

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

RAFAEL CORREIA NASCIMENTO

**Avaliação de Oportunidades de Investimento no Mercado Futuro
Brasileiro na Escala de Dezenas de Segundos**

VITÓRIA

2018

RAFAEL CORREIA NASCIMENTO

**Avaliação de Oportunidades de Investimento no Mercado Futuro
Brasileiro na Escala de Dezenas de Segundos**

Dissertação apresentada ao Programa de Pós-Graduação em Informática do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Informática.

VITÓRIA

2018

RAFAEL CORREIA NASCIMENTO

**Avaliação de Oportunidades de Investimento no Mercado Futuro
Brasileiro na Escala de Dezenas de Segundos**

COMISSÃO EXAMINADORA

Prof. Dr. Alberto Ferreira de Souza

Universidade Federal do Espírito Santo

Orientador

Prof. Dr. Thiago Oliveira-Santos

Universidade Federal do Espírito Santo

Examinador Interno

Profa. Dra. Priscila Machado Vieira Lima

Universidade Federal do Rio de Janeiro

Examinador Externo

Vitória, 9 de maio de 2018.

DEDICATÓRIA

A minha família.

AGRADECIMENTOS

Agradeço à Deus por toda a sabedoria, paciência e força de vontade que me permitiram chegar até aqui.

Agradeço à minha família por todo o suporte e apoio para alcançar os objetivos traçados.

Agradeço à minha esposa Lirielly pela paciência e por estar sempre ao meu lado.

Agradeço ao meu orientador Dr. Alberto Ferreira de Souza pelas conversas, ideias e conselhos que me ajudaram a alcançar mais esse objetivo. Agradeço à minha co-orientadora Dra. Claudine Badue pelas incontáveis revisões no texto que foram base para este trabalho. Agradeço ao Dr. Fábio Daros Freitas pelas dicas, sua expertise em finanças e pela ajuda com o *framework* ITA. Agradeço também ao Frederico Muniz da Peixe Piloto Investimentos que me permitiu acesso aos dados do mercado financeiro utilizados para desenvolver este trabalho.

Agradeço à todos os colegas do Laboratório de Computação de Alto Desempenho (LCAD) que contribuíram com conversas, ideias, artigos e até mesmo dicas de programação que ajudaram no desenvolvimento deste trabalho.

Por fim, agradeço à Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pelo apoio financeiro.

ΕΠΙΓΡΑΦΕ

“It’s difficult to make predictions, especially about the future.”

Danish proverb, author unknown

RESUMO

A utilização de sistemas automáticos de investimentos na Bolsa de Valores brasileira (BM&FBovespa) vem crescendo a cada ano. Isso ocorre porque os sistemas automáticos de investimento, também chamados de robôs, são capazes de avaliar vários ativos financeiros simultaneamente e em escalas de tempo muito menores do que as de um investidor. Dessa forma, surge a necessidade de se criar algoritmos capazes de analisar grandes quantidades de dados em tempo real e de decidir acerca da melhor ação a ser tomada para um determinado ativo financeiro de interesse a cada instante.

Neste trabalho, foram avaliadas oportunidades de investimento no mercado futuro brasileiro (uma parte da BM&FBovespa) na escala de tempo de dezenas de segundos, usando um sistema automático de investimento baseado em preditores e considerando os custos de operação. Inicialmente, foi avaliado o limite superior de retorno que pode ser gerado por investimentos no mercado futuro usando um preditor perfeito, comumente chamado de oráculo. Em seguida, foram avaliados dois tipos de preditores neurais: um baseado em redes neurais *Multilayer Perceptron* (MLP) e o outro baseado em redes neurais sem peso VG-RAM. Os resultados mostraram que existem diariamente grandes oportunidades de investimento nas escalas de tempo analisadas, mas estas são difíceis de serem preditas usando 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.

ABSTRACT

The use of automatic investment systems in the Brazilian Stock Exchange (BM&FBovespa) has been growing every year. This is because automatic investment systems, also called robots, are able to evaluate various financial assets simultaneously and at much shorter time scales than as of an investor. Thus, the need arises to create algorithms capable of analyzing large volumes of data in real time and making the decision on the best action to be taken for a particular financial asset of interest at any moment.

In this work, it was evaluated investment opportunities in the Brazilian futures market (a part of BM&FBovespa) in the time scale of tens of seconds, using an automatic investment system based on predictors and considering operation costs. Initially, it was evaluated the upper limit of return that can be generated by investments in the future market using a perfect predict, called oracle. Following, two types of neural predictors were evaluated: one based on Multilayer Perceptron neural networks (MLP) and the other based on VG-RAM weightless neural networks. Results showed that there are daily great investment opportunities in the time scales analyzed, but those were difficult to be predicted using the neural networks considered. This is because quotes of future market financial assets have a behavior very close to that of random-walk series. However, using decision mechanisms based on predictors' recent performance, it is possible to improve the quality of buying and selling decisions, and to benefit from moments in which assets quotations' series are more predictable.

LISTA DE FIGURAS

Figura 1 – Arquitetura do preditor do sistema automático de investimento.....	26
Figura 2 – Neurônio artificial.....	29
Figura 3 – Arquitetura de rede neural MLP.	30
Figura 4 – Diagrama das implementações.....	37
Figura 5 – (a) Média diária do percentual de retorno sobre o capital disponível. (b) Média do percentual de retorno por operação <i>Long</i> . (c) Média do número de operações <i>Long</i> por dia. (d) Percentual de operações <i>Long</i> possíveis considerando todas as oportunidades de realiza-las.....	41
Figura 6 – Ajuste de parâmetros preditor VG-RAM 32 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w	44
Figura 7 – Ajuste de parâmetros preditor VG-RAM 64 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w	45
Figura 8 – Ajuste de parâmetros preditor VG-RAM 128 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w	46
Figura 9 – Ajuste de parâmetros preditor VG-RAM 256 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w	47

LISTA DE TABELAS

Tabela 1 – Características técnicas de contratos futuros negociados no mercado futuro brasileiro.....	18
Tabela 2 – Características das operações para cada ativo.....	25
Tabela 3 - Parâmetros ótimos da arquitetura do preditor VG-RAM para as escalas de tempo de interesse, t . nn é o número de neurônios, ns é o número de sinapses por neurônio e w é o tamanho da janela de entrada (ALEKSANDER, 1998) (DE SOUZA et al., 2012).	43
Tabela 4 – Desempenho médio HR dos preditores MLP e VG-RAM.	48
Tabela 5 – Tempo médio de treinamento dos preditores MLP e VG-RAM nas duas etapas de operação do sistema de investimento para as escalas de interesse, t	49
Tabela 6 – Desempenho médio do preditor VG-RAM em termos da métrica HR	51
Tabela 7 – Desempenho financeiro médio do sistema de investimento 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	52
Tabela 8 - Parâmetros ótimos do novo critério de decisão para as escalas de tempo de interesse.....	53
Tabela 9 – Desempenho médio do sistema de investimento com o novo critério de decisão.....	54
Tabela 10 – Percentual de dias nos quais as séries das cotações dos ativos se comportam como séries random-walk.....	57

Sumário

1	Introdução.....	13
1.1	Mercado Futuro Brasileiro	15
1.2	Motivação.....	18
1.3	Objetivo	18
1.4	Contribuições	19
1.5	Organização do Texto	19
2	Trabalhos Relacionados.....	21
3	Sistema Automático de Investimento Baseado em Preditores de Retorno	24
3.1	Arquitetura do Sistema Automático de Investimento.....	24
3.2	Preditores.....	27
3.2.1	Preditor Oráculo.....	28
3.2.2	Preditor Neural Baseado em Redes Neurais <i>MultiLayer Perceptron</i> (MLP) 28	
3.2.3	Preditor Neural Baseado em Redes Neurais Sem Peso do Tipo <i>Virtual Generalizing Random Access Memory</i> (VG-RAM)	31
4	Metodologia Experimental.....	33
4.1	<i>Intelligent Trading Architecture</i> (ITA).....	33
4.2	Keras e TensorFlow	34
4.3	Máquina Associadora de Eventos (MAE).....	35
4.4	Implementação.....	36
4.5	Base de Dados.....	37
4.6	Métricas.....	38
5	Resultados Experimentais	40
5.1	Avaliação do Limite Superior de Retornos Usando o Preditor Oráculo	40
5.2	Comparação do Desempenho dos Preditores MLP e VG-RAM.....	42

5.3	Avaliação da Taxa de Acerto do Preditor VG-RAM.....	50
5.4	Avaliação das Séries das Cotações dos Ativos	55
6	Conclusão e Trabalho Futuro	58
6.1	Sumário.....	58
6.2	Conclusão	59
6.3	Trabalho Futuro.....	60
7	Publicações	61
8	Referências Bibliográficas	62

1 INTRODUÇÃO

A Bolsa de Valores é um mercado que relaciona tomadores de recursos e investidores por meio de investimentos em ativos financeiros (ações de empresas, por exemplo). Esse relacionamento entre tomadores de recursos e investidores não acontece diretamente, mas sim por intermédio de vários atores (ou instituições) que facilitam esse encontro, o regulam e o fiscalizam. Um dos principais atores nesse intermédio são corretoras de valores.

