



AVALIAÇÃO DE OPORTUNIDADES DE INVESTIMENTO NO MERCADO FUTURO BRASILEIRO NA ESCALA DE DEZENAS DE SEGUNDOS

**Rafael Correia Nascimento, Claudine Badue,
Thiago Oliveira-Santos, Alberto Ferreira De Souza**
Departamento de Informática, Universidade Federal do Espírito Santo
Av. Fernando Ferrari 514, Goiabeiras, Vitória, ES, 29075-910
rafael.correian@gmail.com, claudine@lcad.inf.ufes.br,
todsantos@inf.ufes.br, alberto@lcad.inf.ufes.br

Filipe Mutz
Coordenação de Informática, Instituto Federal do Espírito Santo
Rodovia ES 010, Km 6.5, Manguinhos, Serra, ES
filipe.mutz@ifes.edu.br

Fábio Daros Freitas, Christian Daros Freitas
Receita Federal do Brasil
Vitória, ES, Brasil
freitas@computer.org, cdfreitas@gmail.com

RESUMO

Neste trabalho avaliamos oportunidades de investimento no mercado futuro brasileiro na escala de tempo de dezenas de segundos usando preditores neurais. Inicialmente, avaliamos o limite superior de retorno que pode ser gerado por investimentos no mercado futuro usando um preditor oráculo. Em seguida, avaliamos dois tipos de preditores neurais: um baseado em redes neurais MLP e o outro baseado em redes neurais sem peso VG-RAM. Nossos resultados mostraram que existem diariamente grandes oportunidades de investimento nas escalas de tempo analisadas, mas estas são difíceis de prever com as redes neurais consideradas. Isso ocorre porque as cotações dos ativos financeiros do mercado futuro têm comportamento muito próximo ao de séries *random-walk*. Contudo, usando mecanismos de decisão baseados no desempenho recente dos preditores, é possível melhorar a qualidade das decisões de compra e venda e se beneficiar de momentos em que as séries de cotações dos ativos são mais previsíveis.

PALAVRAS CHAVE. Mercado Futuro Brasileiro, Redes Neurais, Redes Neurais Sem Peso.

Área Principal: GF – Gestão Financeira

ABSTRACT

In this work, we evaluate investment opportunities in the Brazilian futures market in the scale of tens of seconds using neural predictors. Initially, we evaluated the upper limit of return that can be generated by trading on futures market using an oracle predictor. Next, we evaluated two types of neural predictors: one based on MLP neural networks and the other based on VG-RAM weightless neural networks. Our results showed that there are large investment opportunities on the analyzed time scales every day, but these are difficult to predict with the considered networks. This is because the quotes of financial assets in the futures market have a behavior very close to that of random-walk series. However, using decision mechanisms based on the recent performance of predictors, it is possible to improve the quality of buy and sell decisions and benefit from times when the series of asset prices are more predictable.

KEYWORDS. Brazilian Futures Market. Neural Networks. Weightless Neural Networks.

Main Area: GF – Financial Management



1. Introdução

Diferente do mercado de ações da BM&FBovespa, no qual são negociadas ações de empresas, no mercado futuro brasileiro são negociados *contratos futuros* com liquidação em datas futuras previamente definidas. Por exemplo, no mercado futuro são negociados *contratos futuros de dólar* com diferentes datas de vencimento, isto é, são negociados *compromissos de se vender e comprar dólares* em diferentes datas futuras. Um comprador ou vendedor de contrato futuro pode especificar qual contrato deseja comprar ou vender – um contrato é definido pela sua data de vencimento – mas, tipicamente, a maior parte do volume negociado diariamente é relativo ao próximo contrato a vencer.

Neste trabalho, avaliamos oportunidades de investimento em quatro ativos do mercado futuro brasileiro – contratos de dólar, mini-dólar, índice Bovespa e mini-índice Bovespa – e em quatro escalas de tempo – 32, 64, 128 e 256 segundos – usando um sistema automático de investimento baseado em preditores neurais. Inicialmente, para avaliar o limite superior de retorno que pode ser gerado por investimentos no mercado futuro, empregamos um preditor oráculo (que implementa uma versão simplificada da *Omniscient Trader Methodology* (OTM) apresentada por Kearns et al. [2010]), o qual pode fazer previsões perfeitas considerando dados históricos do mercado. Os resultados dessa avaliação mostraram que, se um preditor for capaz de estimar com precisão os retornos dos ativos, é possível obter diariamente retornos substanciais sobre o capital disponível em todos os ativos e escalas de tempo analisadas. Em seguida, avaliamos dois tipos de preditores neurais: um baseado em redes neurais *MultiLayer Perceptron* (MLP) [Haykin 2001] e o outro baseado em redes neurais sem peso do tipo *Virtual Generalizing Random Access Memory* (VG-RAM) [Aleksander 1998] [De Souza et al. 2012]. Os resultados dessa avaliação mostraram que o preditor VG-RAM prediz o sinal da variação de valor dos ativos melhor que o MLP na maioria dos casos, e nos casos em que seu desempenho foi pior, o foi por pequena margem. Além disso, o treinamento do preditor VG-RAM é pelo menos mil vezes mais rápido do que o do preditor MLP. Os resultados dessa avaliação mostraram, também, que ambos os preditores tiveram dificuldades em detectar oportunidades de investimento. A fim de melhorar a qualidade das decisões de compra e venda tomadas pelo sistema de investimento, avaliamos um novo critério de decisão de investimento baseado no desempenho passado recente de preditores. Os resultados dessa avaliação mostraram que, com o novo critério de decisão, o sistema de investimento pode aumentar a perspectiva de retorno sobre o capital disponível. Finalmente, a fim de elucidar a razão pela qual os preditores tiveram dificuldades em detectar oportunidades de investimento, examinamos detalhadamente as séries de cotações dos ativos. Os resultados desse estudo mostraram que as séries de cotações dos ativos do mercado futuro brasileiro podem frequentemente ser modeladas como séries *random-walk* [Fama 1970] [Fama 1991], sendo essa uma das razões que podem explicar as dificuldades de previsão.

