da i -ésima semana, quer a posição seja comprada ou vendida, d_{i+1} é a cotação de fechamento na semana seguinte, e s_i é dado por:

$$s_i = \begin{cases} +1 & \text{se } \text{sign}(d_{i+1} - d_i) = \text{sign}(y_{i+1} - d_i) \\ -1 & \text{se } \text{sign}(d_{i+1} - d_i) \neq \text{sign}(y_{i+1} - d_i) \end{cases} \quad (4)$$

em que *sign* é a função que assume valor igual a +1 se seu argumento for positivo, valor igual a -1 se for negativo, e igual a 0 se o argumento for nulo. A estimativa y_{i+1} da rede neural do fechamento do índice Standard & Poor's 500 na semana seguinte à i -ésima semana é igual a y da equação (1). Mesmo que a previsão da cotação do índice pela rede neural se desvie materialmente do valor observado, o sistema de *trading* será ganhador se a oscilação, positiva ou negativa, prevista do fechamento semanal do índice Standard & Poor's 500 for igual à observada. Neste trabalho assumiu-se que a estimativa da rede neural y_{i+1} da cotação de fechamento semanal d_{i+1} e a implementação de uma operação pelo preço d_i , no caso da indicação da rede neural ser alterada em relação à semana anterior, são feitas no mesmo instante do fechamento do pregão na i -ésima semana, igual a d_i . A ideia de postergar a execução para a abertura do primeiro pregão subsequente é discutida mais adiante. Não foram consideradas taxas de corretagem, mas por outro lado os lucros auferidos pelo sistema de *trading* não foram reinvestidos.

3.2 Seleção dos atributos

A escolha dos atributos foi inspirada no trabalho de Klassen (2005) que empregou os fechamentos semanais nas 4 semanas anteriores à semana da estimativa da rede neural e o índice técnico MACD (*moving average convergence and divergence*) na semana imediatamente anterior, com o propósito de avaliar a eficácia de uma rede neural nas previsões dos fechamentos dos índices Dow Jones Industrial e Nasdaq Composite com uma semana de antecedência, avaliada pelo critério do menor erro percentual entre a média das saídas da rede neural e as cotações de fechamento semanais observadas. Nesse trabalho não foi proposto um sistema de *trading*.

Momento é a taxa de variação dos preços por unidade de tempo, expresso por:

$$Momento = \left(\frac{P_{i+m} - P_i}{m} \right) \quad (5)$$

em que P_i é o preço de um ativo financeiro no i -ésimo instante e m o número de unidades de tempo escolhido conforme o horizonte desejado. Tanto a sequência das cotações de fechamento do índice Standard & Poor's 500 nas semanas anteriores à semana cujo fechamento se pretende estimar, quanto o indicador MACD são métricas do momento de uma tendência. Como o indicador técnico ROC (*rate of change*) não esteve presente no rol dos testados por Klassen (2005), ele foi incluído neste trabalho por ser também um indicador de momento muito utilizado (Murphy, 1999).

A função mapeada pela rede neural foi:

$$d_{i+1} = f(d_i, \Psi d_{i-1}, \Omega d_{i-2}, \Gamma d_{i-3}, \Theta MACD_i, \Phi ROC_i) \quad (6)$$

em que d_{i+1} é o preço de fechamento do índice Standard & Poor's 500 na semana seguinte à i -ésima semana, a ser previsto pela rede neural. Os atributos do vetor de entrada são d_{i-k} , $k = 0, \dots, 3$, ou seja, os preços de fechamento do índice nos últimos pregões das 4 semanas imediatamente anteriores à semana cujo preço de fechamento é estimado, $MACD_i$ e ROC_i são indicadores técnicos referentes à i -ésima semana. Os parâmetros Ψ , Ω , Γ , Θ e Φ podem assumir valores iguais a 0 ou 1, conforme a configuração selecionada. Devido à forte influência de d_i , ou seja, o último fechamento semanal conhecido no momento da decisão sobre a implementação de eventual operação pelo sistema de *trading*, essa variável sempre esteve presente em todas as configurações testadas e, portanto, o seu parâmetro é sempre igual a 1. Os indicadores técnicos $MACD_i$ e ROC_i , referentes à i -ésima semana, são dados por:

$$MACD_i = MME_i(p_1) - MME_i(p_2) \text{ e } ROC_i = d_i - d_{i-p_3-1} \quad (7)$$

em que $MME_i(p_1)$ e $MME_i(p_2)$ designam as médias móveis exponenciais do índice Standard & Poor's 500 na i -ésima semana com parâmetros p_1 e p_2 . A $MME_i(p_1)$ é calculada por:

$$MME_i(p_1) = \left(d_i - MME_{i-1}(p_1) \right) \frac{2}{1 + p_1} + MME_{i-1}(p_1) \quad (8)$$

em que $MME_1(p_1)$ é igual a d_1 . Neste trabalho os parâmetros p_1 e p_2 são, respectivamente, 8 e 17 sugeridos por Klassen (2005) e p_3 é igual a 10, uma vez que a rede neural foi informada sobre a sequência dos fechamentos de até 4 semanas anteriores à estimativa do fechamento na i -ésima semana. Se os valores do $MACD_i$ ou do ROC_i aumentam (diminuem) significa que o momento da tendência de alta (baixa) do índice se fortalece (*convergence*) e, em caso contrário, se enfraquece (*divergence*).

A ideia de postergar a execução de uma operação para a abertura do primeiro pregão da semana subsequente à previsão, levantada na subseção 3.1, não encontra respaldo na equação (6), pois esse preço de execução não é parte dos argumentos da função mapeada pela rede neural e esse valor poderia apresentar diferença material em relação a d_i , que é o preço da execução. Além disso, não é realista incluir o preço de abertura da semana seguinte como um dos atributos na equação (6), pois ele é desconhecido no instante da execução.