Tomadores de recursos são aqueles que querem captar recursos para diversos fins, como pagamento de dívidas, financiamento de equipamentos, entre outros. Já investidores são aqueles que dispõem de recursos financeiros e desejam multiplicar seus recursos por meio de investimentos. Investimentos na Bolsa de Valores são investimentos de renda variável, porque, como o próprio nome diz, têm resultado variável ao longo do tempo. Investimentos na Bolsa de Valores se diferenciam de investimentos em renda fixa, como a poupança, por exemplo, porque não é possível mensurar seu resultado a priori, ou seja, o investidor não sabe o quanto vai receber por aquele investimento ao final de um período. Além disso, investimentos na Bolsa de Valores podem gerar ganhos significativamente maiores que investimentos convencionais em renda fixa; porém, podem gerar também prejuízos proporcionais.

Dois maneiras de se fazer investimentos na Bolsa de Valores são por meio de análises fundamentalistas e de análises técnicas. Análises fundamentalistas são aquelas que se baseiam na ideia de que o valor negociado de um ativo não reflete o valor real desse ativo. Por isso, a análise fundamentalista busca estimar o valor intrínseco de um ativo financeiro para determinar se esse se encontra subvalorizado ou supervalorizado, por meio do estudo de tudo aquilo que pode afetar o valor do ativo, do contexto econômico do país até a gerência da empresa (para os casos de ações de empresas). Análises técnicas se baseiam na ideia de que o histórico de negociações e variações de preços de ativos são melhores indicadores do valor futuro dos ativos do que o seu valor intrínseco. Sendo assim, a análise técnica busca realizar previsões de valores futuros de ativos a partir da análise de dados históricos dos ativos, de forma a encontrar padrões e tendências. Para isso, a análise técnica

utiliza métodos estatísticos e de aprendizado de máquina para, a partir de dados históricos, realizar previsões de valores futuros de ativos.

No contexto de análises técnicas, sistemas automáticos de investimentos em bolsas de valores, capazes de realizar previsões de cotações dos ativos financeiros a partir de dados históricos e tomar decisões baseadas nessas previsões, oferecem vantagens competitivas aos investidores. Isso ocorre porque sistemas automáticos são capazes de avaliar vários ativos financeiros simultaneamente e em escalas de tempo proibitivas para investidores. Por conta disso, a utilização de sistemas automáticos de investimentos na Bolsa de Valores, Mercadorias e Futuros brasileira (BM&FBovespa) vêm crescendo a cada ano (PARANÁ, 2016). Dessa forma, surge a necessidade de criar algoritmos capazes de analisarem grandes quantidades de dados em tempo real e de decidirem acerca da melhor ação a ser tomada para um determinado ativo financeiro de interesse a cada instante.

Neste trabalho, foram avaliadas 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 (ou seja, por meio de análise técnica) e considerando custos de operação cobrados por corretoras de valores. Inicialmente, para avaliar o limite superior de retorno que pode ser gerado por investimentos no mercado futuro, foi empregado 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, foram avaliados 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, foi avaliado 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, as séries de cotações dos ativos foram examinadas detalhadamente. 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 predição.

1.1 Mercado Futuro Brasileiro

O mercado futuro brasileiro é composto por um conjunto de ativos financeiros negociados na BM&FBovespa. Diferente do mercado de ações da BM&FBovespa, no qual são negociadas ações de empresas, no mercado futuro são negociados *contratos futuros* com liquidação em datas futuras previamente definidas. Para ilustrar o conceito de contrato futuro, é tomada como exemplo a negociação de *contratos futuros de dólar*, um dos ativos do mercado futuro da BM&FBovespa.

Suponha que uma empresa sediada no Brasil deseje vender, em dólar, produtos para empresas no exterior e precise decidir a que preço, em reais, é aceitável vender seus produtos na moeda estrangeira. Na negociação com as empresas sediadas no exterior, a empresa brasileira verifica quando e quanto essas empresas estão dispostas a pagar em dólar pelos seus produtos. 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. A empresa nacional avalia se a cotação dos contratos de dólar é suficiente para cobrir suas despesas e garantir seu lucro; a cotação dos contratos de dólar é avaliada pela empresa nacional na data em que ela receberia dólares pelos produtos que deseja vender no exterior. Caso a cotação dos contratos de dólar seja suficiente, a empresa nacional fecha a negociação com a empresa no exterior e vende contratos de dólar no mercado futuro em valor equivalente ao dos produtos negociados. Ao vender os contratos de dólar no mercado futuro, a empresa nacional recebe imediatamente o valor em reais (ela precisa possuir crédito para tal, obviamente) e mantém o compromisso de entregar os dólares na data de vencimento dos contratos. Na data em que a empresa nacional receber pelos seus produtos da empresa no exterior, a empresa nacional terá os dólares para cumprir o compromisso de entrega dos dólares estabelecido nos contratos de dólar negociados previamente. Dessa forma, a empresa nacional garante o valor em reais de seus produtos a serem entregues em troca de dólares no futuro.

Sem possuir quaisquer mercadorias para vender, qualquer ator pode atuar no mercado futuro, especulando sobre o valor de contratos futuros, e comprando-os ou vendendo-os no mercado futuro. Um comprador ou vendedor de contrato futuro pode especificar qual contrato – um contrato é definido pela sua data de vencimento – deseja comprar ou vender, mas, tipicamente, a maior parte do volume negociado a cada dia é relativo ao próximo contrato a vencer.

Contratos futuros são cotados na BM&FBovespa em pontos de contrato e não em reais, como ações de empresas. Para negociar um contrato futuro é exigida uma margem de garantia (tipicamente significativamente inferior ao seu valor). Estes ativos possuem características técnicas específicas, tais como o valor do ponto de contrato futuro, o tamanho do lote padrão (número mínimo de contratos futuros que podem ser negociados de uma única vez) e as datas de vencimento dos contratos. Possuem um período de pré-abertura de negociação, no início do dia, o qual tem duração variável. Possuem 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, possuem diversas datas de vencimento (BM&FBOVESPA1, 2017) (BM&FBOVESPA2, 2017). Neste trabalho, são considerados os horários de negociação entre os períodos de pré-abertura e encerramento, e a cotação do contrato futuro com data de vencimento mais próxima, porque esse é o contrato mais negociado.

O mercado futuro brasileiro disponibiliza também minicontratos futuros. Minicontratos futuros guardam semelhanças com contratos futuros “cheios”. Porém, representam menos dinheiro e objetivam viabilizar a participação de investidores pessoa física no mercado futuro. Além disso, são cotados de forma independente de seus respectivos contratos futuros “cheios” (BM&FBOVESPA1, 2017) (BM&FBOVESPA2, 2017).

Dentre os ativos negociados no mercado futuro brasileiro, constam o índice Bovespa, o mini-índice Bovespa, o dólar (americano) e o mini-dólar. A Tabela 1 apresenta características técnicas dos contratos futuros de mini-índice Bovespa (WIN), índice Bovespa (IND), mini-dólar (WDO) e dólar (DOL), examinados neste trabalho. Nessa tabela, para se chegar a um dos valores da última coluna, multiplicam-se os valores das colunas anteriores (observar as unidades). Outras características relevantes desses contratos futuros são apresentadas no Capítulo 3 (ver Tabela 2).

Tabela 1 – Características técnicas de contratos futuros negociados no mercado futuro brasileiro.

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

1.2 Motivação

Este trabalho está inserido em um grupo de pesquisa do Laboratório de Computação de Alto Desempenho (LCAD) do Departamento de Informática (DI) da Universidade Federal do Espírito Santo (UFES). Grupo de Pesquisa de Computação de Alto Desempenho em Finanças (CADF), que têm entre seus objetivos a aplicação de técnicas de computação de alto desempenho e inteligência artificial para estudar fenômenos e comportamentos de ativos financeiros nos mercados financeiros.

A principal motivação deste trabalho é contribuir para o grupo de pesquisa CADF com o estudo de séries temporais financeiras em escalas de tempo de dezenas de segundos e da capacidade de preditores neurais em prever tais series.

1.3 Objetivo

O objetivo deste trabalho é realizar um estudo sobre oportunidades de investimento no mercado futuro brasileiro na escala de dezenas de segundos. É também objetivo deste trabalho desenvolver um sistema automático de investimentos baseado em

preditores neurais, o qual seja capaz de explorar essas oportunidades de investimento observadas.

1.4 Contribuições

As principais contribuições deste trabalho foram:

- Desenvolvimento de um sistema para amostragem e coleta de séries temporais de ativos financeiros de interesse a partir de dados brutos obtidos junto à BM&FBovespa;
- Estudo de oportunidades de investimento no mercado futuro brasileiro na escala de dezenas de segundo, considerando custos de operação;
- Desenvolvimento de um sistema automático de investimentos baseado em preditores com redes neurais *Multilayer Perceptron* (MLP), considerando custos de operação;
- Desenvolvimento de um sistema automático de investimento baseado em preditores com redes neurais sem peso do tipo *Virtual Generalizing Random Access Memory* (VG-RAM), considerando os custos de operação;
- Desenvolvimento de um critério de decisão baseado no desempenho recente dos preditores;
- Análise das séries temporais dos ativos financeiros utilizados neste trabalho;
- Criação de uma base de dados com as séries temporais dos ativos financeiros utilizados neste trabalho.

