

Universidade Federal Fluminense

JOSÉ RICARDO MAGALHÃES RIVERO

Aplicação de Redes Neurais Artificiais para  
Previsão do Comportamento de Ações

VOLTA REDONDA - RJ  
2023

JOSÉ RICARDO MAGALHÃES RIVERO

## Aplicação de Redes Neurais Artificiais para Previsão do Comportamento de Ações.

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional em Ciência e Tecnologia da Universidade Federal Fluminense, como requisito parcial para obtenção do título de Mestre em Modelagem Computacional em Ciência e Tecnologia. Área de Concentração: Modelagem computacional.

Orientador:

Prof. Cleber Almeida Corrêa Junior, D.Sc,

Coorientadora:

Prof<sup>a</sup>. Rosilene Abreu Portella Corrêa, D.Sc.

Universidade Federal Fluminense

VOLTA REDONDA - RJ

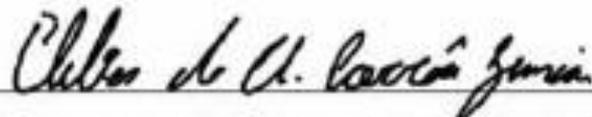
2023

# Aplicação de Redes Neurais Artificiais para Previsão do Comportamento de Ações

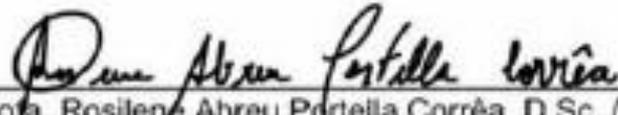
José Ricardo Magalhães Rivero

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional em Ciência e Tecnologia da Universidade Federal Fluminense, como requisito parcial para obtenção do título de Mestre em Modelagem Computacional em Ciência e Tecnologia. Área de Concentração: Modelagem computacional.

Aprovada por:



Prof. Cleber Almeida Corrêa Junior, D.Sc. / UFF



Prof. Rosilene Abreu Portella Corrêa, D.Sc. / UFF



Prof. Panters Rodriguez Bermudez, D.Sc. / UFF



Documento assinado digitalmente  
FÁBIO FREITAS FERREIRA  
Data: 02/12/2023 11:30:29-0300  
Verifique em <https://verificacao.gov.br>

Prof. Fábio Freitas Ferreira, D.Sc. / UFF



Prof. Nelson Machado Barbosa, D.Sc. / UENF



Documento assinado digitalmente  
LUCIANO DOS SANTOS RANGEL  
Data: 04/03/2023 08:40:17-0300  
Verifique em <https://verificacao.gov.br>

Prof. Luciano dos Santos Rangel, D.Sc. / FeMASS

Volta Redonda, 31 de março de 2023

# Agradecimentos

O meu primeiro agradecimento vai a Deus que por ser o criador de todas as coisas me fez capaz de aprender o que me transmitem como conhecimento, capaz de ver a vida sob novos horizontes e capaz de reconhecer e enfrentar todos os desafios que a carreira impõe.

A minha esposa Giovana por todo apoio e compreensão.

Aos meus filhos Lucas e Davi pela paciência nas minhas ausências.

Aos meus pais Juan e Sônia, por sempre acreditarem em mim e me incentivarem.

Aos meus professores e orientadores, Cleber e Rosilene Corrêa, pela disponibilidade, atenção, orientações e diálogo aberto, que não se esquivaram de mostrar os pontos chaves para que eu pudesse atender às exigências que um trabalho como este enseja.

Agradeço também aos demais professores do programa de mestrado, que durante as disciplinas que tive oportunidade de cursar tanto me ensinaram, são eles: saudoso Professor Diomar Cesar Lobão, Professor Gustavo Benitez Alvarez, Professor André Gusso; Professor Wellington Gomes Dantas; Professor Cleyton Senior Stampa; Professor Tiago Araújo Neves, Professor Wagner Rambaldi Telles, por todo ensinamento passado.

Aos colegas de curso, que também tiveram sua participação nesse empreendimento em especial, Dayane Alves, Douglas Oliveira, Matheus Abrahao, Erika Rocha, Marcos Corrêa, Sérgio Cordero Calvimonte e Caíque da Silva Machado.