3.3 Pré-seleção das configurações

Foi empregada uma notação para facilitar as identificações das configurações testadas. Como exemplo de notação uma rede neural com 3 neurônios na camada escondida e com todos os atributos na equação (6), com os parâmetros Ψ , Ω , Γ , Θ e Φ iguais a 1 (o parâmetro de d_i é sempre igual a 1), a notação da configuração é 1-1-1-1-1-1-N3. Para atributos d_i , d_{i-1} , $MACD_i$ e com 1 neurônio na camada escondida a notação da configuração é 1-1-0-0-1-0-N1. Foram testadas 10 configurações, a saber:

1. 1-1-1-1-1-0-N3,
2. 1-1-1-1-1-0-N2, ambas com ROC_i ausente,
3. 1-1-1-1-0-1-N3,
4. 1-1-1-1-0-1-N2, ambas com $MACD_i$ ausente,
5. 1-1-1-0-1-0-N2, com ROC_i ausente,
6. 1-1-1-0-0-1-N2, com $MACD_i$ ausente,
7. 1-1-0-0-1-0-N1, com ROC_i ausente,
8. 1-1-0-0-0-1-N1, com $MACD_i$ ausente,
9. 1-0-0-0-1-1-N2 e
10. 1-0-0-0-1-1-N1, ambas com $MACD_i$ e ROC_i presentes.

As configurações candidatas a integrar o sistema de *trading* foram pré-selecionadas, entre as relacionadas acima, por meio de critérios abordados na subseção 3.4, testadas no período de verificação entre 13/07/2007 e 29/06/2012, de 260 semanas ou cerca de 5 anos, sem o emprego da técnica do **janelamento móvel** por razões que serão explicadas mais adiante.

3.4 Critério de escolha das configurações

Devido à enorme carga computacional exigida pela técnica do janelamento móvel foi feita uma pré-seleção das configurações elencadas na subseção 3.3 em uma 1ª etapa, conforme descrito a seguir. Na 2ª etapa, com o número de configurações reduzido, foi empregada a técnica do janelamento móvel e escolhidas a configuração e as redes neurais que integraram o sistema de trading.

1ª Etapa: Pré-seleção de até 4 configurações.

Na primeira etapa, entre as 10 configurações elencadas na subseção 3.3, foram pré-selecionadas até 4 configurações de acordo com os passos descritos a seguir:

- Para cada uma das 10 configurações elencadas na subseção 3.3, foi gerada 1 rede neural pelo critério do menor MSE (*mean squared error*) na **amostra de treinamento propriamente dito**. Esse processo foi repetido 1000 vezes tendo resultado em 1000 redes neurais para cada configuração.
- Com os pesos fixados nos treinamentos, foram apurados para cada uma dessas 1000 redes neurais o RMSE.R na amostra de teste, a taxa de acerto nas previsões das oscilações semanais do índice pelas redes neurais nessa amostra de teste e a taxa de retorno anual nominal do sistema de *trading* no período de verificação.
- Para cada configuração, entre as 10 mencionadas, foram escolhidas 2 redes neurais, uma atendendo o critério 1 e outra atendendo o critério 2, conforme descrito a seguir:
 - menor RMSE.R na amostra de teste pertencente ao subconjunto que apresentou taxa de acerto superior a 60% nessa mesma amostra de teste, critério proposto neste trabalho;
 - menor RMSE.R na amostra de teste, sem a restrição da taxa de acerto, critério usualmente empregado.

Dessa maneira obteve-se 20 redes neurais, 2 para cada configuração, uma atendendo o critério 1 e outra atendendo o critério 2.

- As configurações correspondentes às redes neurais escolhidas pelos critérios 1 e 2, descritos no item c) acima, que apresentaram o menor RMSE.R na amostra de teste e a maior taxa anual de retorno no período de verificação foram selecionadas para serem testadas pela técnica do janelamento móvel (2ª Etapa), totalizando até 4 configurações (uma configuração pode ser escolhida pelos 2 critérios). Neste passo também foi estipulado a exigência de um **viés de alta consistente** (coeficiente angular) da curva do capital empregado (*equity line*) do sistema de *trading*, relativo a cada uma das configurações pré-selecionadas.

2ª Etapa: Critério de escolha da configuração e das redes neurais para integrar o sistema de trading.

Na 2ª Etapa, para cada uma das até 4 configurações pré-selecionadas na 1ª Etapa, foram escolhidas redes neurais pelos critérios 1 e 2, conforme item c) da 1ª Etapa, mediante o emprego da técnica do janelamento móvel. A técnica do janelamento móvel consiste no treinamento periódico de redes neurais empregadas nas previsões correspondentes a períodos (janelas) de verificação que se movem ao longo do tempo. Significa que a janela única no período de verificação de cerca de 5 anos, mencionada anteriormente, é fatiada em diversas janelas e para cada uma é escolhida uma rede neural. A Figura 1 ilustra como as amostras de verificação, de treinamento, validação e teste se movem ao longo do tempo. A configuração e respectivas redes neurais que apresentaram a **maior taxa anual de retorno composta** no período de verificação foram escolhidas para integrarem o sistema de *trading*. Nos experimentos deste trabalho as janelas móveis dos sucessivos períodos de verificação cobriram as 260 semanas no intervalo entre 13/07/2007 e 29/06/2012. O tamanho máximo das amostras de treinamento, validação e teste foi de 900 semanas, sendo a primeira semana finda em 06/04/1990. Os seguintes passos foram adotados nesta etapa:

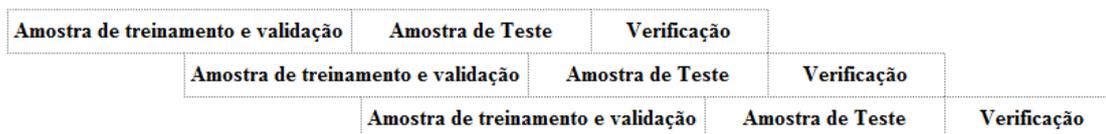


Figura 1: Técnica do janelamento móvel

- Inicialmente o período de verificação, correspondente a 260 semanas, foi fatiado em J janelas móveis, sendo J medido em número de semanas. As amostras de treinamento, validação e teste variaram de acordo com um múltiplo de J que, neste trabalho, recebeu a notação de M. Portanto, o tamanho dessas amostras foi igual ao produto entre J e M. Para cada janela J foi escolhida 1 rede neural para cada uma das até 4 configurações pré-selecionadas na 1ª Etapa, utilizando os critérios 1 e 2 conforme o item c) da 1ª Etapa.
- Os seguintes valores de J e M foram considerados:

- ii.1) Para J igual a 52 semanas, equivalente a 1 ano, foram testados M iguais a 6 e 17 (312 e 884 semanas, respectivamente). Como o período total de verificação é de 260 semanas foram escolhidas, nesse caso, 5 redes neurais (260/52), uma para cada janela móvel.
- ii.2) Para J igual a 26 semanas, equivalente a 1 semestre, foram testados M iguais a 34, 17 e 6 (884, 442 e 156 semanas, respectivamente). Nesse caso foram escolhidas 10 redes neurais (260/26), uma para cada janela móvel.
- ii.3) Para J igual a 13 semanas, equivalente a 1 trimestre, foram testados M iguais a 69 e 34 (897 e 442 semanas, respectivamente). Nesse caso foram escolhidas 20 redes neurais (260/13), uma para cada janela móvel.
- iii) Finalmente, entre as diversas combinações de J, M e as até 4 configurações, foram escolhidas a configuração, e respectivas redes neurais, que apresentaram a **maior taxa anual de retorno no período de verificação** entre 13/07/2007 e 29/06/2012 e um grau de viés da curva do capital empregado ascendente.

4. RESULTADOS

Nesta subseção são apresentados os resultados dos procedimentos mencionados na subseção 3.4.

4.1 Pré-seleção das configurações com janela única

A Tabela 1 mostra que, pelo critério 1, a configuração 1-1-0-0-1-0-N1 apresentou o menor RMSE_R de 0,016377 na amostra de teste e a configuração 1-1-1-0-1-0-N2 a maior taxa anual de retorno composta de 14,34% no período de verificação. Pelo critério 2 a configuração 1-0-0-0-1-1-N2 apresentou o menor RMSE_R de 0,015969 e a configuração 1-1-1-0-1-0-N2 a maior taxa anual de retorno composta de 15,44%. Essas configurações e respectivas métricas estão assinaladas em negrito na Tabela 1.

Tabela 1: Resultados da taxa anual de retorno com janelamento único

Configuração	Critério 1		Critério 2	
	RMSE_R	Retorno	RMSE_R	Retorno
1-1-1-1-1-0-N3	0,017067	13,03%	0,017057	5,23%
1-1-1-1-1-0-N2	0,017261	12,58%	0,017076	10,20%
1-1-1-1-0-1-N3	0,017059	11,96%	0,016511	9,51%
1-1-1-1-0-1-N2	0,016705	9,98%	0,016367	7,24%
1-1-1-0-1-0-N2	0,016927	14,34%	0,016357	15,44%
1-1-1-0-0-1-N2	0,017005	13,55%	0,016640	11,75%
1-1-0-0-1-0-N1	0,016377	11,59%	0,016377	11,59%
1-1-0-0-0-1-N1	0,017293	11,96%	0,016561	11,99%
1-0-0-0-1-1-N2	0,017673	1,32%	0,015969	5,71%
1-0-0-0-1-1-N1	0,017531	4,09%	0,016698	3,34%

A configuração 1-1-1-0-1-0-N2 atendeu os critérios 1 e 2 com a maior taxa anual de retorno. Como a configuração 1-0-0-0-1-1-N2 que apresentou o menor RMSE_R pelo critério 2 e obteve uma taxa anual de retorno nominal de 5,71%, não apresentou uma curva dos rendimentos acumulados claramente ascendente ao longo do período de verificação, ela foi descartada como opção para ser testada no janelamento móvel. Sobraram, então, as configurações 1-1-0-0-1-0-N1 e 1-1-1-0-1-0-N2.

4.2 Seleção da configuração, do tamanho da janela de verificação e das amostras de treinamento, validação e teste e das redes neurais pelo janelamento móvel

A Tabela 2 mostra as taxas anuais nominais de retorno compostas do sistema de *trading*, das redes neurais correspondentes a cada uma das 2 configurações selecionadas na subseção anterior, quais sejam 1-1-0-0-1-0-N1 e 1-1-1-0-1-0-N2, com combinações de diferentes tamanhos de janelas de verificação J e dos múltiplos M das amostras de treinamento, validação e teste. O critério final de escolha da configuração e das respectivas redes neurais foi o da maior taxa anual de retorno nominal no período de verificação entre 13/07/2007 e 29/06/2012, sendo que a escolhida foi **1-1-0-0-1-0-N1** que apresentou taxa anual composta de 15,42%, com tamanho de janela J de verificação igual a 52 semanas, portanto com 5 redes neurais (260/52), e múltiplo M igual a 17, totalizando 884 (52x17) semanas para as amostras de treinamento, validação e teste. A melhor opção corresponde aos atributos (do vetor de entrada) d_i , d_{i-1} , $MACD_i$ e 1 neurônio na camada escondida, e atendeu o critério do menor RMSE_R nas amostras de testes entre as que apresentaram taxas de acerto semanais nessas amostras acima de 60%, critério 1 sugerido neste trabalho.