1.5 Organização do Texto

Este trabalho está organizado da seguinte forma. Depois desta Introdução, no **Capítulo 2**, são apresentados alguns trabalhos relacionados com o tema deste trabalho. No

Capítulo 3, são apresentadas a arquitetura do sistema automático de investimento proposto neste trabalho e os preditores utilizados no sistema automático de investimento. Primeiro, é apresentado o preditor oráculo; depois, o preditor baseado em redes neurais *MultiLayer Perceptron* (MLP); e, por fim, o preditor baseado em redes neurais sem peso do tipo *Virtual Generalizing Random Access Memory* (VG-RAM). No

Capítulo 4, é apresentada a metodologia experimental com os *frameworks* utilizados, a implementação, a base de dados utilizada e as métricas. No

Capítulo 5, são apresentados os resultados obtidos neste trabalho. No

Capítulo 6, são apresentados um sumário do trabalho, as conclusões obtidas e sugestões para trabalhos futuros. Finalmente, no

Capítulo 7, são apresentadas as publicações obtidas durante o mestrado.

2 TRABALHOS RELACIONADOS

A previsão das cotações de ativos financeiros em bolsas de valores sempre foi alvo de grande interesse por parte de investidores. Isso acontece, pois, aqueles que conseguem prever cotações futuras ou ao menos predizer tendências de comportamento do mercado possuem grandes vantagens em relação aos outros investidores (SANTANA et al., 2016) e podem obter grandes retornos financeiros. Kearns et al. (2010) avaliou 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. O OMT foi avaliado com dados do ano de 2008 da bolsa de valores norte americana NASDAQ. Os resultados apresentados destacam lucratividade máximas anuais surpreendentemente modestas em valores percentuais, alcançando menos de 0,05% de um volume negociado de aproximadamente US\$ 52 trilhões, contabilizado a partir dos dados dos negócios realizados (TAQ data). Uma versão simplificada da OTM foi empregada para estimar o máximo de retorno possível nas escalas de tempo de 32, 64, 128 e 256 segundos na BM&FBovespa. Os resultados com o preditor oráculo no mercado futuro brasileiro mostraram que são possíveis retornos substanciais em todos os ativos e escalas de tempo analisadas.

A discussão acerca da previsibilidade das cotações de ativos financeiros em bolsas de valores tem um marco fundamental na Hipótese dos Mercados Eficientes (HME). Em sua forma fraca, a 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 series das cotações dos ativos financeiros

podem ser modeladas por séries aleatórias do tipo *random-walk*. De fato, Sitte e Sitte (2002) verificaram que preditores neurais aplicados à série da cotação 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 previsões 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*”. Os autores argumentam que este efeito não é uma limitação das redes neurais empregadas, mas sim um comportamento consistente com décadas de resultados obtidos pela análise estatística, e que contradizem a crença de que os valores passados das séries temporais das cotações dos ativos contêm informação acerca dos seus valores futuros.

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*. O método apresentado pelos autores consiste em duas etapas. Primeiro, as previsões das séries das cotações dos ativos são produzidas por meio de redes neurais (FERREIRA et al., 2008) e filtros morfológicos (ARAÚJO e FERREIRA, 2013). Em seguida, as previsões obtidas passam por um processo de correção de fase que envolve aplicar padrões de entrada reconstruídos, com os valores das previsões, novamente a entrada das redes neurais. Os trabalhos apresentaram experimentos envolvendo diversas séries de cotações de ativos financeiros, tais como os índices *Dow Jones Industrial Average* (DJIA) e *NASDAQ* (FERREIRA et al., 2008), e as ações do *Directv Group Inc* e da *Microsoft Corporation* (ARAÚJO e FERREIRA, 2013) e os efeitos da correção de fase das previsões foram proeminentes.

Konar e Bhattacharya (2017), por outro lado, apresentaram uma nova metodologia para previsão 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. Na etapa de segmentação um novo algoritmo on-line e não-paramétrico assinala os rótulos “*rise*”, “*fall*”, e “*equality*” a janelas de comprimento variável ao longo da série temporal de acordo com o gradiente local das transições entre dois pontos sucessivos. Em seguida, janelas sucessivas com o mesmo rótulo são combinadas para formar um segmento temporal. Os segmentos temporais de comprimentos distintos são normalizados empregando-se uma representação baseada em um número fixo de pontos equidistantes, e em seguida são clusterizados por meio de uma extensão do algoritmo DBSCAN que suporta clusterização hierárquica multinível. Por fim, os *cluster centers* obtidos são utilizados como símbolos de entrada para um autômato especializado construído para representar o conhecimento da série temporal. Um conjunto de experimentos foi realizado com a série da cotação de fechamento diária do índice TAIEX (*Taiwan Stock Exchange Capitalization Weighted Stock Index*) entre 1990 e 2000, e foi obtida uma acurácia acima de 90% na predição da sequência de transições para a série. Os resultados alcançados por estes autores sugerem que é possível realizar predições de séries temporais de valores de ativos ainda que estas possuam comportamento *random-walk*. Neste trabalho, foi avaliado 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 aqui examinadas.

3 SISTEMA AUTOMÁTICO DE INVESTIMENTO BASEADO EM PREDITORES DE RETORNO

Neste capítulo, é apresentado o sistema automático de investimento baseado em preditores de retorno. Na Seção 3.1, é descrita a arquitetura do sistema automático de investimento e, na Seção 3.2, são descritos os preditores neurais.

3.1 Arquitetura do Sistema Automático de Investimento

Neste trabalho, é avaliado um sistema automático de investimento baseado em preditores de retorno para exploração de oportunidades de investimento no mercado futuro brasileiro na escala de dezenas de segundos. O sistema de investimento 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 certa quantidade 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, 2017)) 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 sistema. A Tabela 2 apresenta também os volumes e os custos de operação para cada ativo, os quais (os custos) estão de acordo com os custos cobrados pelas principais corretoras brasileiras à época de avaliação do sistema.

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 são realizados, também, operações de treinamento 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.

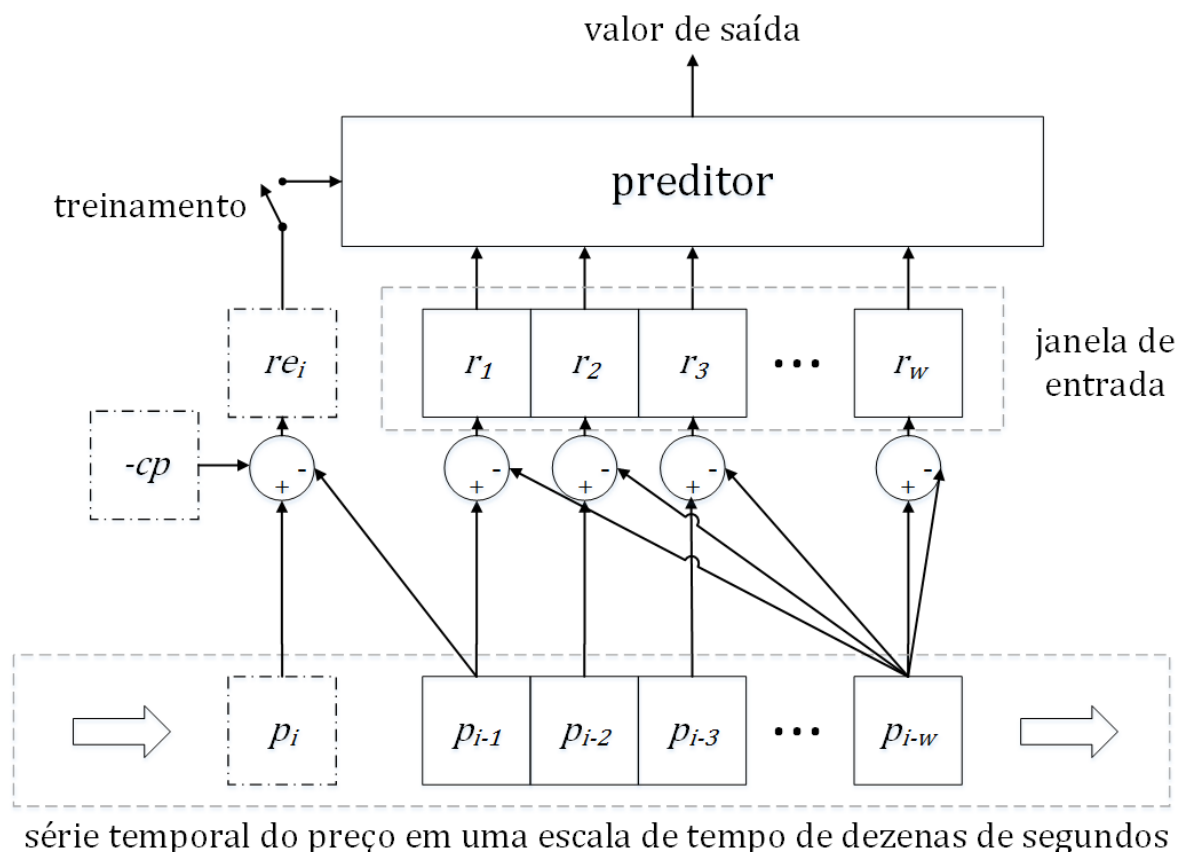


Figura 1 – Arquitetura do preditor do sistema automático de investimento.