# Resumo

Dados estatísticos apontam para o fato que a grande maioria da população mundial, mesmo após trabalhar por toda a vida, quando se aposenta, não possui reservas significativas de recursos financeiros de maneira a garantir uma boa qualidade de vida na terceira idade. Tendo em vista que o mercado financeiro de ações oferece uma oportunidade viável para a ampliação de capital ao longo da vida; buscou-se através desse trabalho, desenvolver-se uma técnica inovadora, no que se refere a metodologia aplicada, para permitir um suporte simples e com base em modelos matemáticos, para tomada de decisão por pessoas comuns, de compra ou venda de ações. Isso porque as técnicas que suportam as boas tomadas de decisão serem atualmente complexas e não dominadas amplamente pela maioria da população. O algoritmo proposto para melhor desempenhar essa tarefa, foi o correspondente a uma Rede Neural Artificial do tipo “*Perceptron Multi Camadas*” com *backpropagation*. Pois essa RNA é apropriada para aprendizagem de padrões de séries históricas, que são usualmente o objeto de estudo do comportamento do preço de ações pelas metodologias de análise técnica que são amplamente usadas pelo mercado. Realizou-se, portanto um estudo comparativo entre os resultados encontrados com o uso da metodologia com a RNA proposta versus os resultados obtidos a partir de análise técnica simples e compra e venda guiada pela média aritmética de oito períodos versus operações únicas de compra e venda no período de um ano. Verificou-se que: o modelo RNA utilizado, orientou a obtenção de resultados superiores para operações com as ações testadas, comprovando dessa forma, ser um caminho promissor para a resolução de problemas dessa natureza; relacionados a identificação de padrões matemáticos de séries históricas e do comportamento dos preços de ações da bolsa de valores de São Paulo.

# Abstract

Statistical data indicate that the vast majority of the world's population, even after working their entire lives, do not have significant financial resources to ensure a good quality of life in their old age. Considering that the stock market offers a viable opportunity for capital expansion over one's lifetime, this work aimed to develop an innovative technique, in terms of the applied methodology, to provide simple support based on mathematical models for decision-making by ordinary people, regarding the buying or selling of stocks. This is because the techniques that support good decision-making are currently complex and not widely mastered by the majority of the population. The algorithm proposed to better perform this task was a Multi-Layer Perceptron Artificial Neural Network with backpropagation. This is because this ANN is suitable for pattern learning of historical series, which are usually the object of study for the behavior of stock prices by technical analysis methodologies that are widely used by the market. Therefore, a comparative study was carried out between the results obtained with the use of the methodology with the proposed ANN versus the results obtained from simple technical analysis of buying and selling guided by the eight-period arithmetic mean versus single buying and selling operations within a year. It was found that the used ANN model guided the achievement of superior results for operations with the tested stocks, thus proving to be a promising approach for solving problems of this nature related to the identification of mathematical patterns of historical series and the behavior of stock prices on the São Paulo stock exchange.

# Palavras-chaves

1. Método de Análise Técnica
2. Ações
3. Redes Neurais Artificiais
4. Séries históricas
5. *Perceptron* Multi Camadas
6. *Backpropagation* (retropropagação)
7. Reconhecimento de Padrões
8. Probabilidade de comportamento de séries

# Glossário

|        |   |
|--------|---|
| RNA    | : Redes Neurais Artificiais   |
| PMC    | : Perceptron Multicamadas   |
| AMAR3  | : Papel da empresa Marisa Lojas S.A.  |
| AMBP3  | : Papel da empresa Ambipar Participações e Empreendimentos S.A.                       |
| ENEV3  | : Papel da empresa Eneva S.A.   |
| HASH11 | : Hashdex Nasdaq Crypto Index Fundo de Índice   |
| KEPL3  | : Papel da empresa Kepler Weber S.A.  |
| LAND3  | : Papel da empresa Terra Santa Propriedades Agrícolas S.A.                            |
| RRRP3  | : Papel da empresa 3R Petroleum Óleo e Gás S.A.                                       |
| PRI03  | : Papel da empresa Petro Rio S.A.   |
| SLCE3  | : Papel da empresa SLC Agrícola S.A.  |
| TRPL4  | : Papel da empresa CTEEP - Companhia de Transmissão de Energia Elétrica Paulista S.A. |
| TTEN3  | : Papel da empresa Três Tentos Agroindustrial S.A.                                    |
| USIM5  | : Papel da empresa Usinas Siderúrgicas de Minas Gerais S.A.                           |
| WEGE3  | : Papel da empresa WEG S.A.   |

