

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
MESTRADO EM INFORMÁTICA**

ANDRÉ GUSTAVO COELHO DE ALMEIDA

**PREDITOR DE ALTO DESEMPENHO PARA RETORNOS
DE AÇÕES BASEADO EM REDES NEURAIS SEM PESO**

Vitória – ES
2011

ANDRÉ GUSTAVO COELHO DE ALMEIDA

**PREDITOR DE ALTO DESEMPENHO PARA RETORNOS
DE AÇÕES BASEADO EM REDES NEURAIIS SEM PESO**

Dissertação apresentada ao Mestrado em Informática do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Mestre em Informática.

Orientador: Prof. Dr. Alberto Ferreira De Souza.

Co-orientador: Dr. Fábio Daros de Freitas

Vitória – ES
2011

ANDRÉ GUSTAVO COELHO DE ALMEIDA

PREDITOR DE ALTO DESEMPENHO PARA RETORNOS DE AÇÕES BASEADO EM REDES NEURAIS SEM PESO

Dissertação apresentada ao Mestrado em Informática do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Mestre em Informática.

Aprovada em 30 de agosto de 2011.

COMISSÃO EXAMINADORA

Prof. Dr. Aberto Ferreira De Souza
Universidade Federal do Espírito Santo
Orientador

Dr. Fábio Daros de Freitas
Receita Federal do Brasil
Co-orientador

Prof. Dra. Claudine Santos Badue Gonçalves
Universidade Federal do Espírito Santo

Prof. Dr. Felipe Maia Galvão França
Universidade Federal do Rio de Janeiro

Vitória – ES
2011

Para minha família.

AGRADECIMENTOS

Agradeço aos meus pais, José e Joana, e ao meu irmão Júlio Henrique, por representarem os pilares dos meus valores pessoais, e modelos nos quais me inspiro para continuar evoluindo enquanto indivíduo.

Agradeço ao professor Alberto Ferreira De Souza, por sua amizade e orientação, além da paciência e incentivo incansáveis, que tornaram possível o desenvolvimento deste trabalho. Agradeço também por todos os conselhos que recebi durante estes dois últimos anos de trabalho. Por fim, agradeço a oportunidade de conviver com um profissional dedicado e competente que além de ajudar minha formação acadêmica contribuiu muito para minha formação como cidadão e profissional.

Agradeço ao Fábio Freitas pela co-orientação, pelo seu apoio e pelo comprometimento na realização deste trabalho. Agradeço também por todas as ideias e sugestões que trocamos durante nossas reuniões.

Agradeço ao professor Elias de Oliveira pelas proveitosas discussões e preciosos aconselhamentos durante todo o período do mestrado.

Agradeço aos meus companheiros e amigos (Lucas, Jorcy, Vitor, Avelino, Mariella, Jairo, Nuno, Tommir, Vicente, Beto, Gustavo, Filipe, Rafael, Jader, Maikon e Erick) do Laboratório de Computação de Alto Desempenho (LCAD) pela ajuda no desenvolvimento deste trabalho e pelas discussões sobre algoritmos, tecnologia, *startups*, vida, política, economia, entre outros.

Agradeço a minha namorada, Fernanda Guzzo, pela paciência, incentivo incansável e ajuda no desenvolvimento deste trabalho.

Agradeço aos amigos da Chemtech, em especial o Márcio Andrade e o Lucas Sampaio, por resolver os problemas quando não podia estar presente no escritório e por todas as palavras de incentivo e motivação para conclusão deste trabalho.

SUMÁRIO

PUBLICAÇÕES DERIVADAS DESTE TRABALHO DE PESQUISA.....	7
LISTA DE FIGURAS	8
LISTA DE TABELAS	9
LISTA DE ABREVIACÕES	10
RESUMO.....	11
ABSTRACT	12
1. INTRODUÇÃO.....	13
1.1. MOTIVAÇÕES	14
1.2. OBJETIVOS.....	15
1.3. CONTRIBUIÇÕES	15
1.4. ESTRUTURA DESTE TRABALHO	16
2. CONCEITOS FUNDAMENTAIS	17
2.1. MERCADO DE AÇÕES	17
2.2. SÉRIES TEMPORAIS	19
2.3. REDES NEURAI BIOLÓGICAS	20
2.4. REDES NEURAI ARTIFICIAIS	22
3. PREDIÇÃO DE RETORNOS DE AÇÕES	24
3.1. PREDIÇÃO NO MERCADO DE AÇÕES	24
3.2. PREDITOR ARNN	25
3.3. PREDITOR WNN VG-RAM.....	26
4. METODOLOGIA	32
4.1. BASE DE DADOS.....	32
4.2. MÉTRICAS.....	34
5. EXPERIMENTOS.....	38
5.1. PREDIÇÕES DO PREDITOR ARNN.....	38
5.2. CALIBRAÇÃO DO PREDITOR WNN VG-RAM	39
5.3. PREDIÇÕES DO PREDITOR WNN VG-RAM	44
5.4. RESULTADOS.....	45
5.5. NORMALIDADE DOS ERROS DE PREDIÇÃO	47
5.6. DESEMPENHO COMPUTACIONAL DO PREDITOR WNN VG-RAM	48
6. DISCUSSÃO	49
6.1. TRABALHOS CORRELATOS	49
6.2. ANÁLISE CRÍTICA DESTE TRABALHO DE PESQUISA	50
7. CONCLUSÃO.....	52
7.1. SUMÁRIO	52
7.2. TRABALHOS FUTUROS.....	53
REFERÊNCIAS BIBLIOGRÁFICAS	54

PUBLICAÇÕES DERIVADAS DESTE TRABALHO DE PESQUISA

De SOUZA, A. F.; FREITAS, F. D.; ALMEIDA, A. G. C. High performace prediction of stock Returns with VG-RAM weightless neural networks. *High Perfomace Computational Finance (WHPCF)*, 2010 *IEEE Workshop on*. New Orleans, LA, USA, 2010. p. 1-8. ISBN 978-1-4244-9062-2.

De SOUZA, A. F.; FREITAS, F. D.; ALMEIDA, A. G. C. Fast learning and predicting of stock returns with virtual generalized random access memory weightless neural networks. *Concurrency And Computation: Praticice and Experience*, John Wiley & Sons, Ltd, p. n/a-n/a, 2011. ISSN 1532-0634.

LISTA DE FIGURAS

Figura 1 - Representação de um neurônio biológico.....	20
Figura 2 - Esquema de uma sinapse.....	21
Figura 3 – Representação de um conjunto de retornos a partir de uma imagem.....	28
Figura 4 – Padrão de interconexão sináptica do preditor WNN VG-RAM.	29
Figura 5 – Diagrama esquemático do preditor WNN VG-RAM	30
Figura 6 – Janela deslizante utilizada para treinamento do preditor ARNN(4)	39
Figura 7 – Janela deslizante para calibração do preditor WNN VG-RAM	41
Figura 8 – Impacto dos parâmetros no desempenho do preditor WNN VG-RAM.....	42
Figura 9 – Janela deslizante para treino e teste do preditor WNN VG-RAM.....	44
Figura 10– Predições do preditores VG-RAM e ARNN(4) para as ações da PETROBRAS PN (PETR4)	47

LISTA DE TABELAS

Tabela 1 - Tabela de busca de um neurônio da WNN VG-RAM	26
Tabela 2 – Resultados do teste de <i>chi-square</i> para a base utilizada	33
Tabela 3 - Valores de máximo e mínimo da curtose e assimetria dos dados utilizados	33
Tabela 4 - Sentido da melhoria das métricas utilizadas.....	37
Tabela 5 – Resumo das previsões obtidas para as 46 ações	45
Tabela 6 – Análise da normalidade dos erros de previsão do preditor WNN VG-RAM.....	47
Tabela 7 – Análise da normalidade dos erros de previsão do preditor ARNN(4).....	48

LISTA DE ABREVIações

<i>WNN</i>	<i>Weightless Neural Network</i>
<i>ARNN</i>	<i>Autoregressive Neural Network</i>
<i>RAM</i>	<i>Random Access Memory</i>
<i>VG-RAM</i>	<i>Virtual Generalized Random Access Memory</i>
<i>ME</i>	<i>Mean Error</i>
<i>RMSE</i>	<i>Root Mean Square Error</i>
<i>MAPE</i>	<i>Mean Absolute Percentage Error</i>
<i>H_R</i>	<i>Hit Hate</i>

RESUMO

Este trabalho apresenta um novo preditor de séries temporais baseado em rede neural sem peso que utiliza *Virtual Generalized Random Access Memory*. Esta rede neural não armazena conhecimento em suas conexões, mas sim na memória RAM dos nós da rede, ou neurônios. Esse novo preditor foi avaliado na predição de retornos futuros semanais de 46 ações do mercado de ações brasileiro e comparado com preditores neurais autoregressivos baseados em redes neurais *feedforward* treinadas com o algoritmo *backpropagation*. Nossos resultados mostram que preditores neurais sem peso podem produzir previsões de retornos com os mesmos níveis de erros e propriedades dos preditores neurais autoregressivos, entretanto, executando 5.000 vezes mais rápido.

ABSTRACT

This work presents a new weightless neural network-based time series predictor that uses Virtual Generalized Random Access Memory weightless neural network, which does not store knowledge in their connections but in Random Access Memories (RAM) inside the network's nodes, or neurons. This new predictor was evaluated in predicting future weekly returns of 46 stocks from the Brazilian stock market and compared with neural autoregressive predictors based on feedforward neural networks trained with the backpropagation algorithm. Our results showed that weightless neural network-based predictors can produce predictions of future stock returns with the same error levels and properties of baseline autoregressive neural network predictors, however, running 5.000 times faster.

1. INTRODUÇÃO

A Bolsa de Valores é uma instituição que oferece as condições e sistemas necessários para a realização de negociação de compra e venda de títulos e valores mobiliários de forma transparente. É na Bolsa de Valores que são feitas as negociações de compra e venda de ações, que são títulos nominativos negociáveis que representam, para quem as possui, uma fração do capital social de uma empresa. As empresas que possuem ações negociadas na Bolsa de Valores são chamadas Companhias de Capital Aberto.

Para se investir em ações é necessário, inicialmente, escolher um intermediador, que é um agente (corretora, banco ou distribuidora) autorizado pela CVM (Comissão de Valores Mobiliários) a operar na Bolsa de Valores que efetuará as negociações desejadas.

Para escolher as ações, o investidor normalmente deve ponderar, dentre outros, três critérios: liquidez (facilidade de vender a ação quando quiser resgatar), retorno (possibilidade de ganhos) e risco (possíveis perdas). A combinação desses três elementos, a critério do investidor, definirá em quais ações aplicar.

Desde o trabalho pioneiro de White (1988), preditores baseados em redes neurais vêm sendo aplicados com sucesso na predição de retornos futuros de ações e de outras variáveis financeiras, exibindo muitas vantagens sobre métodos alternativos (SHARDA; PARTIL, 1992; MOODY, 1994; HANSEN; NELSON, 1997; FREITAS, De SOUZA; ALMEIDA, 2009).

A abordagem mais comum na literatura para preditores neurais de séries temporais é o preditor baseado em redes neurais autoregressivas (*Autoregressive Neural Network* — ARNN) (WHITE, 1988), também conhecidas como *Focused Time Lagged Feedforward Network* (HAYKIN, 1999). Estes preditores utilizam p entradas — o valor presente e os $p - 1$ valores passados de uma série — e produzem como saída uma estimativa do próximo valor da série. Após ter sido treinado, o preditor ARNN implementa um modelo regressivo não linear da série temporal, cujos coeficientes de regressão são dados pelos pesos da rede. Séries temporais complexas requerem sofisticados modelos de regressão que podem ser representados com escolhas apropriadas dos elementos topológicos da ARNN, como o número de camadas, de neurônios e as funções de transferências, somente para citar alguns.

O treinamento de um preditor ARNN é geralmente realizado com um algoritmo de gradiente descendente, como o algoritmo *backpropagation* (HAYKIN, 1999) e, em alguns casos especiais, com alternativas mais eficientes como o algoritmo de *Levenberg-Marquardt* (HAGAN; MENHAJ, 1994). Em ambos os casos, os algoritmos de treinamento são implementados com procedimentos iterativos que são interrompidos após alcançar um critério de convergência baseado nos erros de predição para o conjunto de validação, ou após determinado número de iterações. Esses procedimentos consomem alto tempo computacional e são de difícil paralelização.

Redes neurais baseadas em memória RAM (*Random Access Memory*), também conhecidas como classificadores de n-tuplas ou redes neurais sem peso (*Weightless Neural Network* — WNN), não armazenam conhecimento em suas conexões, mas em suas memórias de acesso randômico (RAM) que ficam dentro dos nós da rede, ou neurônios. Seu treinamento pode ser feito em um único passo e basicamente consiste em armazenar uma saída desejada em um endereço associado a um vetor de entrada de um neurônio (ALEKSANDER, 1966), sendo assim, mais eficiente e fácil de paralelizar do que a ARNN.

1.1. MOTIVAÇÕES

Muitas abordagens de predição de retornos exploram modelos na busca de minimizar os erros de predição usando um arsenal de métodos estatísticos e de inteligência computacional (SHARDA; PARTIL, 1992; MOODY, 1994; HANSEN; NELSON, 1997; FREITAS; De SOUZA; ALMEIDA, 2009), mas com pouca atenção para requisitos de desempenho computacional.