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) no tempo $i-1$ 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.

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).

3.2 Preditores

Neste trabalho, foram avaliados três preditores: um preditor oráculo e dois preditores neurais. Na Seção 3.2.1, é descrito o preditor oráculo, na Seção 3.2.2, o preditor neural baseado em redes neurais *MultiLayer Perceptron* (MLP) (HAYKIN, 2001) e, na Seção 3.2.3, o preditor neural baseado em redes neurais sem peso do tipo *Virtual Generalizing Random Access Memory* (VG-RAM) (ALEKSANDER, 1998) (DE SOUZA et al., 2012).

3.2.1 Preditor Oráculo

Nesta seção é apresentado o preditor oráculo. 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 previsões 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 (isto é, 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.

3.2.2 Preditor Neural Baseado em Redes Neurais *MultiLayer Perceptron* (MLP)

Nesta seção é apresentado o primeiro preditor neural avaliado e baseado em redes neurais *MultiLayer Perceptron* (MLP) (HAYKIN, 2001). Redes neurais *MLP* são constituídas de várias unidades simples de processamento, chamadas neurônios artificiais (Figura 2). Os neurônios artificiais são conectados a neurônios de outras camadas. Uma conexão entre um par de neurônios é chamada de sinapse e possui um peso associado a ela. O peso de uma sinapse diz o quão forte é a conexão entre o par de neurônios. Cada neurônio computa a soma ponderada de suas entradas pelos pesos das sinapses e aplica esse resultado a uma função de ativação para gerar sua saída. A função de ativação de um neurônio pode ser linear, quando a soma ponderada não sofre alteração, ou não linear, quando a soma ponderada é submetida a uma função não linear, tal como função sigmoide ou função tangente hiperbólica.

Fonte: Adaptado da internet.

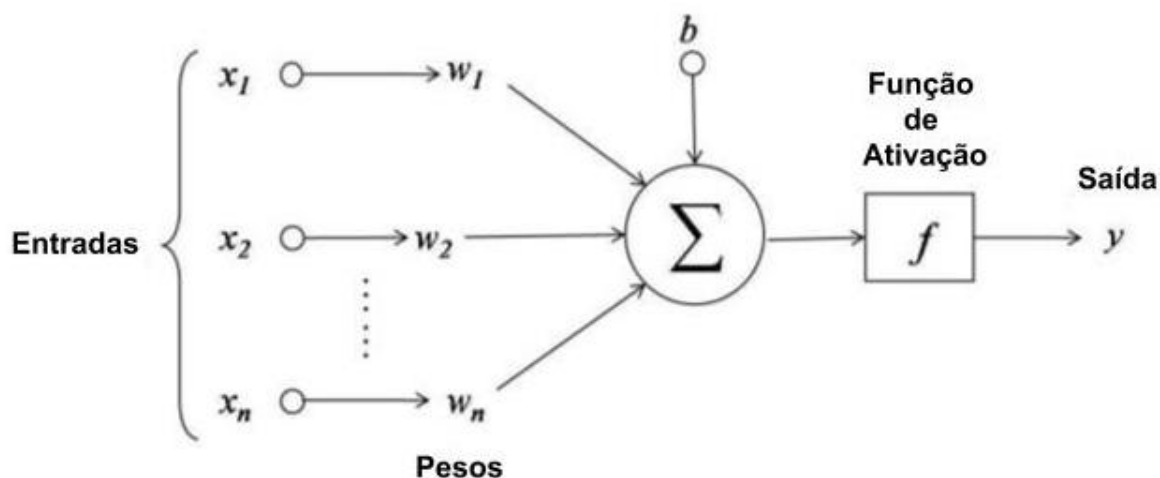


Figura 2 – Neurônio artificial

Redes *MLP* (Figura 3) são geralmente organizadas em três ou mais camadas: uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Na camada de entrada, cada neurônio recebe apenas uma entrada e possui função de ativação linear. Nas camadas escondidas, os neurônios são totalmente conectados aos neurônios das camadas imediatamente anterior e posterior. Nessas camadas, os neurônios possuem função de ativação não linear. Finalmente, na camada de saída, os neurônios são totalmente conectados à camada imediatamente anterior e a função de ativação depende do problema a ser resolvido.

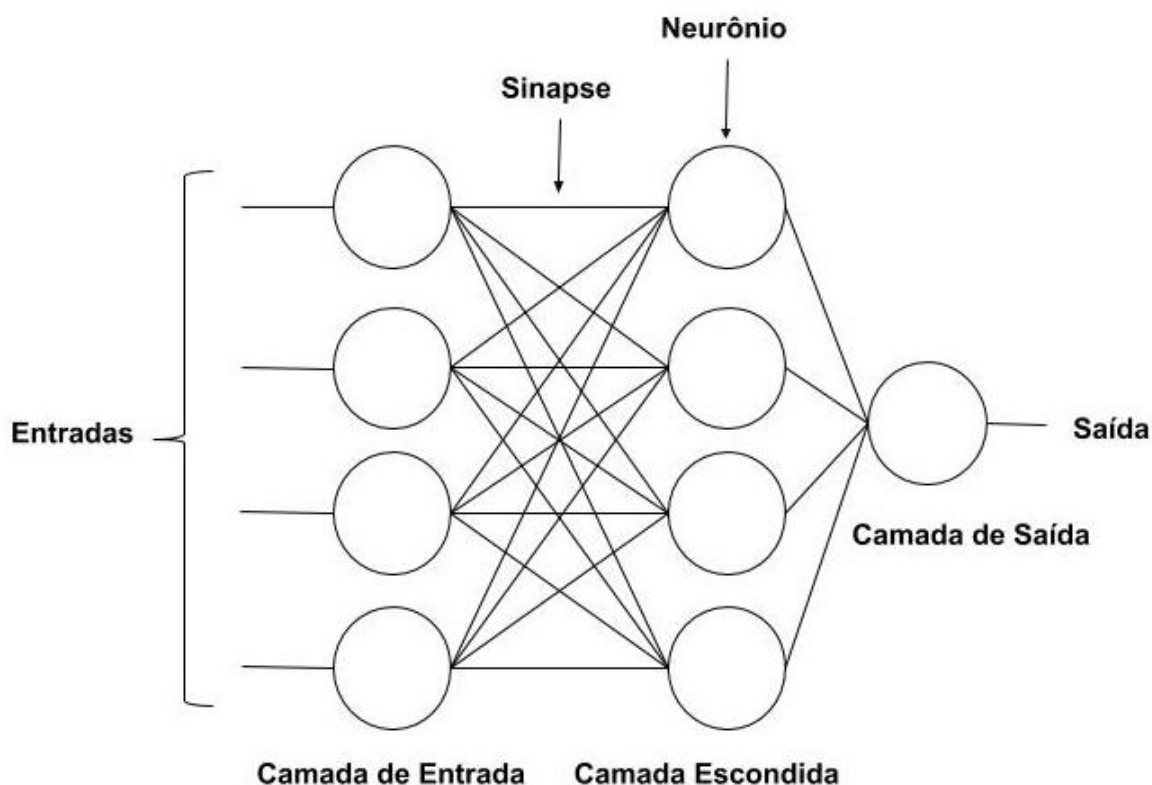


Figura 3 – Arquitetura de rede neural MLP.

Na fase de treinamento das redes *MLP*, dado um conjunto de pares entrada e saída, é encontrado o conjunto de pesos das sinapses que minimiza a diferença entre as saídas estimadas pela rede e as saídas esperadas. Na fase de teste, dada uma nova entrada, é estimada uma saída a partir dos pesos das sinapses aprendidos durante a fase de treinamento. Redes *MLP* possuem uma fase de treinamento lenta, devido ao processo iterativo de ajuste de pesos das sinapses, mas uma fase de teste rápida.

No preditor MLP, é utilizada 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, é adotada uma função de ativação tangente hiperbólica e, na camada de saída, uma função de ativação linear. No treinamento, o algoritmo de retro-propagação do erro (*backpropagation*) *Stochastic Gradient Descent* (SGD) (LECUN et al., 2012) é empregado, 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 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.

3.2.3 Preditor Neural Baseado em Redes Neurais Sem Peso do Tipo *Virtual Generalizing Random Access Memory* (VG-RAM)

Nesta seção é apresentado o segundo preditor neural avaliado e 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 neurais *MLP*, nas quais o conhecimento é armazenado na forma de pesos de sinapses, em redes neurais sem peso VG-RAM, conhecimento é armazenado nas memórias dos neurônios da rede. Na fase de treinamento das redes VG-RAM, para cada par entrada e saída do conjunto de treinamento, cada neurônio coleta um padrão de bits da entrada por meio de suas sinapses e armazena em sua memória o padrão de bits coletado e a saída associada. Na fase de teste, dada uma nova entrada, as memórias dos neurônios são consultadas, comparando a nova entrada com todos os padrões de bits armazenados na fase de treinamento. A saída estimada por cada neurônio é dada pela saída associada ao padrão mais próximo à nova entrada; a função de distância empregada é a distância de Hamming. A saída estimada pela

rede é dada pela média da saída estimada pelos neurônios. As redes VG-RAM possuem uma fase de treinamento rápida, pois ela pode ser feita em apenas um passo, bem como uma fase de teste rápida. De fato, trabalhos anteriores avaliaram o desempenho de redes VG-RAM em aplicações para reconhecimento de faces (DE SOUZA et al., 2008), categorização de texto (BADUE et al., 2008), estimativa de profundidade usando visão estéreo (VERONESE et al., 2012), detecção (BERGER et al., 2012) e reconhecimento de placas de trânsito (DE SOUZA et al., 2013), mapeamento e localização de carros autônomos (LYRIO et al., 2015). Nesses trabalhos anteriores, os resultados experimentais mostraram que redes VG-RAM são ferramentas de aprendizado de máquina efetivas e que oferecem implementação simples, e treinamento e teste rápidos.