# Sumário

|  |             |
|--|-------------|
| <b>Lista de Figuras</b>  | <b>viii</b> |
| <b>Lista de Gráficos</b>   | <b>ix</b>   |
| <b>Lista de Tabelas</b>  | <b>x</b>    |
| <b>1 Introdução</b>  | <b>11</b>   |
| <b>2 Revisão Bibliográfica</b>                                   | <b>13</b>   |
| 2.1 Contexto Histórico da Análise Fundamentalista.....           | 13          |
| 2.2 Contexto Histórico da Análise Técnica.....                   | 16          |
| 2.3 Epílogo entre as Análises Técnicas e Fundamentalistas .....  | 18          |
| <b>3 Redes Neurais Artificiais</b>                               | <b>19</b>   |
| 3.1 Algoritmo Backpropagation .....                              | 24          |
| 3.1.1 Derivação do Algoritmo Backpropagation .....               | 27          |
| 3.1.2 Ajuste dos Pesos Sinápticos .....                          | 30          |
| <b>4 Metodologia</b>   | <b>34</b>   |
| 4.1 Conceitos Básicos da Análise Técnica .....                   | 35          |
| 4.2 Definição de uma Arquitetura de Rede Neural Específica ..... | 37          |
| 4.3 Escolha das Ações do BOVESPA.....                            | 38          |
| 4.4 Recuperando dados Históricos .....                           | 39          |
| 4.5 Preparação das Matrizes para a aprendizagem da RNA .....     | 40          |
| 4.6 Aprendizagem da RNA no Matlab.....                           | 42          |
| 4.7 Recuperação dos resultados.....                              | 43          |
| 4.8 Materiais e Metodologia .....                                | 44          |
| 4.9 Objetivos específicos .....                                  | 45          |
| <b>5 Resultados</b>  | <b>46</b>   |
| 5.1 Primeiro papel estudado – PRIO3.....                         | 46          |

|          |   |           |
|----------|---|-----------|
| 5.2      | Segundo papel estudado – AMAR3.....                     | 50        |
| 5.3      | Operação combinada das 2 ações com suporte da RNA ..... | 56        |
| <b>6</b> | <b>Conclusões e trabalhos futuros</b>                   | <b>59</b> |
|          | <b>Referências</b>                                      | <b>61</b> |

# Lista de Figuras

|  |    |
|--|----|
| Figura 3.1: Esquema de um neurônio biológico (Silva et al, 2010 [27]).                               | 19 |
| Figura 3.2: Modelo de Neurônio Artificial (Lopes, 2007 [31]).  | 21 |
| Figura 3.3: Modelo de rede neural (Rao et al, 2006 [33]).  | 23 |
| Figura 3.4: Ilustração de uma Rede PMC (Silva et al, 2010 [27]).                                     | 24 |
| Figura 3.5: Ilustração das duas fases de treinamento da rede PMC (Silva et al, 2010 [27]).           | 25 |
| Figura 3.6: Interpretação Geométrica do Método do Gradiente. (Demidovich et al, 1976 [34]).          | 26 |
| Figura 3.7: Notação para derivação do algoritmo backpropagation (Silva et al, 2010 [27]).            | 27 |
| Figura 3.8: Configuração do neurônio utilizado para derivação do algoritmo (Silva et al, 2010 [27]). | 28 |
| Figura 3.9: Ilustração do método de inserção do termo de momentum (Silva et al, 2010 [27]).          | 33 |
| Figura 4.1: Fluxograma Metodológico Aplicado.  | 34 |
| Figura 4.2: Ilustração dos candles.  | 36 |
| Figura 4.3: Arquitetura da rede neural artificial escolhida para esse trabalho.                      | 38 |
| Figura 4.4: Exemplo da configuração usada para recuperação de dados históricos.                      | 40 |
| Figura 4.5: Ilustração da preparação das matrizes de entrada, saída e teste.                         | 41 |
| Figura 4.6: Exemplo de teste dos resultados.   | 43 |