Entre as 7 opções de janelamento J-T para as 2 configurações pré-selecionadas, totalizando 14 opções, mostradas na Tabela 2, somente em 2 casos a taxa anual de retorno nominal no período de verificação pelo critério 1 foi inferior à obtida pelo critério 2, usualmente empregado. Esses 2 casos foram registrados com janelamento J-T iguais a 26-34 para a configuração 1-1-0-0-1-0-N1, cuja taxa anual de retorno composta foi de 13,42%, e J-T iguais a 26-17 para a configuração 1-1-1-0-1-0-N2, cuja taxa anual de

Tabela 2: Resultados com janelamento móvel

Janelamento		Configurações			
J	Número de Semanas	1-1-0-0-1-0-N1		1-1-1-0-1-0-N2	
		Critério		Critério	
T	Múltiplo	1	2	1	2
J-T	13-69	9,31%	8,97%	8,32%	5,79%
J-T	13-34	8,05%	7,15%	-1,67%	-5,07%
J-T	26-34	10,08%	13,42%	10,78%	8,93%
J-T	26-17	7,49%	-0,54%	0,51%	9,74%
J-T	26-06	-1,03%	-7,03%	-12,94%	-9,52%
J-T	52-17	15,42%	9,70%	9,70%	8,84%
J-T	52-06	-2,43%	-2,86%	-0,25%	-4,84%

retorno composta foi de 9,74%.

Constata-se também que a redução do múltiplo M, que define o tamanho das amostras de treinamento, validação e teste, piorou o desempenho do sistema de *trading* pelos 2 critérios em 15 entre 16 casos. O único caso em que a diminuição do tamanho da amostra melhorou o desempenho do sistema foi na redução de M de 34 para 17, no caso de J igual a 26, critério 2 e configuração 1-1-1-0-1-0-N2. Por outro lado, o fato de terem sido realizadas 1000 simulações para cada tamanho de janela e em cada simulação ter sido criado um laço de 5 iterações para encontrar a rede neural com o menor MSE na amostra de treinamento propriamente dito, embora tenha exigido uma expressiva carga computacional, foi um procedimento adequado. Dessa maneira os experimentos foram realizados 2 vezes para a configuração escolhida 1-1-0-0-1-0-N1, com J-T iguais a 52-17, sendo que as métricas de desempenho mostradas na subseção 4.3 foram iguais nas 2 rodadas até a segunda casa decimal.

4.3 Métricas de desempenho do sistema de *trading*

A Tabela 3 mostra as métricas de desempenho do sistema de *trading* da configuração 1-1-0-0-1-0-N1, tamanho de janela J igual a 52 semanas e M igual a 17 (884 semanas), referentes ao período de verificação entre 13/07/2007 e 29/06/2012 (260 semanas), que apresentou nesse período uma taxa anual de retorno composta de 15,42%. O capital inicial empregado no sistema de *trading* foi de \$ 1530,44, que foi a cotação do índice Standard & Poor's 500 no fechamento da semana de 06/07/2007. O capital final empregado, após computados os resultados, foi de \$ 3134,81, equivalente a um retorno acumulado no período de verificação de 104,82%, sem a inclusão de corretagens e tributação sobre os rendimentos. Considerando 1 ano com 52 semanas a taxa anual composta foi de 15,42%¹.

Tabela 3: Resultados do sistema de *trading*

Métricas de Desempenho									
Taxa de Retorno	Taxa de Acerto Operações	Taxa de Acerto Semanal	Período Médio Operações	Payout	Índice Sharpe	Volatilidade Anual	Percentual Operações Compras	Melhor Retorno	Pior Retorno
15,42%	75,28%	59,62%	2,92	2,75	0,436	9,78%	49,44%	4,68%	-18,51%

A taxa de acerto das operações de compra e de venda foi de 75,28% e a taxa de acerto semanal de 59,62%, próxima à taxa mensal de acerto do mundialmente conhecido Winton Fund (ver Winton). Este fundo emprega modelos quantitativos e indicadores técnicos como variáveis de entrada, somente opera índices futuros e recorre à alavancagem financeira. A Tabela 4 mostra o detalhamento parcial dos cálculos dos rendimentos semanais e das operações para a configuração escolhida, apresentada como forma de ilustrar a diferença entre essas 2 taxas de acerto (taxas de acerto das operações e taxas de acerto semanais).

A **primeira coluna** na Tabela 4 enumera as semanas do período de verificação, que compreende as de número 1 a 260, e inclui a semana anterior ao início desse período (número igual a 0). A **segunda** e a **terceira colunas** as cotações de fechamento do índice Standard & Poor's 500 e as projeções correspondentes feitas pelas redes neurais **com 1 semana de antecedência**. Os conteúdos das segunda e terceira colunas geraram os resultados das demais colunas. O número 1 na **quarta coluna** (Direção SPX) indica se o índice subiu (segunda coluna) em relação à semana anterior e o -1 se caiu. Se a estimativa da rede, correta ou não, para a semana seguinte é de alta, é atribuído o número 1 na **quinta coluna** (Direção Rede) que resultará, no instante da estimativa, em uma operação de compra (*long*) e, em caso contrário, o número -1, que resultará em uma operação de venda (*short*). Obviamente quando o sistema altera a recomendação em relação à semana anterior é necessário imediatamente fechar a operação em curso, no instante da estimativa, e abrir simultaneamente uma outra na direção contrária. Por outro lado, se a recomendação de compra ou de venda é mantida, a despeito de eventual prejuízo na semana (marcação a mercado - *market to*