Recentemente, entretanto, empresas de *trading* elevaram a demanda por desempenho computacional para tornar possível enviar milhões, até bilhões, de ordens de compra e venda por dia — em alguns casos gastando menos que dez microssegundos por ordem, no que ficou conhecido como *High Frequency Trading*. A alta frequência de negociação se tornou um negócio multibilionário, correspondendo a cerca de 50% a 70% do volume do mercado de capitais negociados por dia nos E.U.A, 28% na Europa e 16% na Ásia (PELTZ, 2010).

No Brasil, mesmo com menos de 1% da população investindo na bolsa de valores (BOVESPA, 2011), as empresas de *trading* já vêm elevando sua demanda por desempenho

computacional. No início de 2010, a Bovespa anunciou a instalação de infraestrutura computacional para atender o segmento de alta frequência (SALGADO, 2011). Neste contexto, surge a justificativa para desenvolver sistemas de alto desempenho para este setor da economia. Considerando os requisitos de desempenho computacional e o fato que as redes neurais sem peso têm exibido capacidade de aprendizado e desempenho computacional superiores (De SOUZA et al., 2008; De SOUZA et al., 2009), vimos a motivação para investigar se as redes neurais sem peso são uma alternativa viável para previsões de alta frequência de séries temporais de retorno de ações.

Com este trabalho de pesquisa, esperamos construir preditores baseados em redes neurais sem peso rápidos o suficiente que permitam, por exemplo, construir sistemas de apoio ao investidor, como *trading systems*, capazes de prever em tempo real o melhor preço de compra e venda dos ativos (precificação) ou a escolha do momento em que se deve comprar ou vender ativos (*timing*).

1.2. OBJETIVOS

O principal objetivo deste trabalho foi construir uma arquitetura baseada em redes neurais sem peso capaz de prever séries de retornos de ações e que fosse rápida o suficiente para ser empregada em aplicações de negociação em alta frequência.

1.3. CONTRIBUIÇÕES

A principal contribuição deste trabalho foi a proposta e o desenvolvimento de um novo preditor de séries temporais baseado em rede neural sem peso que utiliza *Virtual Generalized Random Access Memory* (VG-RAM) (ALEKSANDER, 1966) para prever retorno futuro de ações. Nossos preditores foram avaliados em relação aos resultados reportados por Freitas, De Souza e Almeida (2005) no emprego de preditores baseados em redes neurais autoregressivas na previsão de retornos de ações do mercado brasileiro, utilizando os mesmos dados e metodologia experimental. Nossos resultados mostram que preditores neurais sem peso podem produzir previsões de retornos com os mesmos níveis de erros e propriedades de um preditor neural autoregressivo; entretanto, nossos preditores conseguem fazer isso até 5.000 vezes mais rápido.

1.4. ESTRUTURA DESTE TRABALHO

Após a introdução, este trabalho foi dividido nos seguintes capítulos:

Capítulo 2 — Conceitos fundamentais: Neste capítulo, são descritos os conceitos fundamentais relacionados a este trabalho de pesquisa, quais sejam: mercado de ações, bolsa de valores, séries temporais, retorno de investimento, redes neurais biológicas e artificiais.

Capítulo 3 — Predição de retornos de ações: Neste capítulo, são descritos os preditores ARNN e WNN VG-RAM, sendo que este último é o preditor proposto neste trabalho como uma alternativa eficiente em relação ao preditor ARNN.

Capítulo 4 — Metodologia: Neste capítulo, são descritos os dados utilizados para desenvolvimento deste trabalho, assim como os tratamentos aplicados aos mesmos quando as informações não estão disponíveis na base utilizada. Além disso, são descritas as métricas para avaliação dos preditores ARNN e WNN VG-RAM.

Capítulo 5 — Experimentos: Neste capítulo, são descritos como foram realizados os experimentos com o preditor ARNN e o preditor WNN VG-RAM. Também será apresentada uma avaliação do desempenho alcançado pelo preditor proposto neste trabalho.

Capítulo 6 — Discussão: Neste capítulo, são apresentados trabalhos correlatos e a análise crítica deste trabalho de pesquisa.

Capítulo 7 — Conclusão: Neste capítulo, são apresentados o sumário deste trabalho e novas linhas de investigação que podem ser desenvolvidas a partir deste trabalho.

2. CONCEITOS FUNDAMENTAIS

Neste capítulo são descritos os conceitos fundamentais relacionados a este trabalho de pesquisa, quais sejam: mercado de ações, bolsa de valores, séries temporais, retorno de investimento, redes neurais biológicas e artificiais.

2.1. MERCADO DE AÇÕES¹

A empresa, “organização particular, governamental, ou de economia mista, que produz e/ou oferece bens e serviços, com vista, em geral, à obtenção de lucros”, é uma entidade organizada que congrega capital e trabalho, constituída basicamente na forma de sociedades. Dentre as diversas formas societárias estabelecidas pelo Novo Código Civil brasileiro, instituído pela Lei no 10.406/02 (CÂMARA DOS DEPUTADOS, 2002), as mais comuns são as sociedades limitadas e as sociedades anônimas. As sociedades limitadas são constituídas através de contrato entre os sócios, denominado contrato social, que estabelece as participações individuais no capital social e no resultado da empresa. Destacam-se ainda o caráter nominativo das cotas e a responsabilidade de cada sócio restrita ao valor das suas cotas. Contudo, todos os sócios respondem solidariamente pela integralização do capital social. Esta última característica faz com que estas sociedades tenham dificuldades no aporte vultoso de recursos para empreendimentos de risco.

Nesse contexto, as sociedades anônimas, ou companhias, são uma alternativa societária que favorece o aporte vultoso de recursos para empreendimentos de risco. Nesta modalidade societária, o capital divide-se em ações e a responsabilidade dos acionistas (sócios) é proporcional à quantidade de ações (cotas) de sua propriedade.

Ações são valores mobiliários emitidos pelas companhias, que representam as menores parcelas nas quais se divide o capital da companhia. Em última instância, as ações são títulos de propriedade das empresas constituídas como sociedades anônimas, negociados tanto no mercado primário quanto no mercado secundário.

As negociações no mercado primário se dão na oferta pública de ações (*initial public offering* — IPO), quando a companhia emite uma quantidade de ações e a receita obtida

¹ Esta seção foi baseada no trabalho de Freitas (2008).

através desta subscrição é revertida para a companhia. No mercado secundário, as ações são negociadas nas Bolsas de Valores ou mercados de balcão, com operações realizadas sob as formas de negociação a vista, a termo, a futuro ou opções.

Quanto à espécie, as ações são classificadas como:

- Ações ordinárias — conferem direito a voto nas assembleias gerais das empresas, com cada ação equivalendo a um voto, e proporcionam participação nos resultados da empresa.
- Ações preferenciais — possuem prioridade na distribuição de dividendos e no reembolso de capital no caso da liquidação da companhia, podem ter direito a voto em ocasiões especiais (tipicamente após três exercícios consecutivos sem distribuição), desde que previsto no Estatuto Social da empresa.

Quanto à forma de circulação, as ações podem ser:

- Ao portador — sem um titular especificado na emissão, o proprietário é o dono do título.
- Nominativas — são emitidas através de certificados em nome de um titular. A venda deve ser registrada na empresa que a emitiu.
- Nominativas endossáveis — são ações nominativas na emissão, mas que podem ser transformadas em ações ao portador nas demais transferências através de endosso do título.
- Escriturais — são ações nominativas que não têm emissão de certificado e são mantidas numa conta de depósito do seu titular. O controle é realizado por instituições financeiras autorizadas, em um tipo de conta corrente na qual os valores são lançados a débito ou a crédito dos titulares, não havendo, portanto movimentação física de documentos.

Uma vez subscritas, as ações tornam-se bens negociáveis cujos preços variam ao longo do tempo, constituindo assim instrumentos de investimento que permitem a realização de lucro ou prejuízo em transações de compra e venda. As principais entidades mediadoras destas transações são as corretoras de valores, que se congregam em outras entidades, as Bolsas de Valores.

As Bolsas de Valores são associações civis sem fins lucrativos cujos sócios são as corretoras de valores. As transações de compra e venda são realizadas dentro do recinto das

Bolsas de Valores pelos funcionários ou sistemas das corretoras durante um expediente denominado pregão ou após o encerramento do pregão principal, no serviço eletrônico denominado *after-market*. Dentre as principais atividades de competência das Bolsas de Valores, destacam-se (SÁ, 1987):

- Manter local ou sistema adequado à realização de operações de compra e venda de títulos e valores mobiliários em mercado livre e abertos, especialmente organizados e fiscalizados pelas corretoras-membro e pelas autoridades reguladoras do mercado.
- Dotar o referido local ou sistema de todos meios necessários à pronta e eficiente realização e visibilidade das operações.
- Divulgar as operações realizadas com rapidez e riqueza de detalhes.

A principal Bolsa de Valores brasileira é a Bolsa de Valores de São Paulo — BOVESPA (BOVESPA, 2011).

2.2. SÉRIES TEMPORAIS

Uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo. Uma característica importante deste tipo de dados é que as observações vizinhas são dependentes e em muitos casos é de interesse analisar e modelar esta dependência. Como a maior parte dos procedimentos estatísticos foram desenvolvidos para analisar observações independentes surge a necessidade de estudar outras técnicas para analisar estes tipos de dados (MORETTIN, 2004).

Dados de séries temporais surgem em vários campos do conhecimento como Economia (preços diários de ações, taxa mensal de desemprego, produção industrial), Medicina (eletrocardiograma, eletroencefalograma), Epidemiologia (número mensal de novos casos de meningite), Meteorologia (precipitação pluviométrica, temperatura diária, velocidade do vento), entre outros.

No estudo das séries temporais, em geral, estamos interessados em dois aspectos: (i) a análise e modelagem da série temporal, ou seja, descrever a série, verificar suas características mais relevantes; (ii) previsão da série temporal, ou seja, a partir de valores passados da série encontrar boas previsões de valores futuros da série.

As séries temporais podem possuir algumas particularidades com relação a outros tipos de dados, por exemplo:

- Tendência: variações caracterizadas por um movimento regular e contínuo de longo período de tempo, obedecendo a uma direção geral;
- Movimentos cíclicos: variações que correspondem aos chamados ciclos econômicos, ou seja, oscilações periódicas com desvios em torno da tendência;
- Variações sazonais: as variações sazonais correspondem às oscilações de subida e de queda que ocorrem periodicamente em intervalos de tempos específicos;
- Variações irregulares, residuais ou aleatórias: movimentos causados por fenômenos não econômicos de natureza aleatória, como por exemplo, catástrofes e boatos.

2.3. REDES NEURAIS BIOLÓGICAS

O cérebro humano é o dispositivo mais complexo estudado pelo homem, sendo ainda muito pouco compreendido. Por exemplo, ainda não se tem respostas satisfatórias para as questões mais fundamentais tais como "O que é a consciência?" e "Como eu penso?" (BEALE; JACKSON, 1990).

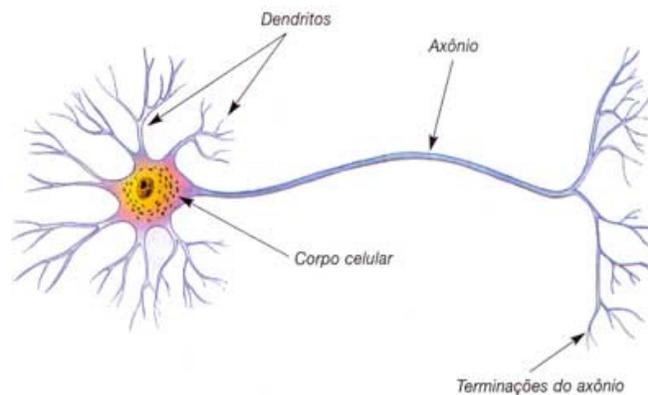


Figura 1 - Representação de um neurônio biológico

O sistema nervoso humano é formado por uma rede de neurônios (ver Figura 1), unidade básica do cérebro, responsável pelos fenômenos conhecidos como pensamento, emoção e cognição, além da execução das funções sensório-motoras e autônomas (WASSERMAN, 1989). Cada neurônio compartilha várias características com outras células, mas possui capacidades singulares para receber, processar e transmitir sinais eletroquímicos ao longo das fibras nervosas, que compreendem o sistema de comunicação cerebral.

Stevens (1985) considera a célula nervosa como uma unidade de processamento analógica independente, capaz de estabelecer a comunicação com o sistema nervoso central.

Segundo Beale e Jackson (1990), um neurônio é conectado a vários outros neurônios através dos dendritos e do axônio. Os dendritos — uma complexa rede de prolongamentos — recebem impulsos nervosos de outros neurônios e os conduzem ao corpo celular ou núcleo, onde essas informações são somadas e novos impulsos são gerados. Caso o resultado dessa soma exceda um determinado limiar, o axônio transmitirá esse estímulo a outros neurônios através de fenômenos químicos das regiões de comunicação entre os neurônios denominados sinapses.