# Lista de Gráficos

|   |    |
|---|----|
| Gráfico 4.1: Exemplo de Gráfico de ações da WEGE3 com Candles semanais e volumes negociados. Fonte: <a href="https://finance.yahoo.com/">finance.yahoo.com/</a> do dia 16/04/2023 as 9h48. .... | 37 |
| Gráfico 5.1: Gráfico das ações da PRIO3 durante o período analisado. ....   | 47 |
| Gráfico 5.2: Gráfico das ações da AMAR3 durante o período analisado. ....   | 50 |

# Lista de Tabelas

|   |    |
|---|----|
| Tabela 5.1: Operações de compra e venda simples da PRIO3.....   | 47 |
| Tabela 5.2: Resultados operações de compra e venda simples da PRIO3. ....   | 47 |
| Tabela 5.3: Operações usando a Média Aritmética da PRIO3. ....  | 48 |
| Tabela 5.4: Resultados operações usando a Média Aritmética da PRIO3. ....   | 48 |
| Tabela 5.5: Operações usando RNA da PRIO3. ....   | 49 |
| Tabela 5.6: Resultados operações usando RNA da PRIO3.....   | 49 |
| Tabela 5.7: Operações de compra e venda simples da AMAR3. ....  | 51 |
| Tabela 5.8: Resultados operações de compra e venda simples da AMAR3. ....   | 51 |
| Tabela 5.9: Operações usando a Média Aritmética da AMAR3. ....  | 51 |
| Tabela 5.10: Resultados operações usando a Média Aritmética da AMAR3. ....  | 52 |
| Tabela 5.11: Operações usando RNA da AMAR3. ....  | 52 |
| Tabela 5.12: Resultados operações usando RNA da AMAR3. ....   | 53 |
| Tabela 5.13: Operações usando RNA atualizada em 3 meses da AMAR3.....   | 54 |
| Tabela 5.14: Resultados operações usando RNA da AMAR3 com 2ª aprendizagem combinada.....  | 54 |
| Tabela 5.15: Operações usando RNA atualizada em 3 meses da AMAR3, considerando-se operações até sexto mês da primeira aprendizagem. ....                    | 55 |
| Tabela 5.16: Resultados operações usando RNA da AMAR3 com 2ª aprendizagem combinada, considerando-se operações até sexto mês da primeira aprendizagem. .... | 55 |
| Tabela 5.17: Simulação operação da combinada. ....  | 57 |
| Tabela 5.18: Resultados operações combinadas usando RNA. ....   | 58 |

# Capítulo 1

## 1 Introdução

A mais de 20 anos operando de forma amadora o mercado de ações e com baixa disponibilidade de tempo durante o horário administrativo e trabalho, observei inconsistência na obtenção de bons resultados ao longo dos anos. Mesmo considerando orientações de traders conceituados e técnicas simples de compra e venda, o crescimento de capital era muito modesto e por vezes negativo.

Nesse trabalho foi realizada uma revisão bibliográfica das análises técnicas e fundamentalistas contextualizando a origem das mesmas.

Em seguida dissertou-se a respeito do algoritmo de retropropagação e sua origem a partir das redes Perceptron Multi Camadas aplicada nesse trabalho. Bem como se esclareceu como a correção dos pesos sinápticos é a chave para obtermos eficácia na fase de aprendizagem da rede e sua consequente assertividade na previsão do comportamento futuro das ações.

Detalhou-se em seguida toda a nova metodologia proposta e utilizada que partiu desde os conceitos básicos da análise técnica, assando pela definição da arquitetura da RNA, recuperação de séries históricas, aprendizagem da rede, algoritmo em Matlab e a recuperação dos dados obtidos.

Por fim apresentou-se os resultados simulados da utilização da RNA no ano posterior ao da aprendizagem e o quanto ela foi capaz de orientar compra e venda durante o período estudado. Ainda apresentou-se um comparativo de quanto a RNA permitiu um aumento superior de capital do investidor, comparando-se a métodos mais simples de compra e venda.

É importante contextualizarmos a motivação do experimento que realizamos com ações da bolsa de valores de São Paulo.