Este artigo está organizado da seguinte forma. Depois desta introdução, na Seção 2, apresentamos trabalhos relacionados. Na Seção 3, descrevemos algumas das principais características do mercado futuro brasileiro. Na Seção 4, apresentamos o sistema de investimento empregado neste trabalho e, na Seção 5, os preditores avaliados. Na Seção 6, discutimos os experimentos realizados e, finalmente, na Seção 7, apresentamos nossas conclusões e propostas de trabalhos futuros.

2. Trabalhos Relacionados

Kearns et al. [2010] avaliaram os limites superiores de retornos que poderiam ser obtidos com uma estratégia de investimentos operando em escalas de tempo entre 10 milissegundos e 10 segundos. Para isso, ele usou a *Omniscient Trader Methodology* (OTM), isto é, uma metodologia que utiliza um preditor perfeito e que, por isso, nunca realiza operações com prejuízo. Nós empregamos uma versão simplificada da OTM para estimar o máximo de retorno possível nas escalas de tempo de 32, 64, 128 e 256 segundos na BM&FBovespa. Nossos resultados com preditor oráculo no mercado futuro brasileiro mostraram que são possíveis retornos substanciais em todos os ativos e escalas de tempo analisadas.



Em sua forma fraca, a Hipótese dos Mercados Eficientes (HME) afirma que os retornos de ativos são serialmente não correlacionados e têm uma média constante, ou seja, um mercado é considerado eficiente se as cotações atuais dos ativos refletem toda informação contida em cotações passadas, o que implica em que nenhum investidor pode elaborar uma regra de negociação baseada exclusivamente em padrões de cotações passadas para obter retornos extraordinários [Fama 1970] [Fama 1991]. Como consequência, a HME explica que as séries das cotações dos ativos financeiros podem ser modelados por séries aleatórias do tipo *random-walk*. De fato, Sitte e Sitte [2002] verificaram que preditores neurais aplicados à série de cotações do índice S&P 500 por 22 anos, entre 1973 e 1994, produziram saídas defasadas em um *lag* em relação à série original de entrada. Como resultado, as representações gráficas destas predições frequentemente ficam muito similares ao deslocamento da série original um passo adiante no tempo. Esta característica observada foi denominada de “o dilema do *random-walk*”.

Apesar da grande controvérsia acerca da eficiência dos mercados financeiros [Ritter 2003], a literatura e a prática têm reportado diversas aplicações que buscam explorar ineficiências do mercado (oportunidades de investimento), mesmo que temporárias, por meio do uso de informações contidas nas séries das cotações e retornos de ativos financeiros. Por exemplo, Ferreira et al. [2008] e Araújo e Ferreira [2013] desenvolveram um método de correção de fase para atacar o dilema do *random-walk*. Konar e Bhattacharya [2017], por outro lado, apresentaram uma nova metodologia para predição de séries temporais econômico-financeiras baseada em três etapas: segmentação das séries, clusterização dos segmentos produzidos, e representação das séries por meio de um autômato especializado. Os resultados alcançados por estes autores segurem que é possível realizar predições de séries temporais de valores de ativos ainda que estas possuam comportamento *random-walk*. Neste trabalho, avaliamos um novo critério de decisão de investimento baseado no desempenho passado recente de preditores neurais que demonstra ser possível aumentar a perspectiva de retorno sobre o capital disponível para investimento no mercado futuro brasileiro nas escalas de tempo que examinamos aqui.

3. Mercado Futuro Brasileiro

Diferente das ações de empresas, contratos futuros são cotados na BM&FBovespa em pontos por contrato. Eles possuem um período de pré-abertura de negociação, no início do dia, o qual tem duração variável e, também, um horário de encerramento de negociação, o qual é diferenciado no dia do seu vencimento, ou seja, as negociações podem encerrar-se em um horário diferente do usual no dia do seu vencimento. Além disso, eles possuem diversas datas de vencimento [BM&FBovespa1 2017] [BM&FBovespa2 2017]. O mercado futuro brasileiro disponibiliza também minicontratos futuros. Minicontratos futuros guardam semelhanças com contratos futuros “cheios”. Porém, eles representam menos dinheiro e objetivam viabilizar a participação de investidores pessoa física no mercado futuro. Além disso, eles são cotados de forma independente de seus respectivos contratos futuros “cheios” [BM&FBovespa1 2017] [BM&FBovespa2 2017]. Para negociar contratos e minicontratos futuros é exigida uma margem de garantia, tipicamente significativamente inferior ao valor que se deseja negociar.

Dentre os ativos negociados no mercado futuro brasileiro, constam o índice Bovespa (IND), o mini-índice Bovespa (WIN), o dólar americano (DOL) e o mini-dólar (WDO). Neste trabalho, consideramos esses ativos nos horários de negociação entre os períodos de pré-abertura e encerramento. As cotações usadas foram as cotações destes ativos com data de vencimento mais próxima, porque esses são os mais negociados. A Tabela 1 apresenta características técnicas dos ativos considerados. Nesta tabela, para se chegar a um dos valores da última coluna, multiplicam-se os valores das colunas anteriores (observar as unidades). Outras características relevantes destes contratos futuros são apresentadas na Seção 4 (ver Tabela 2).

4. Sistema Automático de Investimento Baseado em Preditores de Retorno

O sistema de investimento que desenvolvemos e apresentamos aqui emprega um preditor neural para estimar retornos de ativos e opera em duas etapas. Na primeira etapa, até



uma hora do dia pré-definida, h , são realizadas apenas operações de treinamento do preditor usando as cotações do dia dos ativos disponíveis até o momento. Na segunda etapa, após a hora h , são realizadas previsões que são usadas para decisões de investimento na forma de operações de compra seguidas de operações de venda (ou operações *Long*) de certo número de contratos de um ativo. A fim de computar os resultados financeiros das operações *Long* realizadas pelo sistema de investimento, foi considerado um capital diário de R\$ 125.000,00 (valor depositado como margem, ou garantia [XP Investimentos]) para cada um dos quatro ativos. A Tabela 2 apresenta as quantidades de contratos negociados para cada ativo. Essas quantidades estão em conformidade com uma margem de R\$ 125.000,00 no período de realização dos experimentos de avaliação do nosso sistema. A Tabela 2 apresenta também os volumes considerados e os custos de operação para cada ativo, os quais (os custos) estão de acordo com os valores cobrados pelas principais corretoras brasileiras à época de avaliação do sistema.