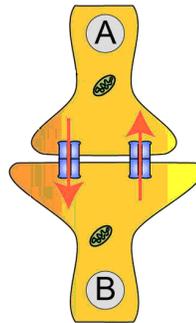


Figura 2 - Esquema de uma sinapse. (a) sinapse do neurônio transmissor. (b) sinapse do neurônio receptor.

As sinapses ocorrem no contato das terminações nervosas (axônios) com os dendritos. O contato físico não existe realmente, pois as estruturas estão próximas, mas há um espaço entre elas (fenda sináptica). Dos axônios são libertadas substâncias (neurotransmissores), que atravessam a fenda e estimulam receptores nos dendritos e assim transmitem o impulso nervoso de um neurônio para o outro, ver Figura 2.

A força sináptica da conexão neural ao refletir o nível de excitação ou inibição entre neurônios adjacentes capacita o cérebro humano ao armazenamento do conhecimento e o conseqüentemente o aprendizado. Através das sinapses os neurônios se unem funcionalmente, formando redes neurais (BEALE; JACKSON, 1990).

2.4. REDES NEURAIS ARTIFICIAIS²

As redes neurais artificiais são um paradigma de computação que se inspira no modelo computacional do cérebro humano (WASSERMAN, 1989). A partir da interconexão massiva dos neurônios, segundo uma determinada arquitetura, o cérebro humano torna-se um complexo computador não-linear e paralelo (HAYKIN, 1999).

As conexões entre os neurônios, ou entre estruturas sensoriais e neurônios, são, de forma simplificada, realizadas por circuitos denominados sinapses, que controlam o fluxo de informações através de mecanismos de excitação e inibição. Desta forma, a função de transformação implementada nos componentes do cérebro é fundamentalmente determinada pelos padrões de interconexão dos neurônios, pelos seus níveis de ativação e pelos estados (excitação ou inibição) das suas sinapses. Uma das características fundamentais do cérebro humano é a modificação destes padrões sinápticos de forma adaptativa em resposta às mudanças no ambiente, através de mecanismos denominados de aprendizado.

Esta máquina formada pelas interconexões sinápticas implementa um sistema de processamento de informação no qual seus componentes continuamente processam as informações recebidas nas suas entradas, transformando-as em novas informações nas suas saídas.

As redes neurais artificiais são construídas a partir de modelos matemáticos de componentes do cérebro humano, e conseguem reproduzir, em determinados níveis, diversas propriedades do cérebro humano. Dentre as propriedades mais importantes exibidas pelas redes neurais artificiais, destacam-se:

- Não-linearidade — as redes neurais podem aproximar mapeamentos de entrada e saída com não-linearidade virtualmente de qualquer ordem, propriedade especialmente importante quando o fenômeno a ser aprendido é de natureza inerentemente não-linear.

- Plasticidade — uma vez treinada para representar as entradas e saídas em um determinado ambiente, a representação do conhecimento da rede neural pode ser adaptada a partir de treinamento adicional para incorporar mudanças no ambiente. Esta propriedade é determinante na representação de fenômenos não-estacionários.

² Esta seção foi baseada no trabalho de Freitas (2008).

- **Aprendizado** — através da apresentação sistemática de exemplos de entradas e saídas, a rede neural consegue, por meio de um algoritmo de treinamento adequado, ajustar sua representação interna de conhecimento de forma a mapear as relações entre as entradas e as saídas apresentadas.

- **Generalização** — a partir do treinamento adequado para a representação de um conjunto de entradas e saídas, a rede neural pode produzir saídas razoáveis para entradas desconhecidas, isto é, distintas daquelas entradas que foram apresentadas durante o treinamento.

3. PREDIÇÃO DE RETORNOS DE AÇÕES

Neste capítulo são descritos os preditores ARNN e WNN VG-RAM, sendo que este último é o preditor proposto neste trabalho como uma alternativa eficiente em relação ao preditor ARNN.

3.1. PREDIÇÃO NO MERCADO DE AÇÕES

A importância de técnicas de modelagem de redes neurais artificiais no reconhecimento de padrões é evidenciada através de um amplo espectro de aplicações, sendo, provavelmente, a área onde as habilidades destes modelos conexionistas foram mais exploradas (BISHOP, 1996).

Diante do sucesso alcançado pelas redes neurais na área de reconhecimento de padrões surge a possibilidade de investigar a aplicabilidade destes modelos na extração de características não lineares presentes em séries temporais econômicas. No mercado de ações o principal interesse é dirigido para a detecção de regularidades no movimento da cotação das ações no mercado.

A Hipótese do Mercado Eficiente (HME) afirma que a posse de um conjunto de informações públicas disponíveis em um determinado instante de tempo não altera o valor da ação no mercado. Ou seja, o valor da ação no tempo t , condicionado às informações conhecidas no tempo $t - 1$ não possuem dependência/correlação. Segundo Fama (1970), o ajuste instantâneo das informações públicas aos preços das ações em um mercado eficiente implica na independência entre variações de preços sucessivos na sequência das negociações. Um mercado que apresenta tal comportamento é, por definição, um mercado eficiente. Baseado nesta hipótese, o movimento da cotação de uma ação seria imprevisível a partir de informações disponíveis. Em finanças, mais estritamente à luz da Hipótese do Mercado Eficiente (FAMA, 1970), os preços das ações seguem um modelo estocástico do tipo caminho aleatório (*random walk*) (MORETTIN, 2004), onde uma série de preços apresenta incrementos aleatórios e com valor esperado nulo no decorrer do tempo, portanto, a história passada da série não pode ser usada para prever o futuro de maneira significativa (COOTNER, 1964).

Em oposição à Hipótese do Mercado Eficiente, existem outras hipóteses que propõem que os preços das ações se movem de acordo com tendências e que os preços passados podem ser usados para prever a direção dos preços futuros das ações (LO; MACKINLEY, 1988).

A previsibilidade dos mercados de ações ainda é uma questão aberta na teoria das finanças; a Hipótese do Mercado Eficiente, arcabouço teórico que tem guiado esta discussão, ainda se encontra sob revisão e testes empíricos (FAMA, 1970; FAMA, 1991; FAMA 1998; MALKIEL, 2003). É a partir desta constatação que a modelagem de redes neurais artificiais se torna uma ferramenta importante na investigação de regularidades no preço das ações mascaradas pelas oscilações do mercado (MOODY, 1994).

3.2. PREDITOR ARNN

O retorno de um período de uma ação no tempo t , r_t , pode ser definido como:

$$r_t = \frac{P_t - P_{t-1}}{P_{t-1}} \quad t \geq 1 \quad (1)$$

Onde P_t e P_{t-1} são os preços das ações no tempo t e $t - 1$, respectivamente, e a série de retornos passados de ações, r^r , pode ser definida como:

$$r^r = (r_1, r_2, \dots, r_R) \quad (2)$$

A abordagem tradicional para preditores de séries históricas baseado em redes neurais é o *Autoregressive Neural Network* (ARNN) (WHITE, 1988; HAYKIN, 1999). O preditor ARNN recebe com entrada um retorno presente e $p - 1$ retornos passados e produz um retorno futuro como saída. Um ARNN(p), então, implementa um sistema de predição não linear, S_R , que tem uma ordem de regressão p e entradas e saídas como mostrado na equação abaixo:

$$r_{t-(p-1)}, \dots, r_t \rightarrow S_R \rightarrow \hat{r}_{t-1} \quad (3)$$

3.3. PREDITOR WNN VG-RAM

Redes neurais baseadas em *Random Access Memories* (RAM), também conhecidas como classificador n-tuplas, não armazenam conhecimento em suas conexões, mas sim, na memória RAM dos nós da rede, ou neurônios. Esses neurônios operam com valores de entrada binários e usam RAM como tabela de busca (*lookup table*): as sinapses de cada neurônio coletam um vetor de bits da entrada da rede que é usado como endereço da RAM e o valor armazenado nesse endereço é a saída do neurônio. O treinamento pode ser feito em um único passo e consiste basicamente em armazenar a saída desejada no endereço associado com o vetor de entrada do neurônio (ALEKSANDER, 1966).

Apesar da sua notável simplicidade, esse tipo de rede é muito efetiva como ferramenta de reconhecimento de padrões, oferecendo treinamentos e testes rápidos, e fácil implementação (ALEKSANDER, 1998). No entanto, se a entrada da rede for muito grande, o tamanho da memória dos neurônios da rede torna-se proibitivo, dado que tem de ser igual a 2^n , onde n é o tamanho da entrada. As redes do tipo *Virtual Generalizing RAM* – VG-RAM – (LUDEMIR et al., 1999) são redes neurais baseadas em RAM que somente requerem capacidade de memória para armazenar os dados relacionados ao conjunto de treinamento.

Tabela 1 - Tabela de busca de um neurônio da WNN VG-RAM

Tabela de busca	X1	X2	X3	Y
entrada #1	1	1	0	categoria 1
entrada #2	0	0	1	categoria 2
entrada #3	0	1	0	categoria 3
	↑	↑	↑	↓
entrada	1	0	1	categoria 2

Os neurônios VG-RAM armazenam os pares de entrada e saída observados durante o treinamento, em vez de apenas a saída. Na fase de teste, as memórias dos neurônios VG-RAM são pesquisadas mediante a comparação entre a entrada apresentada à rede e todas as entradas nos pares de entrada e saída aprendidas. A saída de cada neurônio VG-RAM é determinada pela saída do par cuja entrada é a mais próxima da entrada apresentada – a função de distância adotada pelos neurônios VG-RAM é à distância de Hamming, i.e., o número de bits diferentes entre dois vetores de bits de igual tamanho. Se existir mais do que

um par na mesma distância mínima da entrada apresentada, a saída do neurônio é escolhida aleatoriamente entre esses pares.

A Tabela 1 ilustra a tabela de busca de um neurônio VG-RAM com três sinapses (X1, X2 e X3). Esta tabela de busca contém três entradas (pares de entrada e saída) que foram armazenadas durante a fase de treinamento (entrada #1, entrada #2 e entrada #3). Durante a fase de teste, quando um vetor de entrada é apresentado à rede, o algoritmo de teste VG-RAM calcula a distância entre este vetor de entrada e cada entrada dos pares de entrada e saída armazenados na tabela de busca. No exemplo da Tabela 1, a distância de Hamming entre o vetor de entrada e a entrada #1 é dois, porque ambos os bits X2 e X3 não são semelhantes aos bits X2 e X3 do vetor de entrada. A distância da entrada #2 com relação ao vetor de entrada é um, porque X1 é o único bit diferente. A distância da entrada #3 com relação ao vetor de entrada é três. Portanto, para este vetor de entrada, o algoritmo avalia a saída do neurônio, Y, como categoria 2, pois é o valor de saída armazenado na entrada #2.

3.3.1. ARQUITETURA DO PREDITOR DE AÇÕES WNN VG-RAM

A arquitetura do preditor WNN VG-RAM é similar ao construído em trabalhos anteriores de reconhecimento de face (De SOUZA et al., 2008). Na aplicação de reconhecimento de face os neurônios da rede são treinados para informar um código de uma pessoa a partir da sua imagem; similarmente, no preditor WNN VG-RAM, os neurônios são treinados para informar o índice de um conjunto de retornos a partir de uma imagem equivalente a um conjunto de p retornos passados, como mostrado na Figura 3(a) para $p = 4$. Com esta abordagem, tenta encontrar uma maneira de inspecionar o gráfico de uma série temporal para prever um valor futuro. Nesta tarefa, concentra-se a atenção nos últimos pontos do gráfico, criando um quadro imaginário que delimita esta região do gráfico que oferece uma imagem com informação visual suficiente, espera-se, para prever o próximo valor da série.

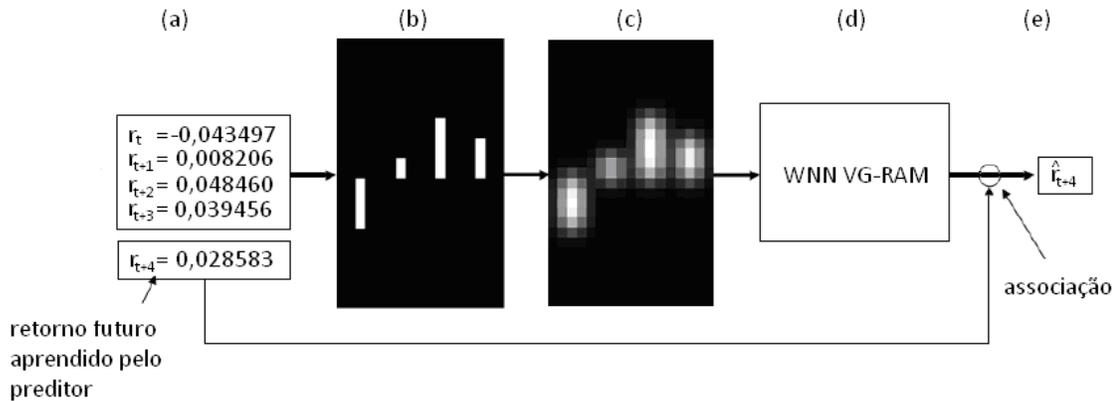


Figura 3 – Representação de um conjunto de retornos a partir de uma imagem equivalente a um conjunto de 4 retornos passados.