Segundo Alexandre Wolwacz, Stormer, (2014 [1]), que apontam o problema a ser trabalhado:

- Menos de 2% da população Mundial tem mais de R\$300.000,00 no banco.

- 93% dos americanos chegam aos 65 anos de idade com menos de U\$10.000,00 na conta.
- Trabalhar a vida toda NÃO significa garantir seu futuro.
- O trabalho deve ser associado com uma melhor administração do fruto desse trabalho.

Esses dados nos fazem refletir para o fato que, a conduta profissional típica do cidadão comum, de obter seu sustento através de um trabalho formal remunerado, mesmo ao longo de anos de carreira profissional, não garante uma estabilidade e boa qualidade de vida pós-aposentadoria.

Portanto o modelo proposto por esse trabalho objetiva oferecer uma alternativa viável, que pode ser inclusive compartilhada em comunidades de redes sociais, para profissionais liberais multiplicarem suas economias.

Um dos objetivos desse trabalho é desenvolver e testar uma metodologia que gere dados que possam ser compartilhados, de forma a orientar investidores comuns a obterem um crescimento de seu capital. O que ao longo de uma vida pode ser um contribuidor para pessoas comuns terem uma boa estabilidade financeira após o término de suas carreiras profissionais.

# Capítulo 2

## 2 Revisão Bibliográfica

Segundo encontrado na literatura, existem duas vertentes de apoio a decisão aos investidores em ações:

- Análise Fundamentalista.
- Análise Técnica.

### 2.1 Contexto Histórico da Análise Fundamentalista

A análise fundamentalista nasceu em 1934 a partir da publicação do livro *Security Analysis*, dos autores Graham, B., Dodd, D. L. F. e Cottle, S. (1934 [2]).

Esse conceito de análise se baseia em uma avaliação quantitativa, qualitativa e temporal dos “fundamentos” contábeis de uma empresa. A base está em obter diversos índices e indicadores, dentre eles podemos citar: indicadores econômico-financeiros e indicadores de mercado.

A análise das empresas a partir desses indicadores tem como objetivo a avaliar o desempenho de uma empresa de forma a conhecer, a partir de seus resultados contábeis atuais, qual poderia ser um prognóstico para o futuro dessa própria empresa.

Já na década de 70, surgiu uma nova abordagem para a análise fundamentalista intitulada de análise dinâmica ou modelo Fleuriet, nome herdado do seu criador, um professor francês chamado Michel Fleuriet (2015 [3]). Ela permitiu um olhar diferente sobre as demonstrações financeiras de uma determinada empresa. Este novo modelo é uma abordagem que avalia a forma inteligente de se administrar uma empresa com o foco na sustentabilidade financeira e econômica de curto e longo prazo, que tem como fundamento tanto a situação de liquidez quanto a dinâmica operacional de uma empresa. Consiste de, a partir da reclassificação das contas

patrimoniais, principalmente do circulante, são dimensionadas três variáveis, cuja combinação permite identificar a situação financeira, baseada no tipo de estrutura financeira de uma empresa, bem como prever possíveis tendências futuras do seu desempenho.

Portanto a análise fundamentalista clássica e dinâmica são modelos que buscam identificar instrumentos que possam aumentar o grau de previsão do desempenho futuro de uma empresa. Quanto mais efetivos forem esses instrumentos, melhor será o retorno dos investidores do mercado de ações.

Efetuada-se uma pesquisa bibliográfica sobre estudos tanto teóricos, quanto empíricos, listou-se de forma cronológica, os seguintes conceitos:

Os autores Ball e Brown (1968 [4]) e Beaver (1968 [5]) foram pioneiros em afirmar que margens de lucro importantes e inesperadas estão relacionadas positivamente com retornos acima da média e que, portanto, a informação contábil tem relação com a determinação do desempenho financeiro das empresas.

Nesse mesmo ano, Altman (1968 [6]) acrescentou que a análise das demonstrações financeiras e o uso de indicadores, propiciam avaliações do patrimônio da empresa e das decisões tomadas, tanto em relação ao passado, o que é retratado nos seus demonstrativos, como em relação ao futuro, de certa forma apoiado no orçamento financeiro e no preço corrente da ação no mercado.