Tabela 1 – Características técnicas dos ativos.

Ativo	Tamanho do Lote Padrão (Contratos)	Cotação de Compra na Abertura do Dia 01/03/2016 (Pontos por Contrato)	Valor do Ponto de Contrato (R\$ por Ponto)	Valor de Compra do Lote Padrão na Abertura do Dia 01/03/2016 (R\$)
WIN	1	43.752,00	0,20	8.750,40
IND	5	43.845,00	1,00	219.225,00
WDO	1	4.030,50	10,0	40.305,00
DOL	5	4.031,00	50,0	1.007.750,00

Tabela 2 – Características das operações para cada ativo.

Ativo	Quantidade Negociada (Contratos)	Volume Negociado na Abertura do dia 01/03/2016 (R\$)	Custo da Operação (Pontos por Contrato)	Custo da Operação (R\$ por Contrato)	Custo da Operação (% Sobre o Valor em Reais, em 01/03/2016)
WIN	50	437.520,00	6,1000	1,22	0,014
IND	10	438.450,00	8,8600	8,86	0,020
WDO	25	1.007.625,00	0,1220	1,22	0,003
DOL	5	1.007.750,00	0,1772	8,86	0,004

Na segunda etapa de operação do sistema são realizados, também, treinamentos do preditor: sempre que uma nova cotação chega, é feito um novo treinamento incluindo o novo dado. A Figura 1 apresenta a arquitetura do preditor neural.

Nas operações de treinamento, o preditor neural recebe um conjunto de pares entrada-saída e é treinado de modo a associar cada entrada com sua respectiva saída. A saída é o retorno esperado em pontos por contrato no tempo i , re_i (ver Figura 1), dado pela Equação 1

$$re_i = p_i - p_{i-1} - cp, \quad \text{Equação 1}$$

na qual $p_{i-1}, p_i \in \{p_1, p_2, \dots, p_{i-1}, p_i, \dots, p_{np}\}$ denotam a cotação (valor) do ativo em pontos por contrato (ver Tabela 1) nos tempos $i-1$ e i , np é o número de valores disponíveis até o momento e cp representa o custo da operação *Long* (custo da operação de compra somado ao custo da operação de venda) em pontos por contrato (ver Tabela 2). A entrada é uma janela de tamanho w de retornos de investimento (medido em pontos por contrato), $\{r_1, r_2, \dots, r_j, \dots, r_w\}$ (Figura 1), na qual cada elemento r_j é dado pela Equação 2

$$r_j = p_{i-j} - p_{i-w}, \quad \text{Equação 2}$$

na qual p_{i-j} denota o valor em pontos por contrato do ativo no tempo $i-j$ e p_{i-w} denota o valor em pontos por contrato do ativo no tempo $i-w$, ou seja, no tempo mais antigo da janela de entrada.

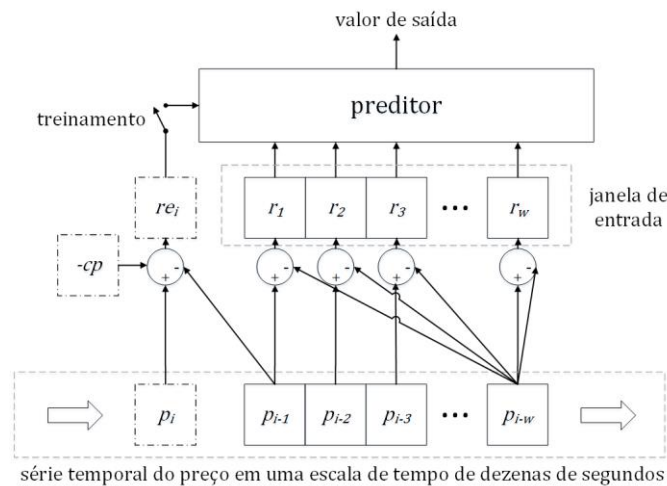


Figura 1 – Arquitetura do preditor do sistema automático de investimento.

Para cada predição, o preditor recebe como entrada uma janela de retornos e produz como saída um retorno esperado. O sistema de investimento usa a saída do preditor para tomar a decisão de realizar ou não uma operação *Long*. Essa decisão é tomada no início de cada intervalo de tempo considerado. Uma operação é realizada apenas quando o preditor produz como saída uma predição de retorno positivo. O retorno em reais de uma operação no tempo i , ro_i , é dado pela Equação 3

$$ro_i = q \times ((p_i - p_{i-1}) \times v - cr), \quad \text{Equação 3}$$

na qual q indica a quantidade de contratos negociados (ver Tabela 2), p_{i-1} o valor de compra do ativo em pontos por contrato (ver Tabela 1) no tempo $i - 1$, p_i o valor de venda do ativo em pontos por contrato no tempo i , v o valor de um ponto em reais por ponto (ver Tabela 1) e cr o custo da operação *Long* em reais por contrato (ver Tabela 2).

5. Preditores

Neste trabalho, avaliamos três preditores: um preditor oráculo e dois preditores neurais. O preditor oráculo implementa uma versão simplificada da *Omniscient Trader Methodology* (OTM) apresentada por Kearns et al. [2010]. Ele é um preditor perfeito, ou seja, um preditor que é capaz de estimar com precisão retornos de ativos. Assim, todas as operações *Long* baseadas em suas predições positivas geram retorno positivo. Um preditor oráculo é, obviamente, irreal e só é viável quando se dispõe dos dados acerca de todo o horizonte de tempo de investimento (i.e., quando o sistema de investimento é usado com dados históricos e não *on-line*). Seus resultados servem aqui para estimar o máximo de retorno possível nas escalas de tempo consideradas.

O primeiro preditor neural avaliado é baseado em redes neurais *MultiLayer Perceptron* (MLP) [Haykin 2001]. No preditor MLP, usamos a arquitetura da rede MLP proposta por Santana et al. [2016], a qual possui 4 neurônios na camada de entrada, 4 neurônios na camada escondida e 1 neurônio na camada de saída. Nas camadas escondidas, adotamos uma função de ativação tangente hiperbólica e, na camada de saída, uma função de ativação linear. No treinamento, empregamos o algoritmo de retro-propagação do erro (*backpropagation*) *Stochastic Gradient Descent* (SGD) [LeCun et al. 2012], com taxa de aprendizado igual a 0,07.