A arquitetura do preditor WNN VG-RAM possui um conjunto de neurônios e, durante o teste, dado um conjunto de p retornos, todos eles são treinados para associar a imagem desse conjunto com um índice, i.e., os neurônios tentam lembrar uma situação similar no passado para produzir uma previsão do retorno futuro, \hat{r}_{t+1} . Durante o teste, uma imagem do retorno presente e os $p - 1$ retornos passados são apresentados para a rede e cada neurônio retorna o índice de um retorno treinado anteriormente. Esses índices são usados para recuperar os retornos na base de treino, no qual é calculada a média para produzir o retorno da rede. Isto produz o valor do retorno futuro da rede, \hat{r}_{t+1} .

A Figura 3 mostra um diagrama que ilustra o funcionamento da arquitetura do preditor WNN VG-RAM. Nesta figura, uma série de quatro retornos é transformada em um gráfico de barras onde o tamanho de cada barra é equivalente a magnitude do retorno a maior representação possível, ver Figura 3(a) e (b). As barras que representam retornos negativos iniciam no meio da imagem e crescem para baixo, enquanto as barras que representam retornos positivos iniciam no meio da imagem e crescem para cima.

Para aumentar a largura das barras — inserir mais informações na imagem — foi aplicado um filtro gaussiano (ver Figura 3(c)) e a saída deste filtro é na verdade a entrada no preditor WNN VG-RAM. Com a utilização do filtro espera-se aumentar a similaridade entre os padrões apresentados à rede na fase de treinamento do preditor.

O preditor WNN VG-RAM realiza a conexão sináptica (ver Figura 4) na entrada fornecida a rede e associa a esta entrada um índice, incrementado sequencialmente de acordo com as entradas fornecidas a rede na fase de treinamento, Figura 3(e). Este índice

será utilizado para recuperar o valor do retorno aprendido na fase de treino do preditor WNN VG-RAM que será utilizado para formar a predição do retorno futuro, Figura 3(a).

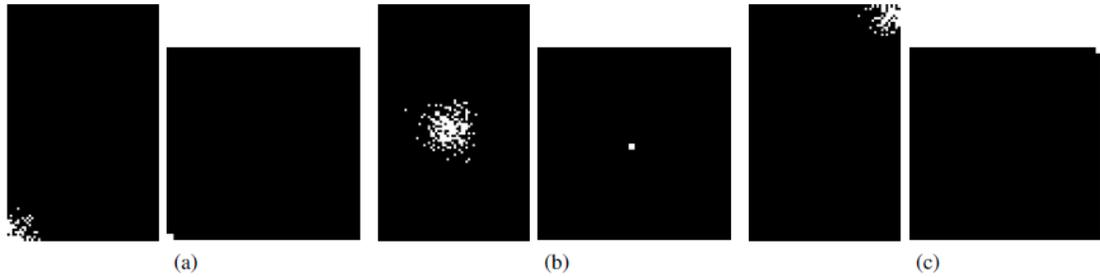


Figura 4 – Padrão de interconexão sináptica do preditor WNN VG-RAM. (a) Esquerda, entrada Φ : em branco, elementos $\Phi_{k,l}$, da entrada Φ que são conectadas pelo neurônio $n_{1,1}$ de N por $\Omega_{1,1}(W)$. Na direita, vetor de neurônios N : em branco o neurônio $n_{1,1}$ de N . (b) Esquerda, entrada Φ : em branco, elementos $\Phi_{k,l}$, da entrada Φ que são conectadas pelo neurônio $n_{m/2, n/2}$ de N por $\Omega_{m/2, n/2}(W)$. Na direita, vetor de neurônios N : em branco o neurônio $n_{m/2, n/2}$ de N . (c) Esquerda, entrada Φ : em branco, elementos $\Phi_{k,l}$, da entrada Φ que são conectadas pelo neurônio $n_{m,n}$ de N por $\Omega_{m,n}(W)$. Na direita, vetor de neurônios N : em branco o neurônio $n_{m,n}$ de N .

O preditor WNN VG-RAM é uma matriz $m \times n$ de neurônios VG-RAM, onde cada neurônio n_{ij} tem um conjunto de sinapses $W = \{w_1, \dots, w_{|W|}\}$, que são randomicamente conectados na entrada bidimensional da rede, Φ , de $u \times v$ entradas, $\phi_{k,l}$ (Figura 4). O padrão de conexão randômico das sinapses de cada neurônio n_{ij} , $\Omega_{ij}(W)$, segue uma distribuição normal com variância σ^2 centrada em ϕ_{u_k, u_l} , i.e, as coordenadas k e l dos elementos Φ que n_{ij} conecta via W seguindo a função de densidade de probabilidade:

$$\omega_{\mu_k, \sigma^2}(k) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(k-\mu_k)^2}{2\sigma^2}} \quad (4)$$

$$\omega_{\mu_l, \sigma^2}(l) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(l-\mu_l)^2}{2\sigma^2}} \quad (5)$$

Onde σ é um parâmetro da arquitetura. Este padrão de interconexões sinápticas imitam muitas classes de neurônios biológicos (KANDEL, 2000). Estas interconexões são criadas quando a rede é construída e não se alteram.

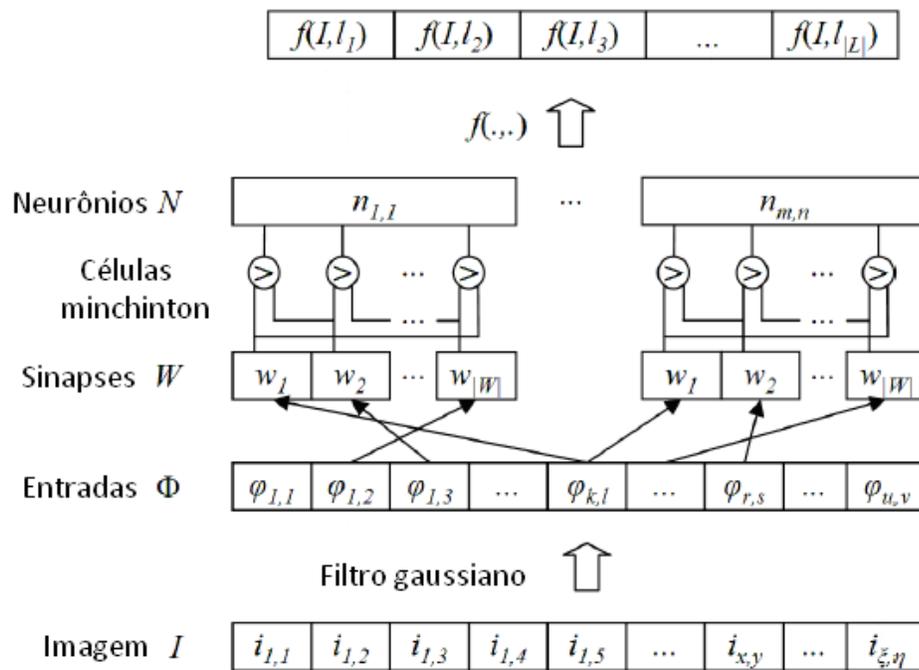


Figura 5 – Diagrama esquemático do preditor WNN VG-RAM

As sinapses da arquitetura WNN VG-RAM só podem recuperar um único bit da entrada. Assim, para permitir que o preditor trabalhe com imagens, no qual cada *pixel* pode assumir um conjunto de valores diferentes, é utilizado células de tipo *minchinton* (MITCHELL, 1998). Na proposta da arquitetura do WNN VG-RAM, cada sinapse do neurônio, w_t , forma uma célula *minchinton* com a próxima, w_{t+1} , ($w_{|W|}$ forma uma célula *minchinton* com w_1). O tipo de célula *minchinton* utilizada retorna 1 se a sinapse w_t da célula conectada com um elemento da entrada, $\phi_{k,l}$, cujo valor é maior do que o valor do elemento $\phi_{r,s}$ cuja sinapse w_{t+1} está conectada, i.e, $\phi_{k,l} > \phi_{r,s}$; caso contrário, retorna 0 (veja as sinapses w_1 e w_2 do neurônio $n_{m,n}$ da Figura 5).

Durante o treino, o gráfico de barras da imagem I_x dos p retornos passados de $r_x, r_{x-p}, \dots, r_{x-1}$, são copiados para a entrada Φ do preditor WNN VG-RAM e em todas as saídas dos neurônios são colocados o índice referente ao conjunto do retorno r_x . Então, todos os neurônios são treinados para responder este índice para a imagem I_x . Este procedimento é repetido para todas as imagens I_x no conjunto de treinamento. Durante o teste, cada imagem do gráfico de barras I_y de p retornos passados $r_y, r_{y-p}, \dots, r_{y-1}$, do conjunto de dados de teste também são copiados para a entrada Φ do preditor WNN VG-RAM. Depois disso, todas as saídas dos neurônios são computadas e com o retorno associado a estas saídas é

calculada a média. O preditor WNN VG-RAM retorna esta média dos retornos como a predição do retorno \hat{r}_y .

4. METODOLOGIA

Neste capítulo são descritos os dados utilizados para desenvolvimento deste trabalho, assim como os tratamentos aplicados aos mesmos quando as informações não estão disponíveis na base utilizada. Além disso, são descritas as métricas para avaliação dos preditores ARNN e WNN VG-RAM.

4.1. BASE DE DADOS

Os dados utilizados neste trabalho de pesquisa são referentes a um subconjunto de 46 ativos que participaram do índice BOVESPA no primeiro quadrimestre de 2005, com séries temporais suficientes para o treinamento das redes neurais. Para cada um desses 46 ativos, computou-se 265 retornos semanais no período entre 16 de Fevereiro de 2000 e 9 de Março de 2005, usando preços de fechamento das quartas-feiras para evitar os efeitos de início da semana e final da semana (MALKIEL, 2003; ELTON et al., 2007). Usamos as últimas 60 observações dos nossos dados, entre 21 de Janeiro de 2004 e 9 de Março de 2005, para avaliar o desempenho no nosso preditor. Em todos os casos de dados faltantes utilizamos o preço de fechamento do último dia disponível.

No trabalho de Freitas (2008) foi formulado um modelo de seleção de carteiras baseado em erros de predição — um modelo de seleção de carteiras de investimento que explora predições de retornos de ações por meio de um arcabouço de diversificação eficiente Normal multivariado — e comparou-se experimentalmente o desempenho deste modelo com o do modelo média-variância de Harry Markowitz. Os resultados de Freitas (2008) mostraram que o modelo de seleção de carteiras baseado em erros de predição obtém retornos significativamente superiores aos do modelo média-variância para níveis equivalentes de risco.

O preditor proposto em Freitas, De Souza e Almeida (2005) utilizado no trabalho de Freitas (2008) e também utilizado como referência neste trabalho consegue obter erros normais de predição a partir de séries de retornos não normais. Como neste trabalho estamos interessados em construir um preditor baseado em redes neurais sem peso com os

mesmos níveis de erros e propriedades era necessário verificar se este preditor era capaz de produzir erros de predições normais a partir de séries de retornos não normais.

Em Freitas, De Souza e Almeida (2005) foram realizados nas séries de retornos utilizadas neste trabalho o teste de *chi-square* (PAPOULIS, 1991), e os resultados para as 46 ações são mostradas na Tabela 2.

Tabela 2 – Resultados do teste de *chi-square* para a base utilizada

σ	H₀ não rejeitado		H₀ rejeitado	
0,01	14	(30%)	32	(70%)
0,05	6	(13%)	40	(87%)
0,10	5	(11%)	41	(89%)

Os testes foram realizados para os níveis de significância padrão (σ) de 0,01; 0,05 e 0,10; e a normalidade foi aceita (i.e, não rejeitada) para 14 (30%), 6 (13%), e 5 (11%) das séries, respectivamente. A Tabela 2 mostra que todas as 46 (100%) distribuições de retornos possuem curtoses positivas, com uma média de 9,5 e desvio padrão de curtose de 1,26 ($se_c = \sqrt{24/n}$, $n = 60$), mostrando valores centrais fortemente elevados pelos esperados por uma distribuição normal — o valor da curtose da distribuição normal é zero. Além disso, 44 (96%) das distribuições mostram assimetria significativamente positivas, com média de 1,2 e com desvio padrão de 0,63 ($se_a = \sqrt{6/n}$, $n = 60$), mostrando a alta probabilidade de ocorrer retornos positivos com relação a retornos negativos — o valor da assimetria da distribuição normal é zero. Os valores de máximo e mínimo da curtose e assimetria são mostrados na Tabela 3.

As medidas de assimetria e curtose avaliam características de uma função distribuição de probabilidades, tipicamente as comparando em relação à distribuição Normal. O Coeficiente de assimetria é dado por

$$v = \frac{m_3(\mu)}{\sigma^3} \quad (6)$$

onde, se $\nu > 0$, então a distribuição tem uma cauda direita (valores acima da média) mais pesada; se $\nu < 0$, então a distribuição tem uma cauda esquerda (valores abaixo da média) mais pesada; e se $\nu = 0$, então a distribuição é aproximadamente simétrica (na terceira potência do desvio em relação à média). O Coeficiente de curtose é dado por

$$\nu = \frac{m_4(\mu)}{\sigma^4} - 3 \quad (7)$$

onde, se $\nu = 0$, então tem o mesmo achatamento que a distribuição Normal; se $\nu > 0$, então a distribuição é mais alta (afunilada) e concentrada que a distribuição Normal; se $\nu < 0$, então a distribuição é mais baixa (achatada) que a distribuição normal. A distribuição Normal apresenta coeficientes de assimetria e curtose iguais a zero.