¹15,42 = [(1+104,82/100) ^ (52/260)-1]100

Tabela 4: Tabulação parcial dos resultados

Semana	Cotação Fech. (Pontos)	Previsão Rede (Pontos)	Direção		Lucro Semanal \$	Operação		Número Operação	Custos \$
			SPX	Rede		Lucrativa \$	Perdedora \$		
0	1530,44			-1					1,16
1	1552,50	1520,55	1	-1	-22,06				
2	1534,10	1542,00	-1	-1	18,40				
3	1458,95	1530,18	-1	1	75,15	71,49		1	2,22
4	1433,06	1467,01	-1	1	-25,89				
5	1453,64	1435,99	1	-1	20,58		-5,31	2	2,21
6	1445,94	1449,68	-1	1	7,70	7,70		3	2,20
7	1479,37	1446,48	1	-1	33,43	33,43		4	2,25
8	1473,99	1472,80	-1	-1	5,38				
9	1453,55	1472,99	-1	1	20,44	25,82		5	2,21
10	1484,25	1455,60	1	-1	30,70	30,70		6	2,26
-	-	-	-	-	-	-	-	-	-
249	1370,26	1394,64	-1	-1	27,82				
250	1378,53	1369,49	1	-1	-8,27				
251	1403,36	1374,98	1	-1	-24,83				
252	1369,10	1397,38	-1	-1	34,26				
253	1353,39	1368,89	-1	-1	15,71				
254	1295,22	1352,73	-1	1	58,17		-17,41	85	1,97
255	1317,82	1299,73	1	-1	22,60	22,60		86	2,00
256	1278,04	1316,17	-1	1	39,78	39,78		87	1,94
257	1325,66	1281,94	1	-1	47,62	47,62		88	2,02
258	1342,84	1322,12	1	-1	-17,18				
259	1335,02	1340,65	-1	-1	7,82				
260	1362,16	1334,81	1		-27,14		-36,50	89	1,04

market), nenhuma operação é realizada. A **sexta coluna** (Lucro Semanal) mostra os resultados semanais do sistema de *trading* marcados a mercado, sendo que eventual prejuízo não obriga o cancelamento da operação em curso. A **sétima coluna** (Operação Lucrativa) mostra os resultados das operações bem-sucedidas iguais às somas dos resultados semanais durante os períodos em que as operações foram mantidas. Na **oitava coluna** têm-se os prejuízos das operações malsucedidas. A **nona coluna** enumera o número de operações, que totaliza 89 e, finalmente, a **décima coluna** relaciona os custos com corretagens e emolumentos, incidentes sobre os valores da segunda coluna.

Um exemplo ajuda a entender o critério de apuração dos lucros. Na semana que antecedeu o início do período de verificação (semana 0) a rede neural estimou o fechamento do índice na semana 1 em 1520,55 pontos. Como esse valor foi inferior ao fechamento conhecido até então, de 1530,44, o sistema iniciou uma operação de venda (aposta em queda da cotação do índice). Como na semana 1 o índice subiu 22,06 pontos, o sistema auferiu um prejuízo no mesmo montante, já que cada operação envolveu apenas 1 contrato. Entretanto, na semana 2, a operação de venda foi mantida porque a estimativa de 1542,00 foi inferior ao fechamento na semana anterior de 1552,50. Como o índice caiu, o sistema de *trading* obteve um lucro na semana 2 de \$ 18,40, que compensou parcialmente a perda na semana anterior. Na semana 3 a rede alterou a sua recomendação tendo projetado alta do índice Standard & Poor's 500 na semana seguinte e, portanto, a operação de venda foi zerada e os resultados semanais acumulados enquanto a operação vigeu foi de \$ 71,49. Na semana 260 a rede não efetuou nenhuma estimativa, pois o período de verificação havia sido encerrado e a operação em curso foi compulsoriamente zerada (com prejuízo de \$ 36,50), sem a abertura de uma nova operação.

O número de vezes em que as 5 redes neurais acertaram as estimativas semanais é obtido pela quantidade de valores positivos na sexta coluna, Lucro Semanal. Em 260 projeções o sistema acertou a tendência semanal do índice Standard & Poor's 500 em 155 tentativas, que representa uma taxa de acerto de 59,62%. Em um total de 89 operações, 67 foram vitoriosas com ganhos de \$ 2521,24 e 22 operações foram malsucedidas com prejuízos de \$ 916,98, representando uma taxa de acerto de operações de 75,28% e um *payout* de 2,75 vezes (valor absoluto da razão entre ganhos e perdas). O resultado líquido das operações foi de \$ 1604,26 - sem o cômputo dos custos de corretagens e emolumentos - que propiciou no período de verificação uma taxa anual de retorno composta sobre o capital inicial de \$ 1530,44 de 15,42% ao ano (ano com 52 semanas).

Em abril de 2013 os custos (corretagens e emolumentos) de uma operação com o índice futuro do IBOVESPA no valor aproximado de R\$ 250 mil foram iguais a 0,076%, percentual incidente sobre o valor do contrato. Com as exceções das primeira e última operações, as demais incorreram em custos de fechar a operação anterior e abrir uma nova na direção oposta e, portanto, os custos foram dobrados. Se os custos fossem computados, correspondentes a \$ 166,56 no período de verificação, a taxa anual de retorno acumulada cairia para 14,17% ao ano, sem o reinvestimento dos lucros e aplicação na renda fixa das sobras de caixa

ociosas. Por outro lado, se fosse usada uma alavancagem de 50%², percentual baixo para os padrões dos fundos multimercados (*hedge funds*) como o Winton Fund, isto é, se em cada operação desde o início do período de verificação fosse utilizado 1,5 contrato, e incluídos os custos, o resultado aumentaria na mesma proporção e a taxa anual de retorno composta subiria para 19,23% ao ano, sem o reinvestimento dos lucros e aplicação na renda fixa das sobras de caixa ociosas. Convém observar que, nesse exemplo, a alavancagem decairia com o aumento dos lucros acumulados e deixaria de existir a partir do instante em que esses lucros superassem 50% do capital inicial empregado. O efeito colateral negativo da alavancagem se dá pelo aumento da volatilidade anual que subiria de 9,78% para 14,21%. Esse indicador é importante porque uma volatilidade elevada poderia afastar especuladores com maior aversão ao risco.