Neste trabalho, o número de neurônios e o número de sinapses por neurônio da arquitetura da rede VG-RAM utilizada pelo preditor neural foram encontrados empiricamente para cada escala de tempo de interesse e serão apresentados em uma próxima seção. 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.

4 METODOLOGIA EXPERIMENTAL

Neste capítulo, é apresentada a metodologia experimental utilizada para avaliar o desempenho do sistema automático de investimento. Na Seção 4.1, é descrita a *Intelligent Trading Architecture* (ITA) utilizada para coletar a base de dados junto à BM&FBovespa. Na Seção 4.2, são descritos a API Keras e o *framework* TensorFlow utilizados na implementação das redes neurais *MLP* e, na Seção 4.3, a Máquina Associadora de Eventos (MAE) utilizada na implementação das redes neurais sem peso VG-RAM. Na Seção 4.4, é descrito um sumário das implementações. Por fim, na Seção 4.5, é descrita a base de dados coletada e, na Seção 4.6, as métricas utilizadas para avaliar o desempenho do sistema automático de investimento.

4.1 *Intelligent Trading Architecture* (ITA)

A base de dados utilizada neste trabalho foi obtida com o auxílio do *framework Intelligent Trading Architecture* (ITA) (FREITAS et al., 2016). ITA é um *framework* para a implementação de *trading systems* que tem como ideia central separar o problema completo de *trading* em bolsas de valores em tarefas mais simples, realizadas por módulos sob uma coordenação central.

A implementação do ITA utiliza o *framework* de código aberto CARMEN (MONTEMERLO et al., 2003). CARMEN utiliza o mecanismo de comunicação *Inter Process Communication* (IPC) (SIMMONS e JAMES, 2001) que é essencialmente um mecanismo de comunicação *publish/subscribe* em que processos (módulos) indicam interesse em receber mensagens de um certo tipo (*subscribe*) e quando outros processos (módulos) publicam (*publish*) essas mensagens os *subscribers* recebem uma cópia da mensagem.

ITA pode ser decomposta em quatro grandes núcleos (*cores*), sendo eles o *market core*, *data core*, *strategy core* e o *planning core*. O *market core* se refere aos módulos de interface com as bolsas de valores e as corretoras, eles são

responsáveis por receber dados das bolsas de valores e enviar ordens de compra e venda às corretoras. As corretoras são responsáveis por rotear as ordens para a Bolsa de valores. O *data core* se refere a bibliotecas de código e módulos responsáveis por organizar e manter estruturas de dados e os bancos de dados internos do ITA. O *strategy core* se refere aos módulos que implementam as estratégias de investimentos e tomadas de decisão. Finalmente, o *planning core* se refere aos módulos responsáveis pelo planejamento e avaliação dos investimentos. Para a obtenção da base de dados foram utilizados o *market core* para receber os dados dos 4 ativos de interesse da BM&FBovespa, o *data core* para montar e organizar os dados recebidos e o *strategy core* para amostrar e salvar os dados de interesse. O *planning core* não foi utilizado no processo de aquisição dos dados.

4.2 Keras e TensorFlow

O preditor neural baseado em redes neurais *MLP* foi desenvolvido com o auxílio da API de alto nível de código aberto para redes neurais Keras (KERAS, 2018). Keras foi inicialmente desenvolvido como parte do projeto *Open-ended Neuro-Electronic Intelligent Robot Operating System* (ONEIROS) e é desenvolvida na linguagem de programação Python. Keras é capaz de funcionar com os *frameworks* TensorFlow (TENSORFLOW, 2018), CNTK (CNTK, 2018) e Theano (THEANO, 2018). Neste trabalho foi utilizado Keras junto com o *framework* TensorFlow.

TensorFlow é um *framework* de código aberto para computação de grafos de fluxo de dados (*data flow graphs*). Os nós do grafo representam operações matemáticas, enquanto que, as arestas representam os vetores multidimensionais de dados (tensores ou *tensors*) que fluem entre eles. TensorFlow foi originalmente desenvolvido por pesquisadores e engenheiros da equipe do Google Brain para a realização de pesquisas em aprendizado de máquina (*Machine Learning*) e em redes neurais profundas (*Deep Learning*). Entretanto, TensorFlow é geral o suficiente para ser aplicado em uma ampla variedade de outros domínios (TENSORFLOW, 2018).

Para a implementação do preditor neural baseado em redes neurais MLP. A API Keras foi utilizada junto com o *framework* TensorFlow. A utilização do Keras permitiu que a complexidade do *framework* TensorFlow ficasse transparente ao ponto que o *framework* TensorFlow pudesse ser substituído por um dos *frameworks* CNTK ou Theano sem prejuízo ao código do preditor neural baseado em redes neurais MLP utilizado neste trabalho.

4.3 Máquina Associadora de Eventos (MAE)

O preditor baseado em redes neurais sem peso do tipo VG-RAM foi desenvolvido com o auxílio do *framework* de código aberto Máquina Associadora de Eventos (MAE) (MAE, 2018). O *framework* MAE foi desenvolvido pelo grupo de pesquisa em Ciência da Cognição do Laboratório de Computação de Alto Desempenho (LCAD/UFES).

MAE pode ser decomposta em duas partes. A primeira delas é o **netcomp**, programa que recebe como entrada a descrição da arquitetura da rede neural, em forma de arquivo com extensão `.con`, e gera como saída código C (`.c`) correspondente a descrição da arquitetura da rede neural. A segunda parte é formada pelas bibliotecas de código MAE.

Para a implementação do preditor neural baseado em redes neurais sem peso do tipo VG-RAM um arquivo `.con` contendo a descrição da arquitetura da rede neural (ver Tabela 3 Seção 5.2) foi gerado. Essa descrição foi então convertida para código C com a utilização do programa MAE **netcomp**. A saída do **netcomp** junto com as bibliotecas de código MAE foram utilizadas para implementação do preditor neural baseado em redes neurais sem peso do tipo VG-RAM.

4.4 Implementação

Para o desenvolvimento deste trabalho foram desenvolvidos os programas listados abaixo e apresentados na Figura 4:

- **Coletador de Dados:** Programa desenvolvido como um módulo no *framework* ITA. Este programa foi o responsável por coletar a base de dados utilizada neste trabalho e salva-la em forma de arquivo texto separado por vírgulas (CSV).
- **Preditor Oráculo:** Programa desenvolvido na linguagem de programação Python para estimar o máximo de retorno possível nas escalas de tempo consideradas.
- **Sistema Automático de Investimentos Baseado em Preditor do Tipo MLP:** Programa desenvolvido em linguagem de programação Python com auxílio da API Keras. Este programa implementa toda a lógica do sistema automático de investimentos baseado em preditores de retorno para o preditor neural com redes neurais MLP.
- **Sistema Automático de Investimentos Baseado em Preditor do Tipo VG-RAM:** Programa desenvolvido como um exemplo do *framework* MAE. Este programa implementa toda a lógica do sistema automático de investimento baseado em preditores de retorno para o preditor neural com redes neurais sem peso do tipo VG-RAM. Este código foi desenvolvido em linguagem de programação C.
- **Analisador de Dados:** Programa desenvolvido em MATLAB (MATLAB, 2018) para analisar a base de dados utilizada neste trabalho quanto ao seu nível de randomicidade.