Tabela 3 - Valores de máximo e mínimo da curtose e assimetria dos dados utilizados

	Curtose	Assimetria
Mínimo	0,4682	-0,4027
Máximo	93,4796	7,3942
Média	9,5148	1,2467
> 0	46	44
< 0	0	2

4.2. MÉTRICAS

O desempenho dos preditores foi avaliado a partir das suas séries de erros de predição, utilizando as medidas de erro médio, raiz de erro quadrático médio, erro percentual absoluto médio e taxas de acerto, que são apresentadas a seguir. Estas métricas foram escolhidas por serem padrão na literatura de previsão de séries temporais (ARMSTRONG; 1992).

4.2.1. ERRO MÉDIO

O erro médio (*mean error – ME*) é a média das diferenças entre o retorno realizado e o retorno predito, definida como:

$$ME = \frac{1}{n} \sum_{t=1}^n r_t - \hat{r}_t \quad (8)$$

onde n é o tamanho das séries históricas, e r_t e \hat{r}_t são o retorno realizado e o retorno predito, respectivamente, no tempo t .

4.2.2. RAIZ DE ERRO QUADRÁTICO MÉDIO

A raiz de erro quadrático médio (*root mean square error – RMSE*) é uma medida padrão para avaliar as diferenças entre duas séries temporais, e é definida em termos das diferenças entre o retorno realizado e o retorno predito como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (r_t - \hat{r}_t)^2} \quad (9)$$

O *RMSE* conforme definido acima, pode ser interpretado como o desvio padrão dos erros de predição. Esta métrica tem baixa proteção contra os *outliers*³, boa sensibilidade para pequenas mudanças nos dados e não exibe as assimetrias dos dados (ARMSTRONG; COLLOPY, 1992).

4.2.3. ERRO PERCENTUAL ABSOLUTO MÉDIO

O erro percentual absoluto médio (*mean absolute percentage error – MAPE*) é definido como:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{r_t - \hat{r}_t}{r_t} \right| \quad (10)$$

³ *Outliers* são valores atípicos presentes nas séries históricas, normalmente gerados por eventos espúrios ou erros de amostragem

onde o operador $| \cdot |$ retorna o valor absoluto do seu argumento. O *MAPE* é amplamente utilizado como figura de mérito do desempenho de preditores na literatura, e é uma medida adimensional, como boa sensibilidade para pequenas mudanças nos dados.

4.2.4. TAXAS DE ACERTO

As taxas de acerto (*Hit Rate* – H_R) H_{R+} e H_{R-} , mensuram a percentagem das predições nas quais os sinais de r e \hat{r} , retorno realizado e retorno predito, respectivamente, coincidem. O H_R é a percentagem dos retornos preditos que apresentam o mesmo sinal que os retornos realizados e ambos foram diferentes de zero, H_{R+} é a percentagem para os retornos preditos positivos e H_{R-} é a percentagem para os retornos preditos negativos. Estas medidas são adequadas para avaliação de preditores como geradores de negociação (HELLSTROM, 1999), e podem ser definidas como:

$$H_R = \frac{\text{count}_{t=1}^n(r_t \hat{r}_t > 0)}{\text{count}_{t=1}^n(r_t, \hat{r}_t \neq 0)} \quad (11)$$

$$H_{R+} = \frac{\text{count}_{t=1}^n(r_t > 0 \& \hat{r}_t > 0)}{\text{count}_{t=1}^n(\hat{r}_t > 0)} \quad (12)$$

$$H_{R-} = \frac{\text{count}_{t=1}^n(r_t < 0 \& \hat{r}_t < 0)}{\text{count}_{t=1}^n(\hat{r}_t < 0)} \quad (13)$$

onde a função $\text{count}_{t=1}^n(\cdot)$ retorna o número de ocorrências do seu argumento.

4.2.5. SENTIDO DAS MÉTRICAS

A Tabela 4 mostra um sumário do sentido da melhoria das métricas apresentadas nas Seções anteriores, onde o símbolo \uparrow significa que quanto maior o valor da métrica, melhor; o símbolo \downarrow significa que quanto menor o valor da métrica, melhor; e o símbolo $|\downarrow|$ significa que quanto menor o valor absoluto da métrica, melhor.

Tabela 4 - Sentido da melhoria das métricas utilizadas na avaliação de desempenho dos preditores

Sentido das Métricas Utilizadas		
Métrica	Descrição	Sentido da Melhoria
ME	Erro Médio	↓
$RMSE$	Raiz do Erro Quadrático Médio	↓
$MAPE$	Erro Percentual Absoluto Médio	↓
H_R	Taxa de Acerto Total	↑
H_{R-}	Taxa de Acerto Negativo	↑
H_{R+}	Taxa de Acerto Positivo	↑

Conforme a Tabela 4 mostra, enquanto as menores medidas de erro são as melhores (com exceção do ME , cujo menor valor absoluto é o melhor), as maiores taxas de acerto são as melhores. A taxa de acerto total é a principal métrica utilizada para comparação dos preditores ARNN(4) e WNN VGRAM.

5. EXPERIMENTOS

Neste capítulo são descritos como foram realizados os experimentos com o preditor ARNN e o preditor WNN VG-RAM. Também será apresentada uma avaliação do desempenho alcançado pelo preditor proposto neste trabalho.

5.1. PREDIÇÕES DO PREDITOR ARNN

As predições utilizadas como referencial de comparação neste trabalho foram reportadas por Freitas, De Souza e Almeida (2005). A topologia e os parâmetros de treinamento do preditor ARNN que foi empregado pelos autores foram obtidos empiricamente e são descritos como a seguir.

Foi utilizado um preditor ARNN(4) implementado com uma rede neural *feedforward* completamente conectada com duas camadas escondidas, com uma função de ativação sigmoideal no intervalo $[-1,1]$ e uma topologia 4:30:15:1 (4 neurônios de entrada, 30 neurônios na primeira camada, 15 neurônios da segunda camada e 1 neurônio na camada de saída). Para treinar e testar esta rede neural foi utilizada uma janela deslizante de 206 dos 265 retornos disponíveis. Isto permitiu 60 predições, i.e., dos 265 retornos (todo o conjunto de dados) menos 206 (tamanho da janela deslizante, incluindo 4 retornos necessários para a entrada no ARNN(4) e o primeiro retorno predito), mais um (a predição da janela inicial).

Foram realizadas 2.760 sessões de treinamento (60 ciclos de treino e teste x 46 ações = 2.760). Cada sessão de treino foi realizada por 200.000 épocas usando o algoritmo *backpropagation* com a taxa de aprendizado de 0,009 e inércia de 0,95.

Cada janela deslizante contém um conjunto de treino (201 pares de entrada e saída) e o conjunto de teste (um par de entrada e saída). Para reduzir *overfitting*, foi empregada uma técnica que divide o conjunto de teste em duas partes: uma parte com 192 pares de entrada e saída e uma parte de validação com pelo menos 9 pares de entrada e saída. A parte de treino foi usada para atualizar os pesos da rede, enquanto a parte de validação foi usada para testar e selecionar, a cada 1.000 épocas de treino (blocos de treino), os pesos que conseguem o menor erro médio quadrático (*root mean square error*) de predição. Este

procedimento foi repetido para as 200.000 épocas, e no final foi obtido o melhor conjunto de pesos que será usado no período de predição do conjunto de teste. Os tamanhos dos conjuntos de treino e teste foram obtidos usando a heurística descrita por Haykin (1999).

O procedimento de treino e teste descrito acima foi repetido para todas as 60 predições avançando a janela deslizante de 206 semanas, uma semana por vez. O esquema de janela deslizante é mostrado na Figura 6, no qual ilustra a primeira posição da janela deslizante e o tamanho, em semanas, da parte de treino (TRN), validação (VAL) e teste (TST).

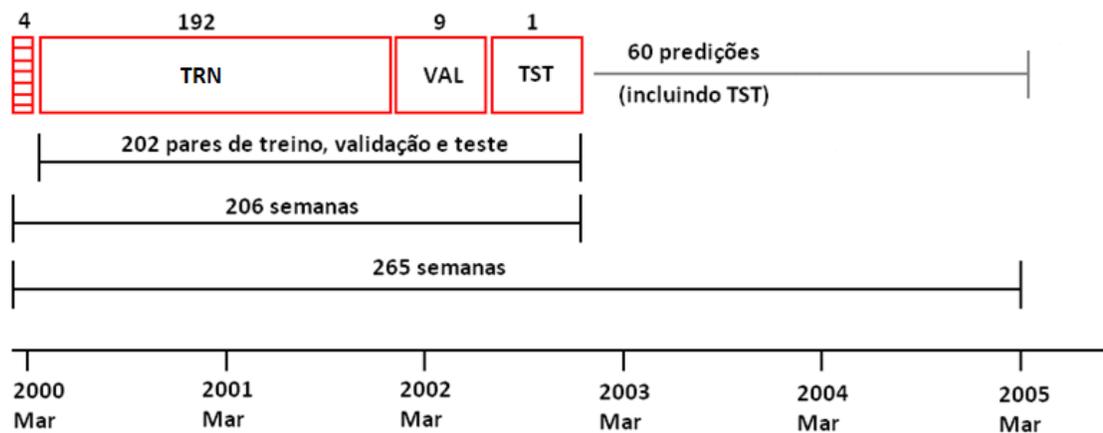


Figura 6 – Janela deslizante utilizada para treinamento do preditor ARNN(4)

É importante notar que, no treinamento, a chegada de novos dados é necessária para obter melhores predições (série dos retornos das ações são não estacionários e novos conhecimentos ajudam a melhorar o modelo feito pela rede neural), embora custe esforço computacional significativo (tempo).

5.2. CALIBRAÇÃO DO PREDITOR WNN VG-RAM

Foram executados experimentos de ajuste (ou calibração) para tentar encontrar empiricamente os parâmetros topológicos adequados do preditor WNN VG-RAM. Como mencionado na Seção 3.3.1, o preditor WNN VG-RAM tem uma única matriz bidimensional de $m \times n$ neurônios VG-RAM, e cada neurônio têm um conjunto de sinapses de tamanho $|W|$ que são aleatoriamente conectados a entrada bidimensional ϕ de $u \times v$ pixels de acordo com um padrão de interconexão sináptica que segue uma distribuição normal bidimensional com variância σ^2 .

Foi utilizado nos experimentos de calibração o desempenho da métrica H_R para seleção dos melhores parâmetros do preditor WNN VG-RAM. Em resumo, o H_R é o percentual das previsões do WNN VG-RAM que são diferentes de zero e têm o mesmo sinal do retorno da série que está sendo previsto. O H_R é formalmente apresentado na Seção 4.2.4.

A métrica H_R foi utilizada para seleção dos melhores parâmetros, pois como o principal objetivo do preditor proposto é a sua utilização em negociações em alta frequência, o H_R é a medida mais adequada para a avaliação de preditores como geradores de negociação (HELLSTROM, 1999).

Foram avaliados os melhores valores dos parâmetros: $m \times n$ no conjunto $\{2 \times 4, 4 \times 8, 8 \times 16, 16 \times 32, 32 \times 64\}$, por $|W|$ no conjunto $\{64, 128, 256, 512\}$, por $u \times v$ no conjunto $\{17 \times 44, 17 \times 88, 17 \times 176, 17 \times 352\}$ (foi fixado u para reduzir o espaço de busca), e para σ no conjunto $\{1, 2, 3, 4\}$ — um total de 400 possibilidades de definição de parâmetros.

O valor de v (altura da imagem gerada pela série de retornos) foi avaliado para o conjunto $\{44, 88, 176, 352\}$, porém, os valores dos retornos possíveis de serem representados pela imagem foram limitados em 0,1 para retornos positivos e -0,1 para retornos negativos. Os valores de retornos acima de 0,1 foram representados por 0,1 e os valores de retornos abaixo de -0,1 foram representados por -0,1.