Na primeira etapa de operação do sistema de investimento, isto é, na hora do dia pré-definida, h , todas as np cotações do ativo do dia presentes até o momento são usadas para treinar a rede neural. Para isso, esses dados são usados para computar os pares entrada-saída de retornos por meio da Equação 1 e Equação 2. Os np pares entrada-saída de retornos são apresentados ne vezes (ne é igual ao número de épocas, [Haykin 2001]) ao algoritmo de treinamento SGD, sendo ne é igual a np nesta etapa de operação do sistema. Na segunda etapa de operação, após a hora h , sempre que uma nova cotação chega, as np últimas cotações, incluindo a nova, são usadas no



treinamento. Para isso, essas novas cotações são usadas para computar os pares entrada-saída de retornos. Nesta etapa, os pares entrada-saída de retornos são usados para uma operação de treinamento apenas (uma época). Note que os pares entrada-saída de retornos são sempre embaralhados antes de serem apresentados ao algoritmo de treinamento SGD.

O segundo preditor neural é baseado em redes neurais sem peso do tipo *Virtual Generalizing Random Access Memory* (VG-RAM) [Aleksander 1998] [De Souza et al. 2012]. Diferente das redes MLP, nas quais o conhecimento é armazenado nos pesos das sinapses, em redes VG-RAM o conhecimento é armazenado nas memórias dos neurônios. O treinamento pode ser feito em apenas um passo e consiste basicamente em armazenar pares entrada-saída na memória dos neurônios [De Souza et al. 2012]. Nas duas etapas de operação do sistema, sempre que uma nova cotação chega, ela é usada no treinamento. Para isso, essa cotação é usada para computar o par entrada-saída de retornos, o qual é armazenado na memória dos neurônios.

6. Avaliação Experimental

6.1. Base de Dados

Neste trabalho, os dados para avaliação do sistema de investimento foram obtidos junto à BM&FBovespa no período de 01/03/2016 a 03/05/2016 (46 dias de pregão) por meio de um sistema de investimento em bolsa de valores que implementa a *Intelligent Trading Architecture* [Freitas et al. 2016]. Para cada ativo de interesse, foi coletada uma série de pares de melhor oferta de compra (BID) e melhor oferta de venda (ASK). Esses pares de ofertas foram coletados a cada segundo, entre 9:30h e 17:55h (horário de fim do pregão do WIN e do IND). No período citado acima, houve dois feriados (25/03/2016 e 21/04/2016) nos quais não ocorreram pregões de mercado futuro. Além disso, houve falha na coleta dos dados em quatro dias (04/03/2016, 21/03/2016, 31/03/2016 e 29/04/2016); por essas razões, a base de dados final é formada por 40 dos 46 dias de coleta de dados.

A fim de usar apenas uma série de cotações por ativo, computamos o valor médio entre a melhor oferta de compra e a melhor oferta de venda. Além disso, a fim de evitar o período de pré-abertura no início do dia (que pode variar por dia e por ativo) e o período de encerramento diferenciado no dia do vencimento dos contratos (no caso do WIN e IND), consideramos apenas os horários de negociação entre 9:30h e 17:30h. Por fim, a base de dados foi dividida em dois conjuntos: um conjunto de treinamento, composto pelos primeiros 30 dias e usado para ajustar os parâmetros do nosso sistema; e um conjunto de teste, composto pelos 10 últimos dias.

6.2. Avaliação do Limite Superior de Retornos Usando o Preditor Oráculo

Nós avaliamos o limite superior de retornos que podem ser obtidos pelo sistema de investimento usando um preditor oráculo e considerando os custos de operação. Nessa avaliação, usamos o conjunto de treinamento da base de dados. Neste e nos próximos experimentos, consideramos os ativos WIN, IND, WDO e DOL e as escalas de tempo $t = 32s$, $t = 64s$, $t = 128s$ e $t = 256s$. Numa dada escala de tempo t , as cotações dos ativos são amostradas a cada t segundos, apenas.

A Figura 2(a) apresenta a média diária (dos 30 dias da base de treino) do percentual de retorno sobre o capital disponibilizado como margem (R\$ 125.000,00). Na figura, o eixo x é a escala de tempo usada e o eixo y é o percentual de retorno médio diário sobre o capital disponibilizado. Cada uma das curvas na figura representa um dos ativos avaliados. Como a Figura 2(a) mostra, escalas de tempo menores permitem maiores retornos, o que demonstra que há oportunidades de retorno mesmo em escalas de tempo destas dimensões (as cotações não ficam estáveis nestas escalas). Os retornos possíveis com os diferentes ativos variam para uma mesma escala de tempo, com os ativos WDO e DOL oferecendo maiores retornos que WIN e IND (i.e., WDO e DOL variam mais como percentuais da margem nos intervalos de tempo considerados). É importante notar ainda que, se o preditor for capaz de estimar com precisão os retornos dos ativos, é possível a obtenção de retornos de mais de 80% em média por dia.