O índice Sharpe de 0,436, uma das medidas da qualidade da gestão de risco, é compatível com os sistemas seguidores de tendência com rentabilidades semelhantes. Cabe notar que em 15,6 anos desde a sua inserção, o Winton Fund (ver Winton) apresentou até março de 2013 uma notável taxa anual composta de 15,47%, índice Sharpe de 0,269 - pior do que o sistema de *trading* -, uma volatilidade anual de 16,80% e taxa de acerto mensal estável de 58% (medida pelas variações mensais dos valores das cotas). As operações de compra de 1 contrato do índice proporcionaram 44,76% dos resultados financeiros do sistema de *trading*, enquanto que as operações de venda contribuíram com 55,24%. As quantidades de operações de compra e de venda foram balanceadas; o melhor retorno de uma operação foi de 4,68%, calculado sobre o capital empregado imediatamente anterior ao início da operação, e o pior foi um prejuízo de -18,51%, sendo que ambas as taxas não foram anualizadas. Essa expressiva perda teve como causa a queda aguda e abrupta da cotação do índice Standard & Poor's 500 devido à quebra do banco Lehman Brothers em 2008. Se movimentos com oscilações nessa magnitude tivessem sido mais frequentes nas amostras de treinamento é plausível imaginar que as redes neurais fossem mais capazes de responder mais rapidamente a tais oscilações.

A Figura 2 mostra a evolução do capital nominal empregado (em negrito) no sistema de *trading* no período de verificação de cerca de 5 anos, antes da apuração do imposto sobre a renda e corretagens, relativas à configuração 1-1-0-0-1-0-N1 e do índice Standard & Poor's 500. Pode-se observar que a curva do capital empregado mostrou uma evolução com nítido viés de alta, embora permeada por bruscas inflexões, característica inerente de um sistema seguidor de tendência. A razão da exclusão da corretagem deveu-se ao fato de que o sistema foi penalizado pela restrição imposta ao aumento do número de contratos - ficou restrito a 1 contrato -, que teria sido possível com os lucros auferidos mantidos ociosos, e pelo fato de não ter sido empregado mecanismo de perda máxima por operação (*stop loss*), técnica usada por todos os fundos, inclusive pelo Winton Fund.

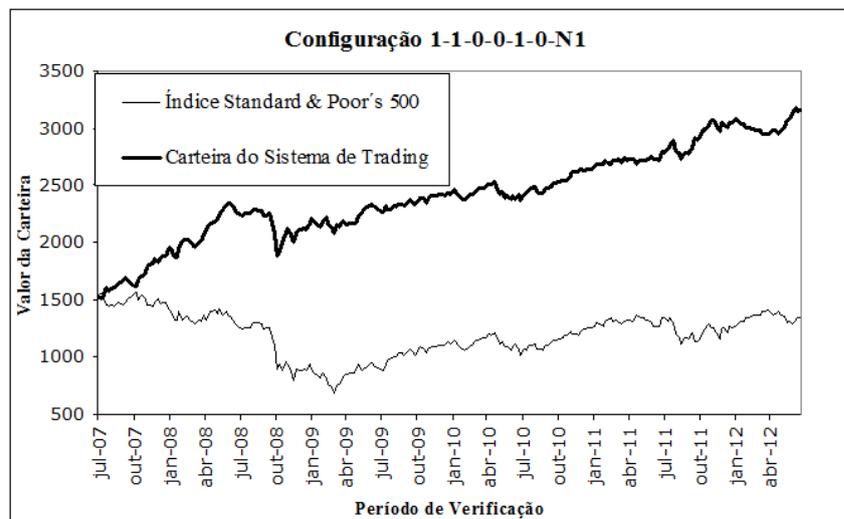


Figura 2: Evolução da carteira do sistema de *trading* e do índice Standard & Poor's 500

O intervalo médio entre 2 operações sucessivas foi de 2,92 semanas. Quanto maior o número de operações pior a rentabilidade de um fundo seguidor de tendência se sua estrutura jurídica não for convenientemente estruturada. A tributação sobre os rendimentos não foi considerada nos cálculos das métricas da Tabela 3 porque ela depende da estrutura jurídica do fundo de investimento e do regime de tributação no país. No Brasil os fundos multimercados exclusivos fechados somente são tributados nos resgates das cotas. Em muitos paraísos fiscais não há incidência de imposto sobre a renda, como é o caso do Winton Fund que é localizado nas Ilhas Virgens Britânicas.

Dutta et al. (2006), que usaram atributos que também capturam o efeito momento sem se fundamentar na literatura financeira, sugeriram em suas recomendações sobre previsões dos preços do índice SENSEX (representativo do mercado indiano) que a rede neural fosse treinada a cada 26 semanas, embora não tenham apresentado experimentos fundamentando essa recomendação. No presente trabalho o tamanho ideal da janela móvel foi de 52 semanas no período de verificação. Entretanto é possível que, com períodos diversos ou com a utilização de atributos de naturezas diferentes, obtenha-se um tamanho ótimo de janela móvel diferente do obtido neste trabalho. Finalmente nota-se na Tabela 3 que, na maioria dos casos, o aumento do tamanho das amostras de treinamento, validação e teste, melhoraram o desempenho do sistema de *trading*.