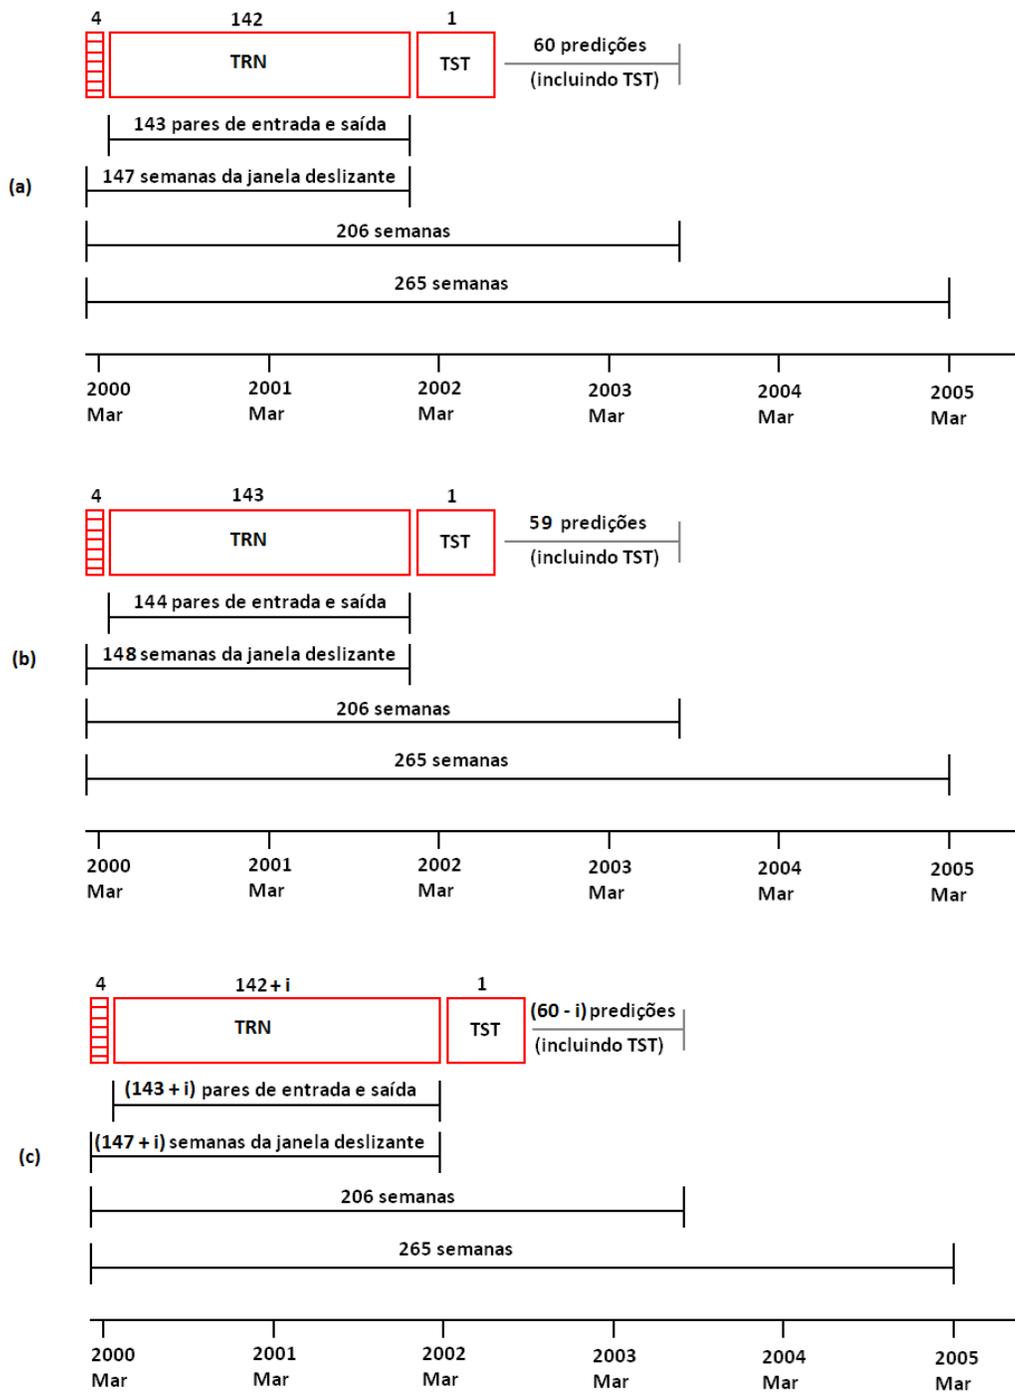


Figura 7 – (a) Janela deslizante para calibração do preditor WNN VG-RAM na posição inicial. (b) Janela deslizante para calibração do preditor WNN VG-RAM deslocada de uma semana após a posição inicial. (c) Janela deslizante para calibração do preditor WNN VG-RAM após i predições.

Para treinar e validar (busca dos melhores parâmetros) o preditor WNN VG-RAM, foi utilizada uma janela deslizando sendo o primeiro o retorno o 147 dos 265 retornos semanais disponíveis. Com isso, foi possível realizar 60 predições para escolher os melhores

parâmetros dentre as 400 possibilidades. Ou seja, dos 265 retornos (todos os retornos disponíveis) menos 147 (janela deslizante, incluindo os quatro retornos necessários para o primeiro conjunto de entrada do preditor WNN VG-RAM) menos 60 retornos separados para o teste, mais um (a predição da janela inicial). Este esquema de janela deslizante é mostrado na Figura 7, que ilustra a primeira posição da janela deslizante, esta formada pelo segmento de treino (TRN) e pelo segmento de teste (TST), os tamanhos dos segmentos são representados em semanas.

Sendo assim, foram realizadas 1.104.000 sessões de treinos (60 ciclos de treinos e teste x 46 ações x 400 combinações de parâmetros = 1.104.000).

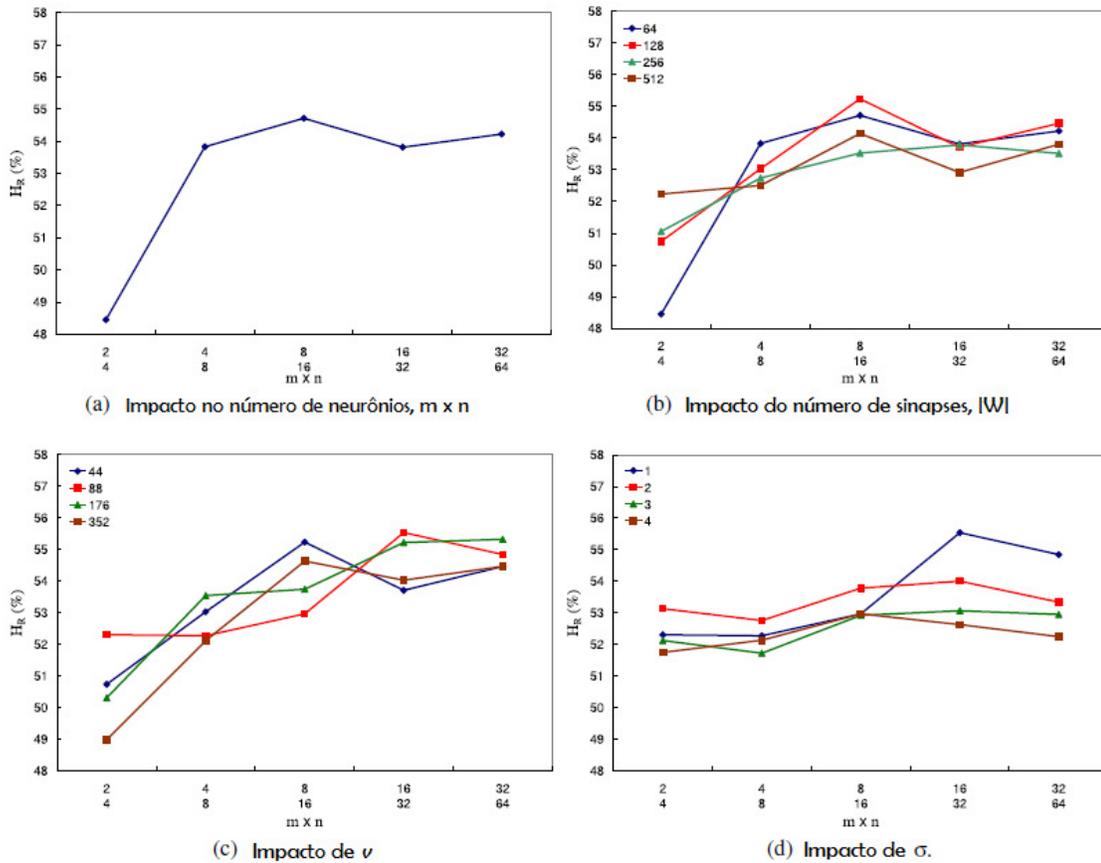


Figura 8 – Impacto dos parâmetros no desempenho do preditor WNN VG-RAM

O gráfico da Figura 8(a) permite avaliar o impacto do número de neurônios no desempenho do preditor WNN VG-RAM. Na Figura 8(a), o eixo x é o número de neurônios $m \times n$, enquanto o eixo y é o desempenho do preditor WNN VG-RAM, em termos de H_R . Para produzir os resultados neste gráfico, os valores de $|W|$, ν e σ foram definidos em seus mínimos: 64, 44, e 1, respectivamente, (ver os intervalos considerados

para cada parâmetro acima) e, então, foram variados os valores de $m \times n$ no conjunto $\{2 \times 4, 4 \times 8, 8 \times 16, 16 \times 32, 32 \times 64\}$. O gráfico da Figura 8(a) mostra que o desempenho do preditor WNN VG-RAM melhora à medida que aumenta o número de neurônios, mas atinge um máximo com 8×16 neurônios para $|W| = 64$, $v = 44$ e $\sigma = 1$.

O gráfico da Figura 8(b) apresenta o impacto do número de sinapses, $|W|$, sobre o desempenho do preditor WNN VG-RAM. Tem o mesmo formato da Figura 8(a), mas inclui uma curva para cada valor de $|W|$ considerado. Para produzir os resultados neste gráfico, foram definidos os valores de v em 44 e o de σ seu mínimo (1) e variou-se o valor de $|W|$ no conjunto $\{64, 128, 256, 512\}$, assim, foi traçado uma curva para cada valor de $|W|$. Como o gráfico da Figura 8(b) ilustra, o desempenho do preditor WNN VG-RAM melhorou com o aumento do número de sinapses, mas atingiu um máximo com 128 sinapses e, então, começou a diminuir. Sendo assim, foi escolhido 128 como o número de sinapses do preditor.

O gráfico da Figura 8(c) apresenta o impacto da altura v da entrada ϕ sobre o desempenho do preditor WNN VG-RAM. Este gráfico possui uma curva para cada valor de v considerado. Para produzir os resultados no gráfico, foi fixado o valor de $|W|$ em 128, e o mínimo de σ ($\sigma = 1$), variou-se o valor de v no intervalo $\{44, 88, 176, 352\}$, e foi traçado uma curva para cada valor de v . Como o gráfico da Figura 8(c) mostra, o desempenho do preditor WNN VG-RAM teve melhoras globais com o aumento de v , mas atingiu um máximo perto de 88, com $m \times n$ igual a 16×32 , e depois começou a diminuir. Então, foi escolhido 88 como o valor de v .

O gráfico da Figura 8(d) apresenta o impacto de σ sobre o desempenho de preditor WNN VG-RAM. Para produzir os resultados deste gráfico, foi fixado o valor de $|W|$ em 128 e v em 88, e foi traçado uma curva para cada valor de σ considerado. Como o gráfico da Figura 8(d) mostra, o melhor desempenho do preditor WNN VG-RAM ocorreu quando $\sigma = 1$. Então, foi escolhido 1 como o valor de σ .

Assim, a partir das experiências de calibração foram descobertos os melhores parâmetros do preditor WNN VG-RAM que foram: $m \times n$ igual a 16×32 neurônios, $|W|$ igual a 128 sinapses, $u \times v$ igual a 17×88 pixels, e σ igual a 1. É importante notar que, para valores iniciais de parâmetros (a região mais a esquerda dos gráficos da Figura 8), o desempenho do preditor WNN VG-RAM está perto do acaso ($H_R = 50\%$). No entanto, com ajuste, o preditor

WNN VG-RAM é capaz de prever com precisão retornos apropriados para muitas aplicações de mercado de ações.

5.3. PREDIÇÕES DO PREDITOR WNN VG-RAM

Após os experimentos de calibração (Seção 5.2) realizados para encontrar o melhor conjunto de parâmetros do preditor WNN VG-RAM ($m \times n$ igual a 16×32 neurônios, $|W|$ igual a 128 sinapses, $u \times v$ igual a 17×88 pixels e σ igual a 1) foram realizados os experimentos de treino e teste para avaliar a capacidade de predição do preditor WNN VG-RAM, estes estão descritos a seguir.