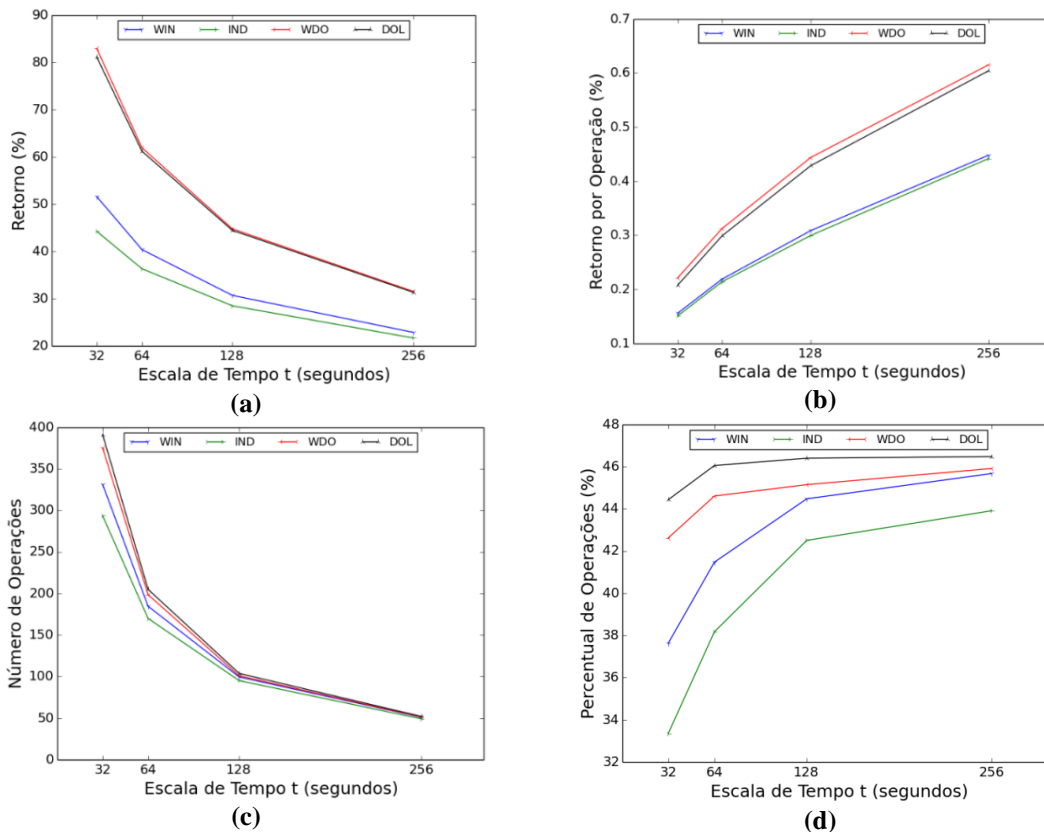


Figura 2 – (a) Média diária do percentual de retorno sobre o capital disponível. (b) Média do percentual de retorno por operação Long. (c) Média do número de operações Long por dia. (d) Percentual de operações Long possíveis considerando todas as oportunidades de realiza-las.

O gráfico da Figura 2(b) apresenta a média do percentual de retorno por operação para cada ativo e escala de tempo considerados. Os resultados da Figura 2(b) mostram que o retorno médio por operação aumenta com a escala de tempo; isso acontece porque podem ocorrer maiores variações das cotações em escalas de tempo maiores. Contudo, isso parece contradizer os resultados mostrados na Figura 2(a). A Figura 2(c) permite esclarecer essa aparente contradição. Nela são mostradas as médias diárias do número de operações Long realizadas para cada ativo em cada escala de tempo. Os resultados da Figura 2(c) mostram que são realizadas mais operações em escalas de tempo menores. Isso acontece porque existem mais oportunidades de se realizar operações Long se o dia for dividido em escalas de tempo menores do que em maiores. Finalmente, o gráfico da Figura 2(d) apresenta o percentual de operações Long dentro do total de oportunidades para tais operações (ou seja, dentro do total de intervalos de tempo considerados) para cada intervalo de tempo e ativo. Como este gráfico mostra, são realizadas percentualmente mais operações Long em escalas de tempo maiores. Isso acontece porque, em escalas de tempo menores, as variações das cotações dentro de um intervalo de tempo, ainda que positivas, por vezes não são suficientes para cobrir os custos das operações. O gráfico da Figura 2(d) mostra também que o percentual de operações Long com retorno positivo possíveis não chega a 50% dos intervalos de tempo em nenhum dos casos analisados, sendo essa uma das razões que podem explicar as dificuldades dos preditores neurais em detectá-las (ver Seção 6.5).

6.3. Métricas Usadas na Avaliação do Desempenho dos Preditores MLP e VG-RAM

Para avaliar individualmente os preditores usamos as métricas HR , HR^+ e HR^- , as quais medem o percentual de situações nas quais os sinais dos retornos observados e dos retornos preditos coincidem de algum modo específico. A métrica HR mede o percentual de situações nas quais ambos os retornos têm o mesmo sinal e são diferentes de zero; a métrica HR^+ mede o percentual de situações nas quais ambos os retornos são positivos; e a métrica HR^- mede o



percentual de situações nas quais ambos os retornos são negativos. As métricas HR , HR^+ e HR^- são dadas pela Equação 4, Equação 5 e Equação 6, respectivamente,

$$HR = \frac{\text{Contador}_{i=1}^n (re_i rp_i > 0)}{\text{Contador}_{i=1}^n (re_i rp_i \neq 0)}, \quad \text{Equação 4}$$

$$HR^+ = \frac{\text{Contador}_{i=1}^n (re_i > 0 \text{ e } rp_i > 0)}{\text{Contador}_{i=1}^n (rp_i > 0)}, \quad \text{Equação 5}$$

$$HR^- = \frac{\text{Contador}_{i=1}^n (re_i < 0 \text{ e } rp_i < 0)}{\text{Contador}_{i=1}^n (rp_i < 0)}, \quad \text{Equação 6}$$

nas quais re_i é o retorno esperado e rp_i é o retorno predito, n é o número de situações analisadas e $\text{Contador}(\cdot)$ é a contagem de ocorrências do seu argumento.

6.4. Comparação do Desempenho dos Preditores MLP e VG-RAM

Os parâmetros ótimos da arquitetura do preditor VG-RAM foram ajustados empiricamente usando a base de treinamento de modo a maximizar a métrica HR nas escalas de tempo de interesse, t (os parâmetros da rede MLP foram os mesmos de Santana et al. [2016]). A Tabela 3 apresenta os parâmetros ótimos do preditor VG-RAM [De Souza et al. 2012].

Tabela 3 - Parâmetros do preditor VG-RAM. w é o tamanho da janela de entrada, nn é o número de neurônios e ns é o número de sinapses por neurônio [Aleksander 1998] [De Souza et al. 2012].

t (segundos)	32	64	128	256
Parâmetros Ótimos	$w = 20,$ $nn = 33, ns = 32$	$w = 15,$ $nn = 33, ns = 32$	$w = 10,$ $nn = 17, ns = 32$	$w = 15,$ $nn = 17, ns = 32$

De posse dos parâmetros ótimos da rede VG-RAM, nós comparamos os desempenhos dos preditores neurais baseados nas redes MLP e VG-RAM em termos HR e do tempo de treinamento usando a base de dados de treinamento. A Tabela 4 apresenta o desempenho HR dos preditores MLP e VG-RAM para os ativos e escalas de tempo de interesse.