²na alavancagem deposita-se na corretora em torno de 20% do valor do contrato e o restante é aplicado na renda fixa

5. CONCLUSÃO

Os resultados dos experimentos mostraram que sistemas de *trading* com redes neurais podem apresentar métricas de desempenho bastante satisfatórias, desde que as escolhas dos atributos dos vetores de entrada, da arquitetura, do algoritmo, do tamanho das janelas móveis e das amostras de treinamento, validação e teste sejam apropriadas. Diferentemente da maioria dos trabalhos na área, neste buscou-se na literatura financeira a escolha da natureza dos atributos de entrada das redes neurais, que consistiu em variáveis que capturam a anomalia do efeito momento dos preços nos mercados. Foram explorados como atributos uma série temporal com defasagem (*lag*) em relação à estimativa do preço pela rede neural, além do indicador técnico MACD. Como recomendação futura poderia ser explorada uma combinação do critério adotado neste trabalho com a escolha das defasagens nos preços (*lags*), usados como atributos, obtidas por meio de algoritmo genético, bem como a adoção de procedimento para a correção do comportamento “*out-of-phase*” das projeções da rede neural treinada convencionalmente, conforme apresentado em Ferreira (2008). A curva do capital empregado (*equity line*) apresentou visível viés de alta conforme desejado, embora tenha apresentado uma perda de 18,51% em uma única operação - sistemas seguidores de tendência são inerentemente voláteis -, a taxa de acerto das operações e o *payout* foram elevados e o sistema tirou bom proveito ao operar nas 2 pontas, de compra e de venda, e se manter sempre exposto aos riscos do mercado. O câmputo de corretagens e emolumentos reduziu a taxa anual de retorno composta de 15,42% para 14,17%, e o sistema foi penalizado por não reaplicar os lucros obtidos no aumento do volume de contratos, que permaneceu restrito a 1 contrato do índice Standard & Poor’s 500. A taxa anual de retorno composta do sistema pelo critério proposto, qual seja, o do menor RMSE_R pertencente ao subconjunto das redes neurais que apresentaram taxa de acerto nas amostras de teste acima de 60%, foi de 15,42% no período de verificação de quase 5 anos, diante de uma taxa anual composta de 13,42% da melhor opção pelo critério do menor RMSE_R, usualmente empregado. A diferença de retorno acumulado no período entre as melhores opções dos 2 critérios confrontados foi de 9,13% a favor do critério proposto. A estratégia compre-e-segure resultou em -2,30% ao ano, equivalente a um prejuízo de cerca de -11% acumulado no período, antes do câmputo dos dividendos em torno de 1,5% ao ano.

O período de verificação foi marcado por uma expressiva volatilidade, sem que tenha havido períodos prolongados de gestão (mercado sem momento). Mercados voláteis e com tendências definidas, como foi o caso, são condições que favorecem os sistemas seguidores de tendência, mesmo com perdas expressivas em operações isoladas. Todavia, uma avaliação mais conclusiva sobre o sistema proposto somente seria possível se abrangesse um período ainda mais elástico, fosse adotado em diversos mercados, tais como moeda, *commodities* e outros índices de ações, bem como em mercados sem tendência definida (*sideways*). Convém salientar que com a globalização financeira, fruto da liberdade do fluxo de capitais, a maioria dos mercados de ações se comportou de maneira similar ao índice Standard & Poor’s 500 no período analisado. Uma das exceções foi o IBOVESPA devido possivelmente à condução da política econômica brasileira a partir de 2011. Ainda assim, no período analisado, a maioria dos mercados, inclusive o IBOVESPA, foi permeado de fortes tendências, característica favorável aos sistemas seguidores de tendência, conforme mencionado anteriormente.

Para evitar perdas significativas em operações, a sugestão feita por Kaastra e Boyd (1996), de eliminar das amostras de treinamento, validação e teste, as correspondentes às oscilações muito pequenas do índice Standard & Poor’s 500, poderia ser explorada. Dessa forma é possível que as redes se tornem mais capazes de aprender a reconhecer as oscilações mais expressivas que são as que contribuem para o melhor retorno financeiro do sistema de *trading*. Não foi utilizado mecanismo de perda máxima (*stop loss*), presente em todos os sistemas utilizados no cotidiano como forma de gerenciamento do risco, inclusive adotado na literatura mais recente, pois a sua adoção esconderia o desempenho das redes neurais, que é o propósito deste trabalho.

O presente trabalho abordou um tema pouco explorado na literatura sobre o tamanho ótimo das janelas móveis. Os experimentos mostraram que a melhor janela móvel e o tamanho de amostra de treinamento, validação e teste JM foram, respectivamente, de 52 e 887 semanas. Por outro lado, como a normalização dos sinais de entrada são feitos pelos parâmetros do treinamento, uma vez que o intervalo de preços do índice negociado no período de verificação é desconhecido no cotidiano, é possível que a janela deva ser reduzida no caso de o índice apresentar forte tendência, quer de alta ou de baixa, e ingressar em território muito fora do intervalo de preços no treinamento. Nesse caso, a normalização no intervalo $[-1,+1]$, adotada neste trabalho, poderia resultar nas saturações das funções de ativação tangentes hiperbólicas. Porém, antes de uma decisão sobre o tamanho da janela seria o caso de examinar se a normalização no intervalo $[-0,75,+0,75]$ seria suficiente para reduzir a possibilidade de saturação. Neste trabalho essa possibilidade inexistiu porque sabia-se *a priori* que o índice Standard & Poor’s 500 permaneceu contido, no período de verificação, dentro do intervalo das amostras de treinamento.