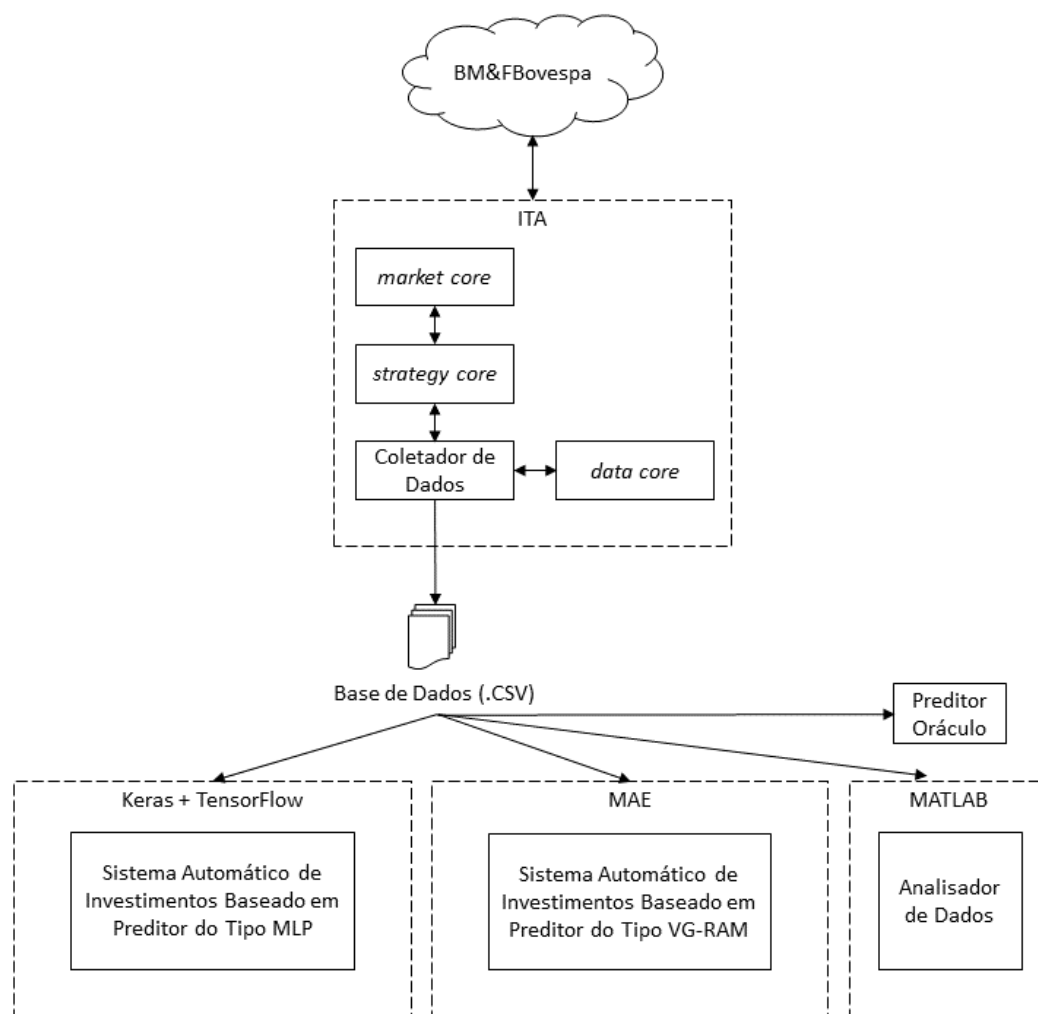


Figura 4 – Diagrama das implementações.

4.5 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) 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 oferta foram coletados a cada segundo, entre 9 horas da manhã e 17 horas e 55 minutos da tarde (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 dias de dados.

A fim de usar apenas uma série de cotações por ativo, o valor médio entre a melhor oferta de compra e a melhor oferta de venda é computado. 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), são considerados 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 30 primeiros dias e usado para ajustar os parâmetros do sistema, e um conjunto de teste, composto pelos 10 últimos dias e usado unicamente na avaliação do desempenho do sistema.

4.6 Métricas

Para avaliar individualmente os preditores as métricas HR , HR^+ e HR^- , as quais medem o percentual de estimativas nas quais os sinais dos retornos esperados e retornos estimados coincidem foram utilizadas. A métrica HR mede o percentual de estimativas nas quais ambos os retornos têm o mesmo sinal e são diferentes de zero; a métrica HR^+ mede o percentual de estimativas nas quais ambos os retornos são positivos; e a métrica HR^- mede o percentual de estimativas nas quais ambos os retornos são negativos. As métricas HR , HR^+ e HR^- são dadas pela, Equação 4, Equação 5 e Equação 6, respectivamente,

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

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

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

Equação 6

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

5 RESULTADOS EXPERIMENTAIS

Neste capítulo, são apresentados os resultados dos experimentos realizados para avaliar o desempenho do sistema automático de investimento. Na Seção 5.1, são descritos os resultados da avaliação do limite superior de retornos usando o preditor oráculo. Na Seção 5.2, são descritos os resultados da comparação do desempenho dos preditores MLP e VG-RAM. Na Seção 5.3, são descritos os resultados da avaliação da taxa de acerto do preditor VG-RAM. Por fim, na Seção 5.4, são descritos os resultados da avaliação das séries das cotações dos ativos. Para realização do experimento 5.1, foi considerado o dia completo, ou seja, entre 9:30h e 17:30h e não houve etapa de treinamento. Para os demais experimentos, a hora h foi 13:30h.

5.1 Avaliação do Limite Superior de Retornos Usando o Preditor Oráculo

No primeiro experimento, foi avaliado o limite superior de retornos que podem ser gerados pelo sistema de investimento usando um preditor oráculo. Nessa avaliação, foi utilizado o conjunto de treinamento da base de dados. Neste e nos próximos experimentos, são considerados os ativos WIN, IND, WDO e DOL e as escalas de tempo $t = 32s$, $t = 64s$, $t = 128s$ e $t = 256s$ de interesse. Numa dada escala de tempo t , as cotações dos ativos são amostradas a cada t segundos.

A Figura 5(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 avaliado.




Figura 5 – (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.

Como a Figura 5(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 (isto é, 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.

O gráfico da Figura 5(b) apresenta a média do percentual de retorno por operação para cada ativo e escala de tempo considerados. Os resultados da Figura 5(b) mostram que o retorno médio por operação aumenta com a escala de tempo; isso ocorre porque podem ocorrer maiores variações das cotações em escalas de tempo maiores. Contudo, isso parece contradizer os resultados mostrados na Figura 5(a). A Figura 5(c) permite esclarecer esta 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 5(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 5(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 5(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 do preditores neurais em detectá-las (ver Seção 5.3).

5.2 Comparação do Desempenho dos Preditores MLP e VG-RAM

No segundo experimento, os parâmetros ótimos da arquitetura do preditor VG-RAM foram ajustados empiricamente usando a base de treinamento de modo a maximizar a métrica *HR* (ver Seção 4.6) para as escalas de tempo de interesse. Para isso, foi feita uma busca em grade dos melhores parâmetros do número de neurônios $nn = \{1, 3, 5, 9, 17, 33\}$, do número de sinapses $ns = \{32, 64, 128, 256\}$ e do tamanho da janela de entrada $w = \{5, 10, 15, 20\}$. As Figura 6, Figura 7, Figura 8 e Figura 9

mostram o processo de escolha dos melhores parâmetros para as escalas de tempo de interesse. A Tabela 3 apresenta os parâmetros ótimos da arquitetura do preditor VG-RAM (DE SOUZA et al., 2012). Os parâmetros da rede MLP foram os mesmos de Santana et al. (2016).

Tabela 3 - Parâmetros ótimos da arquitetura do preditor VG-RAM para as escalas de tempo de interesse, t . nn é o número de neurônios, ns é o número de sinapses por neurônio e w é o tamanho da janela de entrada (ALEKSANDER, 1998) (DE SOUZA et al., 2012).

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







Figura 6 – Ajuste de parâmetros preditor VG-RAM 32 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w .



(a)




(b)




(c)


Figura 7 – Ajuste de parâmetros predictor VG-RAM 64 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w .



(a)




(b)




(c)


Figura 8 – Ajuste de parâmetros preditor VG-RAM 128 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w .



(a)



(b)



(c)

Figura 9 – Ajuste de parâmetros predictor VG-RAM 256 segundos, (a) variando o número de neurônios nn , (b) com nn fixo e variando o número de sinapses ns e (c) com nn e ns fixo e variado o tamanho da janela de entrada w .

De posse dos parâmetros ótimos da rede VG-RAM, foram comparados 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 médio *HR* dos preditores MLP e VG-RAM.

<i>t</i> (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

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.

Os testes de desempenho foram realizados em uma máquina Ubuntu 14.04 LTS com processador Intel Core i7-4770 3.40GHz x 8 e 16GB (4 x 4GB) de memória RAM DDR3 1600MHz.

Tabela 5 – Tempo médio de treinamento dos preditores MLP e VG-RAM nas duas etapas de operação do sistema de investimento para as escalas de interesse, t .

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}

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 $t = 256$ s e o pior foi 0,58s na escala de tempo $t = 32$ s. Para o preditor VG-RAM, o tempo médio diário de treinamento nas duas etapas de operação do sistema foi 22×10^{-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. Além disso, o tempo de processamento de ordens, isto é, a latência do envio das ordens de compra e venda pela ITA é de 50×10^{-3} s o que permite operação em alta frequência, na ordem de segundos. Como o desempenho HR dos preditores VG-RAM é no geral melhor que os dos preditores MLP e o tempo de treinamento do preditor VG-RAM é significativamente menor do que o do preditor MLP, a seguir são apresentados apenas resultados experimentais do preditor VG-RAM.

5.3 Avaliação da Taxa de Acerto do Preditor VG-RAM

No terceiro experimento foi avaliado o desempenho do preditor neural baseado na rede VG-RAM em termos da taxa de acerto (Tabela 6) do sinal do retorno (HR , HR^+ e HR^-). Também foi avaliado o desempenho financeiro (Tabela 7) do sistema de investimento usando o preditor VG-RAM e usando este preditor e um novo critério de decisão (Tabela 9) de investimento baseado no seu desempenho passado de predição. Nestes experimentos foi usado o conjunto de teste da base de dados.

A Tabela 6 apresenta os desempenhos dos preditores VG-RAM em termos das métricas HR . Estes desempenhos são similares aos 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 dificuldade 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 $t = 128s$.

Tabela 6 – Desempenho médio do preditor VG-RAM em termos da métrica *HR*.