Tabela 4 – Desempenho HR dos preditores MLP e VG-RAM.

t (segundos)	MLP				VG-RAM			
	WIN	IND	WDO	DOL	WIN	IND	WDO	DOL
32	53,58	57,79	51,78	51,33	59,03	64,57	53,68	52,48
64	52,34	53,55	51,51	51,04	53,89	57,55	51,79	51,40
128	51,64	51,98	50,46	49,84	52,55	54,02	49,68	50,22
256	49,63	51,21	49,21	50,54	54,25	52,44	50,01	50,24

Tabela 5 – Tempo médio de treinamento dos preditores MLP e VG-RAM.

Preditor	t (segundos)	Tempo Médio de Treinamento	
		Primeira etapa de operação (segundos)	Segunda etapa de operação (segundos)
MLP	32	274,96	0,58
	64	72,64	0,30
	128	18,63	0,15
	256	5,52	0,08
VG-RAM	-	22×10^{-6}	22×10^{-6}

Na Tabela 4 estão destacados em negrito os casos em que o desempenho de uma rede neural foi melhor do que o da outra. Como a Tabela 4 mostra, a rede VG-RAM apresentou desempenho HR melhor na maioria dos casos, e nos casos em que seu desempenho foi pior, o foi por pequena margem.

Os desempenhos dos preditores MLP e VG-RAM foram comparados também em termos do tempo de treinamento. A Tabela 5 apresenta o tempo médio diário de treinamento dos preditores MLP e VG-RAM nas duas etapas de operação do sistema de investimento para as escalas de tempo de interesse. Para o preditor MLP, o melhor tempo de treinamento na primeira etapa de operação do sistema foi 5,52s na escala de tempo $t = 256$ s e o pior foi 274,96s na escala de tempo $t = 32$ s; o melhor tempo de treinamento na segunda etapa de operação foi



0,08s na escala de tempo $t = 256s$ e o pior foi 0,58s na escala de tempo $t = 32s$. Para o preditor VG-RAM, o tempo médio diário de treinamento nas duas etapas de operação do sistema foi $22 \times 10^{-6}s$. Os tempos de teste das duas redes foi similar e muito pequeno.

Os resultados apresentados na Tabela 5 mostram que o treinamento do preditor VG-RAM é pelo menos mil vezes mais rápido do que o do preditor MLP. Como o desempenho HR dos preditores VG-RAM é no geral melhor que o dos preditores MLP e o tempo de treinamento do preditor VG-RAM é significativamente menor do que o do preditor MLP, a seguir apresentaremos apenas resultados experimentais do preditor VG-RAM.

6.5. Avaliação da Taxa de Acerto do Preditor VG-RAM

Nesta seção, avaliamos o desempenho do preditor VG-RAM segundo as métricas HR , HR^+ e HR^- . Avaliamos também o desempenho financeiro do sistema de investimento usando o preditor VG-RAM e usando este preditor e um novo critério de decisão de investimento baseado no seu desempenho passado de predição. Nestes experimentos, usamos o conjunto de teste da base de dados. A Tabela 6 sumariza os resultados.

Tabela 6 – Desempenho do preditor VG-RAM e de sistemas de investimento baseados no mesmo.

Configuração		Desempenho HR			Desempenho Financeiro			Desempenho Financeiro com Critério de decisão		
t (segundos)	Ativo	HR (%)	HR^+ (%)	HR^- (%)	roc (%)	no	ppo (%)	roc (%)	no	ppo (%)
32	WIN	63,88	13,63	87,32	-2,47	57,20	33,4	-0,15	5,80	32,8
	IND	70,72	8,49	92,49	-1,97	34,20	28,4	-0,14	3,80	34,2
	WDO	58,80	23,19	78,59	-1,94	97,10	37,6	-0,20	5,20	28,8
	DOL	55,35	29,42	72,39	-4,25	124,80	41,2	-0,18	7,00	48,6
64	WIN	55,87	30,58	72,22	-2,33	64,20	41,6	-0,06	2,50	40,0
	IND	60,82	24,48	80,00	-2,73	47,90	39,2	-0,21	3,30	33,3
	WDO	52,05	30,98	66,22	-2,46	72,60	38,2	-0,14	1,30	15,4
	DOL	50,88	37,39	60,83	-3,22	85,40	41,3	-0,05	2,00	45,0
128	WIN	52,74	42,68	60,48	-1,84	45,60	45,4	0,06	1,30	46,2
	IND	53,27	34,92	65,28	-2,93	38,80	39,7	-0,14	1,50	46,7
	WDO	50,76	40,38	58,56	-1,70	45,70	42,2	-0,11	1,50	33,3
	DOL	49,51	44,09	54,04	-2,19	50,30	44,5	-0,01	1,20	41,7
256	WIN	51,07	43,64	58,25	-1,07	23,90	50,2	-0,31	1,50	40,0
	IND	50,00	36,80	60,65	-1,73	21,40	43,0	-0,22	1,30	38,5
	WDO	49,29	35,71	59,32	-1,89	21,60	39,4	-0,01	0,50	20,0
	DOL	50,00	41,63	56,51	-1,68	23,90	42,7	-0,22	0,50	20,0

A Tabela 6 está organizada em quatro grandes colunas. Na primeira, são apresentadas as configurações *escala de tempo/ativo* examinadas e, na segunda, os desempenhos dos preditores VG-RAM em termos das métricas consideradas. Estes desempenhos são similares ou maiores que os de outros preditores da literatura [Hellstrom 1999] [Liu et al. 2007] [De Souza et al. 2012]. O valor máximo da métrica HR foi 70,72% para o ativo IND na escala de tempo $t = 32s$ e o valor mínimo da métrica HR foi 49,29% para o ativo DOL na escala de tempo $t = 256s$. Os valores da métrica HR^- mostram que o preditor VG-RAM teve facilidade em detectar as *operações negativas* (i.e., operações que geram retorno negativo). O valor máximo da métrica HR^- foi 92,49% para o ativo IND na escala de tempo $t = 32s$ e o valor mínimo da métrica HR^- foi 54,04% para o ativo DOL na escala de tempo $t = 128s$. Entretanto, os valores da métrica HR^+ mostram que o preditor VG-RAM teve dificuldades em detectar as *operações positivas* (i.e., operações que geram retorno positivo). O valor máximo da métrica HR^+ foi 44,09% para o ativo DOL na escala de tempo $t = 128s$.