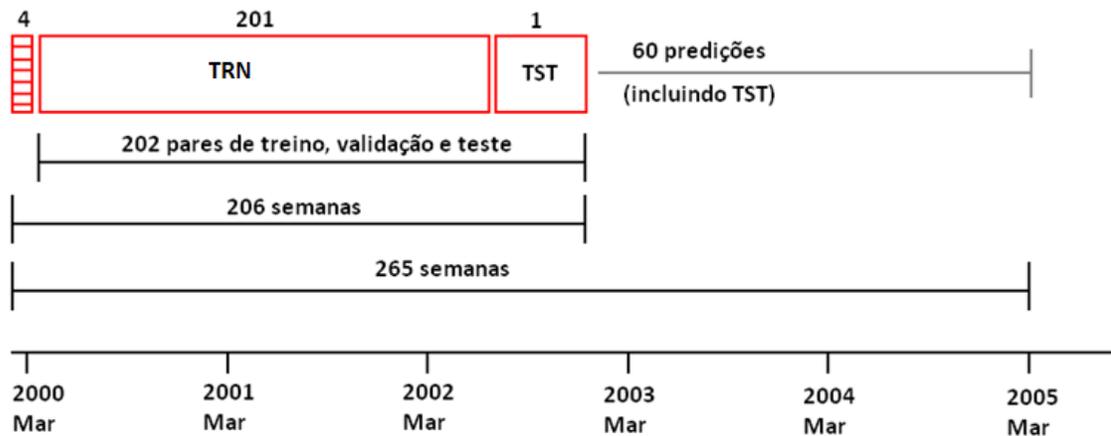


Figura 9 – Janela deslizante para treino e teste do preditor WNN VG-RAM

Para treinar e testar o preditor WNN VG-RAM (após a calibração), assim como reportado por Freitas, De Souza e Almeida (2005), também foi utilizada uma janela deslizante de 206 de 265 retornos semanais disponíveis. Isto permitiu 60 previsões, i.e, 265 retornos (todos os retornos disponíveis) menos 206 (janela deslizante, incluindo os quatro retornos necessários para o primeiro conjunto de entrada do preditor WNN VG-RAM) menos 60 retornos (colocados a parte para o teste), mais um (a predição da janela inicial) (ver Figura 9). Sendo assim, também foram realizadas 2.760 sessões de treinos (60 treinos e ciclos de teste x 46 ações = 2.760). O procedimento de treino e teste foi repetido para todas as 60 previsões avançando a janela deslizante de 206 semanas, uma semana por vez, da mesma maneira realizada no processo de calibração (ver Figura 7).

5.4. RESULTADOS

Um preditor WNN VG-RAM foi treinado e testado para cada uma das 46 ações e usado para obter, para cada, 60 predições de retornos futuros, totalizando 2.760 predições de retornos futuros ($1 \times 46 \times 60 = 2.760$).

A Tabela 5 sumariza o desempenho dos preditores WNN VG-RAM e ARNN(4) de acordo com as métricas descritas na Seção 4.2. Os resultados das predições do preditor WNN VG-RAM são mostrados na Tabela 5(a), enquanto os resultados das predições do preditor ARNN(4), obtidos do trabalho de referência, são mostrados na Tabela 5(b). Os resultados das métricas de avaliação são mostrados nas linhas das tabelas, sendo o valor mínimo (mín), o valor máximo (máx), o valor médio (méd) e o desvio padrão (σ) como colunas da tabela.

A Tabela 5 mostra que a média ME de ambos os preditores foram perto de zero com um baixo desvio padrão indicando predições imparciais. $RMSE$, $MAPE$ e H_R são típicos para este tipo de problema (LIU, 2007; HELLSTROM, 1999). O $RMSE$ de ambos os modelos neurais tiveram desempenho similares. No entanto, WNN VG-RAM foi melhor do que o ARNN(4) nos resultados de $MAPE$, refletido pelo menor máximo e valores médios. Ambos os preditores produziram um H_R médio por volta de 53% e máximo perto de 66%, conseguindo assim um desempenho de pico de 16 pontos percentuais acima do acaso (50%). O desempenho do H_{R+} também foram similares, porém, o preditor WNN VG-RAM teve um H_{R-} com valores mínimos menor que o preditor ARNN(4).

Tabela 5 – Resumo das predições obtidas para as 46 ações (n = 60)

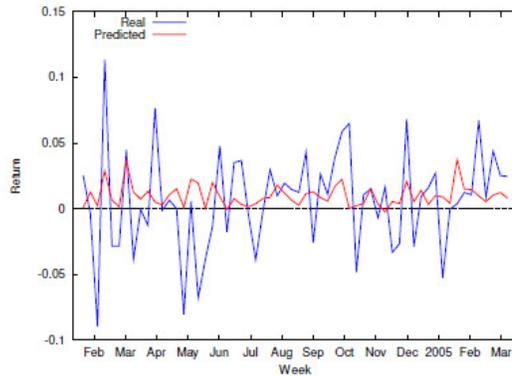
	mín	máx	méd	σ		mín	máx	méd	σ	
<i>ME</i>	-0,0248	0,0100	-0,0047	0,0067		<i>ME</i>	-0,0142	0,0090	-0,0037	0,0052
<i>RMSE</i>	0,0400	0,0800	0,0543	0,0119		<i>RMSE</i>	0,0380	0,0887	0,0544	0,0120
<i>MAPE</i>	0,7500	6,7100	1,6415	0,9830		<i>MAPE</i>	0,7861	307,0927	20,4742	64,2316
<i>H_R</i>	0,4035	0,6552	0,5376	0,0613		<i>H_R</i>	0,3900	0,6600	0,5365	0,0696
<i>H_{R+}</i>	0,3529	0,6250	0,5249	0,0772		<i>H_{R+}</i>	0,3500	0,6600	0,5313	0,0833
<i>H_{R-}</i>	0,0000	1,000	0,3655	0,2266		<i>H_{R-}</i>	0,1100	1,0000	0,4780	0,1492
(a) Predições do preditor WNN VG-RAM					(b) Predições do preditor ARNN(4)					

Os H_R relatados na literatura são geralmente perto de 55% (HELLSTROM, 1999). Em nossos experimentos, em 21 ações das 46 disponíveis os preditores WNN VG-RAM e ARNN (4) ultrapassaram este nível de desempenho. Além disso, em 7 ações o preditor WNN VG-RAM teve H_R maior que 60% e em 9 ações o preditor ARNN (4) teve H_R maior que 60%.

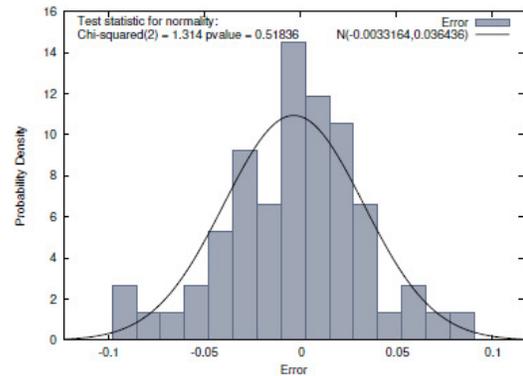
Exceto no ME e H_R de pico, o desempenho das previsões foram semelhantes e modestos — prever a série temporal dos retornos das ações é reconhecida como uma tarefa difícil (HELLSTROM, 1999).

A Figura 10 mostra um exemplo dos resultados das previsões do VG-RAM WNN e ARNN (4) para as ações da PETROBRAS PN (PETR4). A Figura 10(a) e a Figura 10(c) mostram os valores reais e previstos para as 60 semanas, entre 21 de janeiro de 2004 e 9 de março de 2005, e a Figura 10(b) e a Figura 10(d) mostram as distribuições de frequência para os erros de previsão para os preditores VG-RAM WNN e ARNN(4), respectivamente. Como a Figura 10 ilustra, ambos os preditores exibiram comportamento semelhante com relação aos valores preditos e às distribuições de

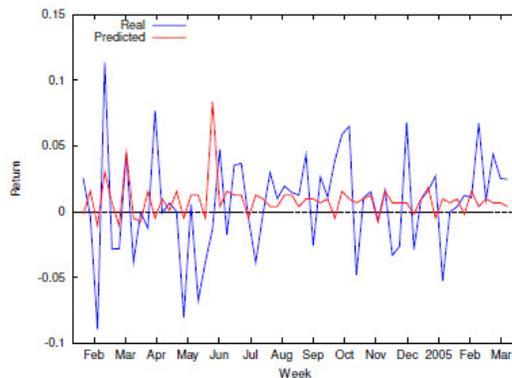
frequência.



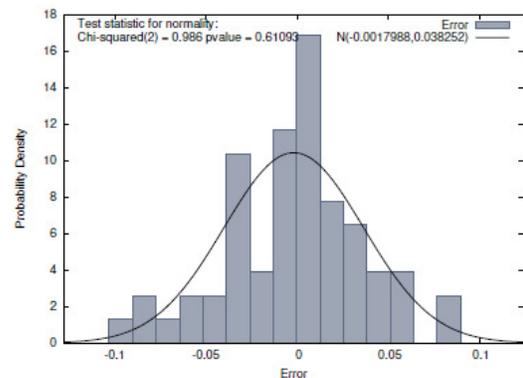
(a) Predições do preditor WNN VG-RAM



(b) Distribuição dos erros de predição do WNN VG-RAM



(c) Predições do preditor ARNN(4)



(d) Distribuição dos erros de predição do ARNN(4)

Figura 10— Predições dos preditores VG-RAM e ARNN(4) para as ações da PETROBRAS PN (PETR4): (a) e (c) retornos reais e preditos, e (b) e (d) a frequência da distribuição dos erros de predição, respectivamente.

5.5. NORMALIDADE DOS ERROS DE PREDIÇÃO

A normalidade dos erros de predição para os preditores WNN VG-RAM e a ARNN(4) foram avaliados e obtive-se os resultados mostrados na Tabela 6 e na Tabela 7, respectivamente. Os testes de *chi-square* das séries dos erros de predição para cada preditor, cada um com 60 observações, foram realizados com níveis de significância padrão (σ) de 0,01; 0,05 e 0,10 com normalidade aceita (i.e, não rejeitadas) para 43 (93%), 40 (87%), e 37 (80%) para preditor WNN VG-RAM, e de 45 (98%), 40 (87%) e 39 (85%) para o preditor ARNN(4).

Tabela 6 – Análise da normalidade dos erros de predição do preditor WNN VG-RAM

σ	H_0 não rejeitado		H_0 rejeitado	
0,01	43	(93%)	3	(7%)

0,05	40	(87%)	6	(13%)
0,10	37	(80%)	9	(20%)

Tabela 7 – Análise da normalidade dos erros de predição do preditor ARNN(4)

σ	H₀ não rejeitado		H₀ rejeitado	
0,01	45	(98%)	1	(2%)
0,05	40	(87%)	6	(13%)
0,10	39	(85%)	7	(15%)

A normalidade das séries de retornos (Seção 5.5) foi aceita para 14 (30%), 6 (13%) e 5 (11%) das séries, respectivamente para os mesmos valores de σ , assim, os resultados sugerem a possibilidade de produzir erros normais de predição a partir de séries não normais de retornos.

5.6. DESEMPENHO COMPUTACIONAL DO PREDITOR WNN VG-RAM⁴

Os experimentos foram realizados utilizando máquinas pessoais com processador Intel Core 2 Duo T8100 (3 MB Cache, 2.10 GHz, 800MHz FSB) e 3GB RAM (DDR-2 800MHz). O preditor ARNN(4) gastou aproximadamente 18.000 segundos (5 horas), na média, para executar as 60 sessões de treino para uma ação (i.e, treinar e prever 60 retornos futuros) usando os métodos descritos da Seção 5.1. O preditor WNN VGRAM, por outro lado, demorou apenas 3.6 segundos em média para realizar a mesma tarefa usando os métodos descritos na Seção 5.3, obtendo um *speedup* de 5000 vezes ($18.000 / 3,6 = 5000$). Isto significa que o preditor WNN VG-RAM pode executar uma sessão de treino e predição de um retorno futuro em apenas 6 milissegundos.

É importante notar que, como o procedimento de calibração, descrito na Seção 5.2, do preditor WNN VGRAM é executado apenas uma vez, este tempo não foi computado no tempo de novas predições.

⁴ Para realizar esta comparação alguns experimentos do trabalho de referência — preditor ARNN(4) (FREITAS; De SOUZA; ALMEIDA, 2005) — foram repetidos com o *software* fornecido pelos autores.

6. DISCUSSÃO

Neste capítulo são apresentados trabalhos correlatos e uma análise crítica deste trabalho de pesquisa.

6.1. TRABALHOS CORRELATOS

Desde o pioneiro trabalho de White (1988), preditores baseados em redes neurais apresentam sucessos quando aplicados na predição de retornos futuros de ações e variáveis financeiras, exibindo muitas vantagens sobre os métodos alternativos (SHARDA; PARTIL, 1992; MOODY, 1994; HANSEN; NELSON, 1997; FREITAS; De SOUZA; ALMEIDA, 2009).

Segundo o nosso melhor conhecimento, este é o primeiro trabalho que emprega redes neurais sem peso na predição de retornos de ações. Contudo, trabalhos similares começam a surgir na literatura. Alhassan e Misra (2011) empregaram WNN na predição de preços de ações do mercado nigeriano e seus resultados apresentaram um erro médio de 0,0086. Nossos preditores WNN apresentaram um erro médio de 0,0047.

Os trabalhos relacionados abaixo não empregam redes neurais sem peso, contudo, demonstram a utilização de redes neurais na extração de características de séries econômico-financeiras para se obter predições no mercado de ações. Estes trabalhos motivaram a investigação da utilização de redes neurais sem peso para predição de retornos de ações.

Freitas (2008) apresenta um modelo de seleção de carteiras baseado em erros de predição que captura oportunidades de investimento no curto prazo. Utiliza preditores neurais autoregressivos com referência móvel para prever os retornos futuros das ações, e uma medida de risco baseada nos seus erros de predição foi derivada de forma a manter a mesma fundamentação estatística do modelo média-variância. Os principais resultados mostraram que é possível obter erros de predição normais a partir de séries de retornos não normais e que o modelo de seleção de carteiras baseado em erros de predição capturou corretamente oportunidades de curto prazo, desempenhando melhor que o modelo média-variância e superando o índice de mercado.