Configuração		Desempenho <i>HR</i>		
<i>t</i> (segundos)	Ativo	<i>HR</i> (%)	<i>HR</i> ⁺ (%)	<i>HR</i> ⁻ (%)
32	WIN	63,88	13,63	87,32
	IND	70,72	8,49	92,49
	WDO	58,80	23,19	78,59
	DOL	55,35	29,42	72,39
64	WIN	55,87	30,58	72,22
	IND	60,82	24,48	80,00
	WDO	52,05	30,98	66,22
	DOL	50,88	37,39	60,83
128	WIN	52,74	42,68	60,48
	IND	53,27	34,92	65,28
	WDO	50,76	40,38	58,56
	DOL	49,51	44,09	54,04
256	WIN	51,07	43,64	58,25
	IND	50,00	36,80	60,65
	WDO	49,29	35,71	59,32
	DOL	50,00	41,63	56,51

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 Tabela 7 apresenta o desempenho do sistema segundo essas métricas para os ativos e escalas de tempo de interesse. Como a coluna *roc* mostra, não foram obtidos resultados positivos em nenhuma das configurações examinadas.

Tabela 7 – Desempenho financeiro médio do sistema de investimento 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*.

Configuração		Desempenho Financeiro		
<i>t</i> (segundos)	Ativo	<i>roc</i> (%)	<i>no</i>	<i>ppo</i> (%)
32	WIN	-2,47	57,20	33,4
	IND	-1,97	34,20	28,4
	WDO	-1,94	97,10	37,6
	DOL	-4,25	124,80	41,2
64	WIN	-2,33	64,20	41,6
	IND	-2,73	47,90	39,2
	WDO	-2,46	72,60	38,2
	DOL	-3,22	85,40	41,3
128	WIN	-1,84	45,60	45,4
	IND	-2,93	38,80	39,7
	WDO	-1,70	45,70	42,2
	DOL	-2,19	50,30	44,5
256	WIN	-1,07	23,90	50,2
	IND	-1,73	21,40	43,0
	WDO	-1,89	21,60	39,4
	DOL	-1,68	23,90	42,7

A fim de melhorar a qualidade das decisões de compra e venda tomadas pelo sistema de investimento, foi desenvolvido 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,

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

na qual npr é o número de vezes no passado recente em que o preditor VG-RAM fez uma predição positiva e ocorreu um retorno positivo; nnr é o número de vezes em que o preditor VG-RAM realizou uma predição positiva mas ocorreu um retorno negativo; e nzs é o número de vezes em que o preditor VG-RAM realizou uma predição positiva mas ocorreu um retorno neutro (zero). A Tabela 8 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 8 - Parâmetros ótimos do novo critério de decisão para as escalas de tempo de interesse.

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

Tabela 9 – Desempenho médio do sistema de investimento com o novo critério de decisão.

Configuração		Desempenho Financeiro com Critério de decisão		
<i>t</i> (segundos)	Ativo	<i>roc</i> (%)	<i>no</i>	<i>ppo</i> (%)
32	WIN	-0,15	5,80	32,8
	IND	-0,14	3,80	34,2
	WDO	-0,20	5,20	28,8
	DOL	-0,18	7,00	48,6
64	WIN	-0,06	2,50	40,0
	IND	-0,21	3,30	33,3
	WDO	-0,14	1,30	15,4
	DOL	-0,05	2,00	45,0
128	WIN	0,06	1,30	46,2
	IND	-0,14	1,50	46,7
	WDO	-0,11	1,50	33,3
	DOL	-0,01	1,20	41,7
256	WIN	-0,31	1,50	40,0
	IND	-0,22	1,30	38,5
	WDO	-0,01	0,50	20,0
	DOL	-0,22	0,50	20,0

A Tabela 9 apresenta o desempenho do sistema de investimento com o novo critério de decisão para os ativos e escalas de tempo de interesse, *t*. 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 com o novo critério de decisão gerou percentual positivo de retorno

sobre o capital disponível para o ativo WIN na escala de tempo $t = 128$ s. Finalmente, pode ser notado que o sistema de investimento com o novo critério de decisão gerou percentuais superiores de operações positivas, *ppo*, para os ativos IND e DOL na escala de tempo $t = 32$ s, ativo DOL na escala de tempo $t = 64$ s e ativos WIN e IND na escala de tempo $t = 128$ s. 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 5(a) e comparar o desempenho para a configuração 128s e WIN).

5.4 Avaliação das Séries das Cotações dos Ativos

A fim de elucidar a razão pela qual o preditor VG-RAM teve dificuldades de detectar oportunidades de investimento, foi avaliado o quão randômicas, logo difíceis de prever, são as séries das cotações dos ativos. Nessa avaliação, toda a base de dados foi utilizada.

A Hipótese de Mercados Eficientes (HME) em sua forma fraca 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 das cotações passadas para obter retornos extraordinários (FAMA, 1970) (FAMA, 1991). 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, logo análises puramente técnicas não seriam eficazes. 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, foi verificado 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). Por exemplo, ele verifica se a variância da série das cotações de um ativo na escala de tempo $t = 32s$ é 32 vezes maior do que a variância da série das cotações desse ativo na escala de tempo $t = 1s$.

Foi avaliado inicialmente as séries como um todo e, para cada ativo, foi considerado as séries das cotações dos diferentes dias (40 dias no total) como sendo uma única série das cotações. Os resultados da avaliação mostraram que o VRT falhou em rejeitar a hipótese nula, no nível de significância de 5% de que a série das cotações é uma série *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*).

Foi avaliado 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 10 apresenta o resultado desta avaliação.

Tabela 10 – Percentual de dias nos quais as séries das cotações dos ativos 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 10 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 $t = 256$ s). O único ativo com menos de 50% dos dias caracterizados como *random-walk* foi o WDO (32,5% dos dias na escala de tempo $t = 32$ s e 45,0% dos dias na escala de tempo $t = 64$ s). Portanto, os resultados mostram que o mercado futuro brasileiro é eficiente na maior parte dos dias, sendo essa uma das razões que podem explicar a dificuldade do preditor VG-RAM em detectar mais oportunidades de investimento.

6 CONCLUSÃO E TRABALHO FUTURO

Este capítulo apresenta conclusões e direções para trabalhos futuros. A Seção 6.1 apresenta uma pequena síntese deste trabalho, a Seção 6.2 traz as conclusões e, por fim, a Seção 6.3 cita sugestões para trabalhos futuros.

6.1 Sumário

A previsão das cotações de ativos financeiros em bolsas de valores sempre foi alvo de grande interesse por parte de investidores. Pois, aqueles que conseguem prever cotações futuras podem obter grandes retornos financeiros. Apesar disso, há uma grande discussão, e controvérsia, acerca da previsibilidade das cotações de ativos financeiros em bolsas de valores. E essa discussão tem um marco fundamental na Hipótese dos Mercados Eficientes (HME) que em sua forma fraca, implica que nenhum investidor pode elaborar uma regra de negociação baseada exclusivamente em padrões de cotações passadas para obter retornos extraordinários. Apesar disso, 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.

Neste trabalho, foram avaliadas as 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 preditores neurais. Inicialmente, foi avaliado o limite superior de retorno que pode ser gerado pelo sistema de investimento usando um preditor oráculo. Em seguida, foram realizados dois experimentos acerca do desempenho dos preditores neurais avaliados. Por fim, foi realizada uma análise da randomicidade das séries das cotações dos ativos de interesse.

6.2 Conclusão

Neste trabalho, foi desenvolvido um sistema automático de investimento baseado em preditores de retornos. Em seguida, foram realizados quatro experimentos utilizando dados de quatro ativos de interesse do mercado futuro brasileiro e em quatro escalas de tempo de dezenas de segundos.

No primeiro experimento, foi avaliado o limite superior de retorno que pode ser gerado pelo sistema de investimento usando um preditor oráculo. Os resultados desse experimento mostraram que: (i) se o preditor for capaz de estimar com precisão os retornos de ativos, então é possível obter diariamente grandes retornos para todos os ativos e escalas de tempo analisadas; e (ii) as operações positivas não são muito frequentes.

No segundo experimento, foram comparados os desempenhos dos preditores neurais baseados nas redes MLP e VG-RAM em termos de *HR* e do tempo de treinamento. Os resultados desse experimento mostraram que: (i) a rede VG-RAM apresentou desempenho *HR* melhor na maioria dos casos e (ii) o treinamento do preditor VG-RAM é pelo menos mil vezes mais rápido do que o do preditor MLP.

No terceiro experimento, foi avaliado o desempenho do preditor neural baseado na rede VG-RAM em termos da taxa de acerto do sinal do retorno de um ativo. Foi avaliado também o desempenho do sistema de investimento usando o preditor VG-RAM e um novo critério de decisão em termos do percentual de retorno sobre o capital disponível e 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 e percentuais de operações positivas em alguns ativos e escalas de tempo.

Finalmente, no quarto experimento, foi avaliado 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.

6.3 Trabalho Futuro

Uma sugestão para trabalho futuro seria investigar classificadores capazes de detectar em que momentos séries de ativos se comportam ou não como séries *random-walk*. Com tal classificador, seria possível se beneficiar de momentos em que séries de cotações de ativos do mercado futuro são mais previsíveis. Outra sugestão para trabalho futuro seria 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. Ainda outra sugestão para pesquisa futura seria analisar, juntamente com dados históricos de ativos, dados de notícias e redes sociais (*sentiment analysis*), a fim de realizar uma fusão da análise fundamentalista com a análise técnica.