O desempenho financeiro do sistema de investimento foi avaliado em termos do percentual de retorno sobre o capital disponível, roc , o número de operações realizadas, no , e o percentual de operações positivas realizadas, ppo . A terceira grande coluna da Tabela 6 apresenta o desempenho do sistema segundo essas métricas para os ativos e escalas de tempo de interesse. Como a coluna roc desta grande coluna mostra, não foram obtidos resultados positivos em



nenhuma das configurações examinadas.

A fim de melhorar a qualidade das decisões de compra e venda tomadas pelo sistema de investimento, desenvolvemos um novo critério de decisão baseado no desempenho passado recente do preditor VG-RAM. O novo critério de decisão consiste em computar um grau de crença de que a próxima estimativa do preditor está correta de acordo com um número, npp , de estimativas passadas recentes do preditor. Uma operação *Long* é realizada apenas quando o grau de crença, b , for maior ou igual a um limiar, tb . O grau de crença, b , é dado pela Equação 7,

$$b = \frac{(3 npr - 3 nnr - nZR)}{3 (npr + nnr + nZR)}, \quad \text{Equação 7}$$

na qual npr é o número de vezes no passado recente em que o preditor fez uma predição positiva e ocorreu um retorno positivo; nnr é o número de vezes em que o preditor realizou uma predição positiva mas ocorreu um retorno negativo; e nZR é o número de vezes em que o preditor realizou uma predição positiva mas ocorreu um retorno neutro (zero). A Tabela 7 apresenta os parâmetros ótimos do novo critério de decisão, os quais foram encontrados empiricamente para as escalas de tempo de interesse usando o conjunto de treinamento da base de dados.

Tabela 7 - Parâmetros ótimos do novo critério de decisão para as escalas de tempo de interesse.

t (segundos)	32	64	128	256
Parâmetros Ótimos	$npp = 20,$ $tb = 65,0$	$npp = 20,$ $tb = 75,0$	$npp = 20,$ $tb = 65,0$	$npp = 20,$ $tb = 75,0$

A quarta grande coluna da Tabela 6 apresenta o desempenho do sistema de investimento com o novo critério de decisão para os ativos e escalas de tempo considerados. Comparando o desempenho do sistema de investimento sem e com o novo critério de decisão, pode-se observar que o sistema de investimento com o novo critério de decisão tornou-se mais cauteloso, o que é evidenciado pela redução do número de operações realizadas, no . Pode ser observado, também, que o sistema de investimento gerou percentual positivo de retorno sobre o capital disponível para o ativo WIN na escala de tempo $t = 128s$. Finalmente, pode ser notado que o sistema de investimento gerou percentuais superiores de operações positivas, ppo , para os ativos IND e DOL na escala de tempo $t = 32s$, ativo DOL na escala de tempo $t = 64s$ e ativos WIN e IND na escala de tempo $t = 128s$. Portanto, os resultados deste experimento mostraram que, usando o novo critério de decisão, é possível melhorar a qualidade das decisões de compra e venda e se beneficiar de momentos em que as séries de cotações dos ativos do mercado futuro são mais previsíveis. Contudo, o único resultado positivo obtido é cerca de 500 vezes menor do que o obtido com o preditor oráculo ($\sim 30 / 0,06 = 500$; ver gráfico da Figura 2(a) e o desempenho para a configuração 128s e WIN).

6.6. Avaliação das Séries de Cotações dos Ativos

A dificuldade do preditor VG-RAM em detectar oportunidades de investimento sugere ser verdadeira a hipótese de que o mercado futuro brasileiro seria um mercado eficiente. Se essa hipótese for verdadeira, então as séries das cotações dos ativos podem ser modeladas por séries aleatórias do tipo *random-walk*. Para avaliar se essa hipótese é verdadeira, verificamos se as séries das cotações dos ativos podem ser aproximadas por séries *random-walk* nas escalas de tempo de interesse usando o teste estatístico da razão de variância (*Variance Ratio Test* – VRT [Campbell et al. 1997]). O VRT tenta rejeitar a hipótese nula de que uma série de dados é uma série *random-walk* [Campbell et al. 1997]. Para isso, ele verifica se a série de dados possui uma característica típica de séries *random-walk*: a de que a variância de seus incrementos é proporcional à sua escala de tempo [Campbell et al. 1997].

Avaliamos inicialmente as séries como um todo e, para cada ativo, consideramos as séries das cotações dos diferentes dias (40 dias no total) como sendo uma única série de cotações. Os resultados da avaliação mostraram que o VRT falhou em rejeitar a hipótese nula, no nível de significância de 5%, de que as séries de cotações são *random-walk* para os ativos WIN e IND em todas as escalas de tempo analisadas (i.e., o VRT sugere que estas séries são *random-walk*). O



VRT rejeitou a hipótese nula para os ativos WDO e DOL em todas as escalas de tempo analisadas (i.e., o VRT sugere que estas séries **não** são *random-walk*). Avaliamos também o percentual de dias nos quais o VRT falhou em rejeitar a hipótese nula, ou seja, o percentual de dias nos quais as séries das cotações dos ativos se comportam como séries *random-walk*. A Tabela 8 apresenta o resultado desta avaliação.

Tabela 8 – Percentual de dias nos quais as séries se comportam como séries *random-walk*.

Ativo	t (segundos)			
	32	64	128	256
WIN	52,5	55,0	65,0	82,5
IND	72,5	77,5	85,0	90,0
WDO	32,5	45,0	55,0	60,0
DOL	57,5	65,0	67,5	77,5

Os resultados apresentados na Tabela 8 mostram que o ativo com o maior percentual de dias caracterizados como *random-walk* foi o IND (90,0% dos dias na escala de tempo $t = 256s$). O único ativo com menos de 50% dos dias caracterizados como *random-walk* foi o WDO (32,5% dos dias na escala de tempo $t = 32s$ e 45,0% dos dias na escala de tempo $t = 64s$). Portanto, nossos resultados mostram que o mercado futuro brasileiro é, em larga medida, eficiente, sendo essa uma das razões que podem explicar a dificuldade do preditor VG-RAM em detectar mais oportunidades de investimento.