Baba e Kozaki (1992) no qual foi desenvolvido um sistema em redes neurais para predição de preços das ações no mercado japonês. Um algoritmo híbrido, que combina algoritmos *backpropagation* com o método de otimização aleatória para treinamento dos parâmetros da rede neural. Este trabalho demonstrou que vários resultados utilizando redes neurais são bastante úteis para fazer uma boa predição dos preços das ações.

Saad, Prokhorov e Wunsch (1998) apresentam uma técnica de obter informações utilizando aprendizagem de máquina e mineração de dados para avaliar as relações de previsão de numerosas variáveis econômicas e financeiras. Modelos de redes neurais para a estimativa de nível e classificação são analisados por sua capacidade de fornecer uma previsão efetiva de valores futuros.

6.2. ANÁLISE CRÍTICA DESTE TRABALHO DE PESQUISA

Neste trabalho, desenvolvemos um preditor baseado em redes neurais sem peso para predição de retornos de ações 5.000 vezes mais rápido que preditores baseados em rede neural autoregressiva. Porém, para conseguir os resultados apresentados neste trabalho foi necessário um grande trabalho de calibração dos parâmetros da rede conforme explicado na Seção 5.2. Para que seja executado este processo de calibração em tempo viável, é necessário a demanda a utilização de arquiteturas de computadores mais complexas como *clusters* de computadores. Sendo assim, a avaliação de novos tipos de preditores (por exemplo, preditores para detecção de pontos de máximo ou mínimo do preço das ações ou detecção de oscilações semanais do preço das ações) demanda uma nova avaliação dos parâmetros da rede, conseqüentemente, um novo esforço de calibração da rede.

Além disso, calibração de redes neurais sem peso para auxiliar sistemas mais complexos (por exemplo, *trading systems*, que introduz um universo maior de parâmetros para serem calibrados — valor de *stop loss* e *stop gain* — para citar alguns) pode tornar o processo de calibração muito custoso e até inviável para curto período de investimento. Outro aspecto relevante da metodologia de treinamento das WNN é a questão de como se fazer a validação do treinamento, uma vez que os métodos clássicos de treinamento destas redes neurais não se valem deste procedimento. Acreditamos que o desenvolvimento de métodos de validação do treinamento de WNN podem em muito contribuir com a melhoria

dos resultados obtidos nesta aplicação, contudo, tal tarefa não fez parte do escopo de investigação deste trabalho.

7. CONCLUSÃO

7.1. SUMÁRIO

Neste trabalho, foi proposto um novo preditor de séries temporais utilizando uma rede neural sem peso baseada em *Virtual Generalized Random Access Memory* (VG-RAM) para prever o retorno futuro de ações. A arquitetura do preditor de ações WNN VG-RAM é similar à projetada para reconhecimento de faces (De SOUZA et al., 2008). No trabalho de reconhecimento de faces, os neurônios são treinados para informar o código de uma pessoa a partir da sua imagem; similarmente, no preditor WNN VG-RAM, os neurônios são treinados para informar o índice do retorno a partir de uma imagem equivalente para um conjunto de retornos passados.

Este novo preditor de séries temporais baseado em redes neurais sem peso foi empregado na predição do retorno de 46 ações do mercado brasileiro de ações, e suas predições foram avaliadas em relação àquelas produzidas por preditores neurais autoregressivos e reportados por Freitas, De Souza e Almeida (2005). Nossos resultados mostraram que o preditor WNN VG-RAM pode produzir predições de retornos futuros de ações com os mesmos níveis de erros e propriedades do preditor baseado em rede neural autoregressiva, no entanto, executando 5.000 vezes mais rápido — o preditor WNN VG-RAM executou uma sessão de treino e predição de um retorno futuro em apenas 6 milissegundos.

Este trabalho contribuiu com o desenvolvimento de uma arquitetura utilizando redes neurais sem peso para predição de retorno de ações; a avaliação de desempenho do preditor baseado em rede neural sem peso (qualidade das predições e desempenho computacional); a verificação da normalidade dos erros de predição dos preditores neurais sem peso; e, a investigação de um grande conjunto de parâmetros da arquitetura proposta para um preditor baseado em redes neurais sem peso.

7.2. TRABALHOS FUTUROS

Nossos trabalhos futuros incluem:

- Reescrever o código do preditor WNN VG-RAM para que explore o alto poder de processamento das *Graphics Processing Units* (GPU), por exemplo, uma implementação em C+CUDA (*Compute Unified Device Architecture*). Com isso, acreditamos que seja possível realizar o processo de calibração em computadores pessoais fazendo com que seja possível construir sistemas que são calibrados, treinados e testados sem a necessidade de utilização de *clusters* de computadores.
- Como o preditor WNN VG-RAM consegue resultados com qualidade similares aos preditores ARNN(4), porém com velocidade de predição muito maior, logo, surge a possibilidade de criar sistemas que utilizem estas predições para auxiliar investidores no processo de compra e venda de ações (*trading systems*) em investimento de curto e curtíssimo prazo, como, por exemplo, operações *intraday*.
- Desenvolver sistemas automatizados de compra e venda de ações utilizando as predições do preditor WNN VGRAM, ou seja, automatizar todo o processo de análise de mercado e negociação de ativos. O desenvolvimento desse tipo de sistema traz vantagens como: evitar o fator emocional no processo de negociação e economia de tempo do investidor.
- Desenvolver novas arquiteturas baseados no preditor WNN VGRAM para detectar pontos de máximo e mínimo dos preços de ações com o objetivo de maximizar os lucros nas operações.

REFERÊNCIAS BIBLIOGRÁFICAS

ALEKSANDER, I. *RAM-Based Neural Networks. From WISARD to MAGNUS: a Family of Weightless Virtual Neural Machines*. World Scientific. 1998.

ALEKSANDER, I. Self-adaptive universal logic circuits, p.231–232. *IEE Electronic Letters*, 1966.

ALHASSAN, J. K; MISRA, S. Using a weightless neural network to forecast stock prices: A case study of Nigerian stock Exchange. *Scientific Research and Essays*, vol. 6, p. 2934-2940, Jul. 2011.

ARMSTRONG, J. S.; COLLOPY, F. Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, v. 8, n. 1, p. 69–80, 1992.

BABA, N.; KOZAKI, M. An intelligent forecasting system of stock price using neural networks. IJCNN. *International Joint Conference*, p. 371-377, vol.1, 1992.

BEALE, R.; JACKSON, T. *Neural Computing: an Introduction*. Bristol. Adam Hilger, 1990.

BISHOP, C. M. *Neural Networks for Pattern Recognition*. Oxford University Press, 1996.

BOVESPA. Acesso em 09 de Maio de 2011, disponível em BOVESPA: <http://www.bovespa.com.br>

BOVESPA. Acesso em 19 de Junho de 2011, disponível em BOVESPA: http://ri.bmfbovespa.com.br/site/portal_investidores/pt/home/home.aspx

CÂMARA DOS DEPUTADOS. BRASIL. *Código Civil*. 1. Coordenação de Publicações. Série Fontes de Referência. Legislação, n 43. Brasília, 2002.

COOTNER, P. H. *The random character of stock market prices*. MIT Press. 1964. ISBN 9780262030090

De SOUZA, A. F.; BADUE, C. G; PEDRONI, F.; OLIVEIRA, E.; SCHWANZ, S. D; OLIVEIRA, H; SOUZA, F. S. Face recognition with VG-RAM weightless neural networks. *Proceedings of the 18th International Conference on Artificial Neural Networks (ICANN'08)*, p. 209–216, 2008.

De SOUZA, A. F.; PEDRONI, F.; OLIVEIRA, E.; CIARELLI, P. M.; HENRIQUE, W. F.; VERONESE, L. d. Automated Multi-label Text Categorization with VG-RAM Weightless Neural Networks. *Neurocomputing*, p. 2209-2217. Amsterdã, 2009.

ELTON, E.; GRUBER, M.; BROWN, S.; GOETZMANN, W. *Modern Portfolio Theory and*

- Investment Analysis*, 7 ed. John Wiley & Sons, Inc., 2007.
- FAMA, E. F. Efficient capital markets II. *Journal of Finance*, v. 46, n. 5, p. 1575–1617, dez. 1991.
- FAMA, E. F. Efficient capital markets: A review of theory and empirical work. *The Journal of Finance, American Finance Association*, v. 25, n. 2, p. 383–417, maio. 1970. ISSN 0022-1082.
- FAMA, E. F. Market efficiency, long-term returns, and behavioral finance. *Journal of Financial Economics*, v. 49, p. 283–306, 1998.
- FREITAS, F. D. *Modelo de seleção de carteiras baseado em erros de previsão*. 2008.
- FREITAS, F. D.; De SOUZA, A.; ALMEIDA, A. Prediction-based portfolio optimization model using neural networks. *Neurocomputing*, p. 2155–2170, 2009.
- FREITAS, F. D.; De SOUZA, A. F.; ALMEIDA, A. A prediction-based portfolio optimization model. *5th International Symposium On Robotics and Automation — ISRA.*, p. 520–525. Hidalgo, México, 2006.
- FREITAS, F. D.; De SOUZA, A. F.; ALMEIDA, A. Autoregressive neural network predictors in the Brazilian stock market. *VII Simpósio Brasileiro de Automação Inteligente (SBAI)/II IEEE Latin American Robotics Symposium (IEEE-LARS)*. São Luís, Brasil, 2005.
- HAGAN, M.; MENHAJ, M. Training feedforward networks with the Marquardt algorithm. *IEEE Trans. Neural Network*. 1994.
- HANSEN, J.; NELSON, R. Neural networks and traditional time series methods: a synergistic combination in state economic forecasts. . *IEEE Trans. Neural Network*, 10.1109/72.595884, p. 863–873, 1997.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2 ed. Prentice-Hall. 1999.
- HELLSTROM, T. *Data snooping in the stock market. Theory of Stochastic Processes*. vol.5, n. 21, p. 33–50, 1999.
- HENDERSHOTT T.; JONES, C.; MENKVELD, A. Does algorithmic trading improve liquidity. *The Journal of Finance*. 2011.
- KANDEL, S. J. *Principles of Neural Science*, 4 ed. Prentice-Hall International Inc. 2000.
- LIU F, N. G. *RLDDE: A novel reinforcement learning-based dimension and delay estimator for neural networks in time series prediction*, p. 1331–1341, 2007.
- LO, ANDREW; MACKINLEY, A. C. Stock Prices do not follow Random Walks: Evidence from a simple specification test. 1998.

- LO, ANDREW. *A Non-Random Walk Down Wall Street*. Princeton University. Press, 1999. ISBN 0691057745
- LUDERMIR, T.; CARVALHO, A.; BRAGA, A.; SOUTO, M. *Weightless neural models: A review of current and past works*. *Neural Computing Surveys*, p. 41–61, 1999.
- MALKIEL, B. G. The efficient market hypothesis and its critics. *The Journal of Economic Perspectives*. *American Economic Association*, v. 17, n. 1, p. 59–82, 2003. ISSN 0895-3309
- MITCHELL, B. J. *RAM-Based Neural Networks: Comparison of Some Methods for Processing Grey Level Data in Weightless Networks*. World Scientific. 1998.
- MOODY, J. *Prediction risk and architecture selection for neural networks. From Statistics to Neural Networks: Theory and Pattern Recognition Applications*. Springer. 1994.
- MORETTIN, P. A; TOLOI, C. M. C. *Análise de Séries Temporais*. 1. ed.: Editora Edgar Bücher Ltda, 2004.
- MORETTIN, P.A. *Econometria Financeira – Um curso em Séries Temporais Financeiras*. 1. ed.: ABE – Associação Brasileira de Estatística, 2004.
- PAPOULIS, A. *Probability, Random Variables, and Stochastic Processes*, 3 ed. McGraw-Hill, 1991.
- PELTZ, M. Inside the machine: A journey into the world of high-frequency trading. *Institutional Investor*, p. 90–93, 2010.
- SÁ, G. *Mercado de Ações e Bolsa de Valores*. Rio de Janeiro: Aplicação Editora, 1987.
- SAAD, E.; PROKHOROV, D.; WUNSCH, D. I. Comparative study of stock trend prediction using time delay, recurrent and probabilistic neural networks. *Neural Networks, IEEE Transactions*, p. 1456 – 1470, 1998.
- SALGADO, E. Uma questão de milésimos. *Revista Exame*. Edição 0959. Disponível em: <http://exame.abril.com.br/revista-exame/edicoes/0959/noticias/questao-milesimos-521769>. Acesso em: 10 ago. 2011.
- SHARDA, R.; PARTIL, R. A connectionist approach to time series prediction: An empirical test. *Journal of Intelligent Manufacturing*, p. 317–323, 1992.
- STEVENS, J. K. *Reverse Engineering the Brain*. Abril. p. 287–289, 1985.
- WASSERMAN, P. D. *Neural Computing: Theory and Practice*. New York: Van Nostrand Reinhold. 1989.

WHITE, H. Economic prediction using neural networks: The case of IBM daily stock returns. *Proceedings of the IEEE International Conference on Neural Networks*, p. 451–45, 1988.

YOON, Y.; SWALES, G. Predicting stock price performance: a neural network approach. *Proceedings of the Twenty-Fourth Annual Hawaii International Conference*, p. 156 - 162 vol.4. Hawaii, 1991.