7 PUBLICAÇÕES

Durante o Mestrado em Informática um artigo diretamente relacionado a este trabalho de pesquisa foi publicado:

- NASCIMENTO, Rafael C.; BADUE, Claudine; OLIVEIRA-SANTOS, Thiago; DE SOUZA, Alberto F.; MUTZ, Filipe; FREITAS, Fábio D.; FREITAS, Christian D. Avaliação de oportunidades de investimentos no mercado futuro brasileiro na escala de dezenas de segundos. In: XLIX SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL (SBPO), 2017, Blumenau. **Anais do XLIX SBPO**. Blumenau: SOBRAPO, 2017; p. 1226-1237.

8 REFERÊNCIAS BIBLIOGRÁFICAS

ALEKSANDER, Igor. From WISARD to MAGNUS: A family of weightless virtual neural machines. In: **RAM-Based Neural Networks**. 1998. p. 18-30.

ARAÚJO, Ricardo De A.; FERREIRA, Tiago A. E. A morphological-rank-linear evolutionary method for stock market prediction. **Information Sciences**, v. 237, p. 3-17, 10 jul. 2013.

BADUE, Claudine; PEDRONI, Felipe; DE SOUZA, Alberto F. Multi-label text categorization using VG-RAM weightless neural networks. In: 10TH BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS (SBRN), 2008, Salvador. **10th Brazilian Symposium on Neural Networks**. Salvador: IEEE, 2008. p. 105-110.

BERGER, Mariella; FORECHI, Avelino; DE SOUZA, Alberto F.; NETO, Jorcy De O.; VEROSNESE, Lucas De P.; BADUE, Claudine. Traffic sign recognition with VG-RAM weightless neural networks. In: 12TH INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS DESIGN AND APPLICATIONS (IDSA), 2012, Kochi. **12th International Conference on Intelligent Systems Design and Applications**. Kochi: IEEE, 2012. p. 315-319.

BM&FBOVESPA1: Futuro de Ibovespa. Disponível em: <http://www.bmfbovespa.com.br/pt_br/produtos/listados-a-vista-e-derivativos/renda-variavel/futuro-de-ibovespa.htm>. Acesso em: 11 abr. 2017.

BM&FBOVESPA2: Futuro de taxa de câmbio de reais por dólar comercial. Disponível em: <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>. Acesso em: 11 abr. 2017.

CAMPBELL, John Y.; LO, Andrew W.; MACKINLAY, Archie C. **The Econometrics of Financial Markets**. Princeton: Princeton University Press, 1997.

CNTK: Microsoft Cognitive Toolkit. Disponível em:

<<https://github.com/Microsoft/cntk>>. Acesso em: 27 jan. 2018.

DE SOUZA, Alberto F.; BADUE, Claudine; PEDRONI, Felipe; OLIVEIRA, Elias; DIAS, Stiven S.; OLIVEIRA, Hallysson; DE SOUZA, Soteiro F. Face recognition with VG-RAM weightless neural networks. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS (ICANN), 2008, Heidelberg. **Lecture Notes in Computer Science**, vol. 5163. Heidelberg: Springer, 2008. p. 951-960.

DE SOUZA, Alberto F.; FONTANA, Cayo; MUTZ, Filipe; DE OLIVEIRA, Tiago A.; BERGER, Mariella; FORECHI, Avelino; NETO, Jorcy De O.; DE AGUIAR, Edilson; BADUE, Claudine. Traffic sign detection with VG-RAM weightless neural networks. In: THE 2013 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2013, Dallas. **The 2013 International Joint Conference on Neural Networks**. Dallas: IEEE, 2013. p. 1-9.

DE SOUZA, Alberto F.; FREITAS, Fábio D.; DE ALMEIDA, André Gustavo C. Fast learning and predicting of stock returns with virtual generalized random access memory weightless neural networks. **Concurrency and Computation: Practice and Experience**, v. 24, n. 8, p. 921-933, 10 jun. 2012.

FAMA, Eugene F. Efficient capital markets: A review of theory and empirical work. **The Journal of Finance**, v. 25, n. 2, p. 383-417, mai. 1970.

FAMA, Eugene F. Efficient capital markets: II. **The Journal of Finance**, v. 46, n. 5, p. 1575-1617, dez. 1991.

FERREIRA, Tiago A. E.; VASCONCELOS, Germano C.; ADEODATO, Paulo J. L. A new intelligent system methodology for time series forecasting with artificial neural networks. **Neural Processing Letters**, v. 28, n. 2, p. 113-129, out. 2008.

FREITAS, Fábio D.; FREITAS, Christian D.; DE SOUZA, Alberto F. Intelligent trading architecture. **Concurrency and Computation: Practice and Experience**, v. 28, n. 3, p. 929-943, 10 mar. 2016.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2ª Ed. Porto Alegre:

Bookman, 2007.

HELLSTROM, Thomas. Data snooping in the stock market. **Theory of Stochastic Processes**, v. 5, n. 21, p. 33-50, out. 1999.

KEARNS, Michael; KULESZA, Alex; NEVMYVAKA, Yuriy. Empirical limitations on high frequency trading profitability. **arXiv preprint arXiv:1007.2593v2**, set. 2010.

KERAS: Deep Learning for humans. Disponível em: <<https://github.com/keras-team/keras>>. Acesso em: 27 jan. 2018.

KONAR, Amit; BHATTACHARYA, Diptendu. Learning structures in an economic time-series for forecasting applications. **Time-Series Prediction and Applications**. 1ª Ed. Cham: Springer, 2017.

LECUN, Yann; BOTTOU, Leon; ORR, Genevieve B.; MULLER, Klaus-Robert. Efficient BackProp. In: **Neural Networks: Tricks of the Trade**. Heidelberg: Springer, 1998. p. 9-50.

LIU, Feng.; NG, Geok S.; QUEK, Chai. RLDDE: A novel reinforcement learning-based dimension and delay estimator for neural networks in time series prediction. **Neurocomputing**, v. 70, n. 7-9, p. 1331-1341, mar. 2007.

LYRIO, Lauro J.; OLIVEIRA-SANTOS, Thiago; BADUE, Claudine; DE SOUZA, Alberto F. Image-based mapping, global localization and position tracking using VG-RAM weightless neural networks. In: 2015 IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2015, Seattle. **2015 IEEE International Conference on Robotics and Automation**. Seattle: IEEE, 2015. p. 3603-3610.

MAE: Máquina Associadora de Eventos. Disponível em: <http://www.lcad.inf.ufes.br/wiki/index.php/M%C3%A1quina_Associadora_de_Eventos_-_MAE>. Acesso em: 27 jan. 2018.

MATLAB. Disponível em: <<https://www.mathworks.com/products/matlab.html>>. Acesso em: 27 jan. 2018.

MONTEMERLO, Michael; ROY, Nicholas; THRUN, Sebastian. Perspectives on standardization in mobile robot programming: The Carnegie Mellon navigation (CARMEN) toolkit. In: 2003 IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS (IROS), 2003, Las Vegas. **Proceedings. 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems.** Las Vegas: IEEE, 2003. v. 3, pp. 2436-2441.

PARANÁ, Edemilson. **A Finança Digitalizada: Capitalismo Financeiro e Revolução Informacional.** Florianópolis: Insular, 2016.

RITTER, Jay R. Behavioral finance. **Pacific-Basin Finance Journal**, v. 11, n. 4, p. 429-437, set. 2003.

SANTANA, Renato. E.; DANTAS, Maria José. P.; LOIOLA Rafael. G. Aplicação de redes neurais para a predição no mercado de ações nacional. In: XLVIII SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL (SBPO), 2016, Vitória. **Anais do XLVIII SBPO.** Vitória: SOBRAPO, 2016; p. 1188–1199.

SIMMONS, Reid; JAMES, Dale. **Inter-Process Communication: A Reference Manual.** Pittsburgh: Robotics Institute, Carnegie Mellon University, 2011.

SITTE, Renate; SITTE, Joaquin. Neural networks approach to the random walk dilemma of financial time series. **Applied Intelligence**, v. 16, n. 3, p. 163-171, 2002.

TENSORFLOW. Disponível em: <<https://github.com/tensorflow/tensorflow>>. Acesso em: 27 jan. 2018.

THEANO. Disponível em: <<https://github.com/Theano/Theano>>. Acesso em: 27 jan. 2018.

VERONESE, Lucas De P.; LYRIO, Lauro J.; MUTZ, Filipe; NETO, Jorcy De O.; AZEVEDO, Vitor B.; BERGER, Mariella; DE SOUZA, Alberto F.; BADUE, Claudine.

Stereo matching with VG-RAM weightless neural networks. In: 12TH INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS DESIGN AND APPLICATIONS (IDSA), 2012, Kochi. **12th International Conference on Intelligent Systems Design and Applications**. Kochi: IEEE, 2012. p. 309-314.

XP INVESTIMENTOS: Futuros – Commodities agrícolas e financeiras para você investir. Disponível em: <<https://www.xpi.com.br/investimentos/futuros/>>. Acesso em: 11 abr. 2017.