7. Conclusão

Neste trabalho avaliamos oportunidades de investimento em quatro ativos do mercado futuro brasileiro – mini-índice Bovespa (WIN), índice Bovespa (IND), mini-dólar (WDO) e dólar (DOL) – e em quatro escalas de tempo – 32, 64, 128 e 256 segundos – usando um preditor oráculo e dois preditores neurais. Nossos experimentos com o preditor oráculo mostraram que, se o preditor for capaz de estimar com precisão os retornos de ativos, é possível obter diariamente grandes retornos para todos os ativos e escalas de tempo analisadas. Nós comparamos experimentalmente, então, os desempenhos de preditores neurais baseados nas redes MLP e VG-RAM em termos de *HR* e do tempo de treinamento. Nestes experimentos: (i) a rede VG-RAM apresentou desempenho *HR* melhor na maioria dos casos; e (ii) o treinamento do preditor VG-RAM foi pelo menos mil vezes mais rápido do que o do preditor MLP. Avaliamos experimentalmente, ainda, o desempenho do preditor neural VG-RAM em termos da taxa de acerto do sinal do retorno dos ativos, e o desempenho de um sistema de investimento baseado no preditor VG-RAM que emprega um novo critério de decisão de investimento baseado no percentual de retorno sobre o capital disponível e no percentual de operações positivas. Os resultados desse experimento mostraram que: (i) o preditor VG-RAM teve facilidade em detectar operações que resultariam em retornos negativos, mas dificuldade em detectar operações que resultariam em retornos positivos; (ii) o sistema de investimento com o novo critério de decisão diminuiu o número de operações realizadas, mas aumentou os percentuais de retorno sobre o capital disponível. Finalmente, avaliamos o quão randômicas são as séries das cotações dos ativos. Os resultados dessa avaliação mostraram que o mercado futuro brasileiro é um mercado eficiente na maior parte dos dias, sendo essa uma das razões que podem explicar a dificuldade do preditor VG-RAM em detectar operações com retorno positivo.

Uma possível direção para trabalhos futuros é a investigação de classificadores capazes de detectar em que momento as séries dos ativos não se comportam como séries *random-walk*. Com tal classificador, seria possível se beneficiar dos momentos dos dias em que as séries das cotações dos ativos do mercado futuro são mais previsíveis. Outra possível direção para trabalhos futuros seria a de usar dados da microestrutura do mercado futuro, tal como o livro de oferta dos ativos, a fim de treinar o preditor do sistema de investimento com seus dados.

Referências

Aleksander, I. (1998). From WISARD to MAGNUS: A family of weightless virtual neural



machines. RAM-Based Neural Networks, 9.

Araújo, R. D. A., e Ferreira, T. A. (2013). A morphological-rank-linear evolutionary method for stock market prediction. *Information Sciences*, 237, 3-17.

BM&FBovespa1 (2017). Futuro de Ibovespa. <http://www.bmfbovespa.com.br/pt_br/produtos/listados-a-vista-e-derivativos/renda-variavel/futuro-de-ibovespa.htm> Acessado em: 11 de abril de 2017.

BM&FBovespa2 (2017). Futuro de Taxa de Câmbio de Reais por Dólar Comercial. <http://www.bmfbovespa.com.br/pt_br/produtos/listados-a-vista-e-derivativos/moedas/futuro-de-taxa-de-cambio-de-reais-por-dolar-comercial.htm> Acessado em: 11 de abril de 2017.

Campbell, J. Y., Lo, A. W. C., e MacKinlay, A. C. (1997). *The econometrics of financial markets*. Princeton University press.

De Souza, A. F., Freitas, F. D., e Coelho de Almeida, A. G. (2012). Fast learning and predicting of stock returns with virtual generalized random access memory weightless neural networks. *Concurrency and Computation: Practice and Experience*, 24(8), 921-933.

Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, 25(2), 383-417.

Fama, E. F. (1991). Efficient capital markets: II. *The journal of finance*, 46(5), 1575-1617.

Ferreira, T. A., Vasconcelos, G. C., e Adeodato, P. J. (2008). A new intelligent system methodology for time series forecasting with artificial neural networks. *Neural Processing Letters*, 28(2), 113-129.

Freitas, F. D., Freitas, C. D., e De Souza, A. F. (2016). Intelligent trading architecture. *Concurrency and Computation: Practice and Experience*, 28(3), 929-943.

Haykin, S. (2001). *Redes Neurais: Princípios e prática*. 2. ed. Bookman, Porto Alegre.

Hellstrom, T. (1999). Data snooping in the stock market. *Theory of Stochastic Processes Vol. 5* (21), (1-2), 33-50.

Kearns, M., Kulesza, A., e Nevmyvaka, Y. (2010). Empirical limitations on high-frequency trading profitability. *The Journal of Trading*, 5(4), 50-62.

Konar, A., e Bhattacharya, D. (2017). Learning Structures in an Economic Time-Series for Forecasting Applications. In *Time-Series Prediction and Applications* (pp. 133-188). Springer International Publishing.

LeCun, Y. A., Bottou, L., Orr, G. B., e Müller, K. R. (2012). Efficient backprop. In *Neural networks: Tricks of the trade* (pp. 9-48). Springer Berlin Heidelberg.

Liu, F., Ng, G. S., e Quek, C. (2007). RLDDE: A novel reinforcement learning-based dimension and delay estimator for neural networks in time series prediction. *Neurocomputing*, 70(7), 1331-1341.

Ritter, J. R. (2003). Behavioral finance. *Pacific-Basin finance journal*, 11(4), 429-437

Santana, R. E., Dantas, M. J. P., e Loiola R. G. (2016). Aplicação de redes neurais para a predição no mercado de ações nacional. In *Anais do XLVIII SBPO*, p. 1188-1199, Vitória. SOBRAPO.

Sitte, R., e Sitte, J. (2002). Neural networks approach to the random walk dilemma of financial time series. *Applied Intelligence*, 16(3), 163-171.

XP Investimentos (2017). Futuros: Commodities agrícolas e financeiras para você investir. <<https://www.xpi.com.br/investimentos/futuros/>> Acessado em: 11 de abril de 2017.