O aumento da quantidade de amostras de treinamento, validação e teste favoreceu o desempenho do sistema de *trading*. O aspecto negativo foi a enorme base de dados exigida para o treinamento, muitas vezes impossível de ser obtida. Como sugestão para trabalhos futuros seria interessante explorar variáveis que capturam a anomalia do momento como uma série temporal de log-retornos com atrasos (*lag*) que tendem a apresentar uma distribuição similar à gaussiana. Essa transformação poderia reduzir o tamanho das amostras de treinamento e viabilizar o emprego da abordagem proposta em índices com bases de dados menores. Além disso, poderia-se testar o algoritmo *Bayesian Regularization* sem o emprego da técnica da validação cruzada que consumiu 20% das amostras de treinamento. Outra recomendação seria empregar a metodologia na frequência diária e intradiária que são mais facilmente obtidas para índices recém lançados.

Agradecimentos: Os autores agradecem as sugestões feitas pelos revisores, que melhoraram a qualidade do artigo. O segundo autor agradece o apoio financeiro do CNPq, processo 301067/2009-0.

REFERÊNCIAS

- Araújo, R. A. “Swarm-Based Hybrid Intelligent Forecasting Method for Financial Time Series Prediction”. In *Learning and Nonlinear Models*, v. 5, p. 137-154, 2007.
- Araújo, R. A. “A Class of Hybrid Morphological Perceptrons with Application in Time Series Forecasting”. In *Knowledge-Based Systems*, v. 24, p. 513-529, 2011.
- Araújo, R. A. “A Morphological Perceptron with Gradient-based Learning for Brazilian Stock Market Forecasting”. In *Neural Networks*, v. 28, p. 61-81, 2012.
- Dase R. K. e Pawar D. D. “Application of Artificial Neural Network for Stock Market Predictions: A Review of Literature”. *International Journal of Machine Intelligence*, vol. 2, no. 2, pp. 14-17, 2010.
- Dutta G., Jha P., Laha A. K. e Mohan N. “Artificial Neural Network Models for Forecasting Stock Price Index in the Bombay Stock Exchange”. *Journal of Emerging Market Finance*, vol. 5, no. 3, pp. 283-295, 2006.
- Fama E. F. “Efficient Capital Markets: A Review of Theory and Empirical Work”. *Journal of Finance*, vol. 5, no. 2, pp. 427-465, 1970.
- Fama E. F. e Litterman R. “An Experienced View on Markets and Investing”. *Financial Analysts Journal*, vol. 68, no. 6, pp. 15-19, 2012.
- Ferreira T. A. E., Vasconcelos G. C., Adeodato P. J. L., “A New Intelligent System Methodology for Time Series Forecasting with Artificial Neural Networks”. *Neural Processing Letters*, vol. 28, pp. 113-129, 2008.
- Gomide P. e Milidiú R. L. “Assessing Stock Market Time Series Predictors Quality through a Pairs Trading System”. In *Proceedings of the 2010 Eleventh Brazilian Symposium on Neural Networks*. pp. 133-139. IEEE Computer Society, 2010.
- Haykin S. *Neural Networks and Learning Machines*, 3 ed. Pearson Education, New Jersey, 2009.
- Jegadeesh N. e Titman S. “Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency”. *Journal of Finance*, vol. 48, no.1, pp. 65-91, 1993.
- Jones R., *The Trading Game: Playing by the Numbers to Make Millions*, John Wiley & Sons, Inc., 1999.
- Kaasra I. e Boyd M. “Designing a Neural Network for Forecasting Financial and Economic Time Series”. *Neurocomputing*, vol. 10, no. 3, pp. 215-236, 1996.
- Kimoto T., Asakawa K., Yoda M e Takeoka M. “Stock Market Prediction - System With Modular Neural Networks”. In *Proceedings of the International Joint Conference on Neural Networks*, San Diego, USA, vol. 1, pp. 1-6, 1990.
- Klassen M.. “Effect of Some Technical Indicators in Stock Market Time-Series Forecasting Using Neural Networks”. *Informatika*, vol. 5, pp. 75-79, 2005.
- Lima, A. R., Mattos Neto, P. S. G. , Albuquerque, J. , Bocanegra, S. , Ferreira, T. A. E. “Forecasting Chaotic and Non-Linear Time Series with Artificial Intelligence and Statistical Measures”. In *Modelling Simulation and Optimization*, Gregorio Romero Rey and Luisa Martinez Muneta (Ed.), InTech, pp. 615-636, 2010.
- Murphy. J. *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance, New York, 1999.
- Martinez L. C., Hora D. N., Palloti J. R, M., Meira J. e Pappa G. “From an Artificial Neural Network to a Stock Market Day-Trading System: A Case Study on the BM&F BOVESPA”. In *Proceedings of the 2009 international joint conference on Neural Networks*. pp. 3251-3258. IEEE Press, 2009.
- Raposo R. e Cruz A. J. O. “Stock Market Prediction Based on Fundamental Analysis with Fuzzy-Neural Networks”. *Proceedings of 3rd WSES International Conference on Fuzzy Sets & Fuzzy Systems*. Neural Networks and Applications, Evolutionary Computation, 2002.
- Tilakaratne, C. D., Mammadov, M. A. e Morris, S. A. “Modified Neural Network Algorithms for Predicting Trading Signals of Stock Market Indices”. *Journal of Applied Mathematics and Decision Sciences*, vol. 2009, pp 1-22, 2009.
- Varga G., “Índice de Sharpe e outros Indicadores de Performance Aplicados a Fundos de Ações Brasileiros”. *Revista de Administração Contemporânea*, vol. 5, no. 3, pp. 215-245, 2001.
- Winton Fund, “<http://www.managedfutures.com/program-performance.aspx?fundtype=&productId=18699>”, acesso em 25/04/2013.
- Yao J. e Tan C. L. “Guidelines for Financial Forecasting with Neural Networks”. In *Proceedings of International Conference on Neural Information Processing*, pp. 14-18, 2001.