O autor Fama (1970 [7]) escreveu que um dos objetivos da análise fundamentalista é o de identificar se o preço corrente atual das ações corresponde ao valor real da mesma, isso a partir da análise dos dados obtidos de seus respectivos demonstrativos contábeis. Ele afirmou ainda que: com esse objetivo, qualquer informação relevante deve ser avaliada e precificada.

Já os autores, Collins e Kothari (1989 [8]), Ou e Penman (1989a [9], 1989b [10]) analisaram a correlação entre o retorno acionário e as margens de lucro, bem como identificaram índices econômico-financeiros úteis na previsão dos lucros e do retorno acionário.

Lev e Thiagarajan (1993 [11]) ressaltaram como o foco da análise fundamentalista a determinação do valor real de uma ação, com base em informações sobre risco, lucro, crescimento e posicionamento competitivo de uma determinada empresa.

Posteriormente, Abarbanell e Bushee (1998 [12]) examinaram a aplicação da análise fundamentalista na montagem de carteiras de ações de empresas que obtiveram retornos significativos acima da média.

Beneish, Lee e Tarpley (2001 [13]) aplicaram técnicas de análise fundamentalista em dois estágios, para prever retornos extremos de ações. Os resultados deles mostraram que uma combinação de variáveis relacionadas ao mercado e baseadas em contabilidade, têm um poder preditivo significativo. Discernir prováveis executores extremos de preços de 4 a 6 meses antes do movimento do preço foi observado. Foi verificado que os sinais fundamentais baseados em contabilidade, são mais úteis para separar potenciais extremos de vencedores de perdedores também extremos.

Liu, Nissim e Thomaz (2002 [14]) bem como Ertirmur, Livnat e Martikainen (2003 [15]) respectivamente estudaram a correlação entre o retorno acionário e a receita de vendas das empresas. Descobriram que múltiplos baseados em lucros futuros explicam razoavelmente os preços das ações porém as vendas têm pior desempenho em termos de correlação com retorno acionário.

Nichols e Wahlen (2004 [16]) constataram que o retorno das ações está relacionado com a direção e a magnitude das mudanças nos lucros e com o fluxo de caixa das operações. E ainda que, normalmente o mercado possui a capacidade de antecipar muitas das informações nos anúncios dos lucros de empresas com resultados dentro da média, mas tem uma resposta imprecisa quando se trata de empresas com lucros extraordinários acima da média, o que são na realidade as mais atrativas em termos de retornos financeiros para os investidores. Entende-se que nesses casos a combinação da análise fundamentalista com a análise técnica permitiria um melhor desempenho de investimentos em empresas com lucros extraordinários citada acima.

Jegadeesh e Livnat (2006 [17]) estudaram também a correlação entre a receita de vendas, o retorno acionário e o conseqüente lucro das empresas. Eles evidenciaram que o mercado não reage às informações que as surpresas de receita transmitem, no momento em que são anunciadas.

Zhang e Chen (2007 [18]) declararam que variação nos indicadores oriundos de demonstrativos contábeis que correspondem as bases de análises fundamentalistas, podem sim impactar os preços correntes das ações de uma respectiva empresa.

Sandhar (2010 [19]) ponderou que os índices econômico-financeiros não são os melhores preditores do retorno acionário, uma vez que a rentabilidade de uma empresa pode ser afetada por diversos outros fatores.

## **2.2 Contexto Histórico da Análise Técnica**

A Análise técnica está baseada no estudo da evolução de preços de mercado dos ativos ao longo do tempo. Ela consiste em uma ferramenta utilizada tanto por amadores como por profissionais, conhecidos como traders, operadores ou negociantes de ações no mercado. Essa ferramenta leva como base a oferta e procura de ativos financeiros com o objetivo de se obter lucro através da identificação dos melhores pontos possíveis de entrada, entende-se ponto de compra e saída, entende-se ponto de venda de ações. Segundo a Teoria de Dow, os preços dos ativos refletem a reação do mercado em relação a qualquer evento, estando todas as informações relevantes disponíveis sobre um determinado ativo já contidas em seu preço.

Segundo Raut (2020 [20]), a análise técnica surgiu no século XVIII com Munehisa Homma, nascido em 1724 e que faleceu em 1803 em Sakata no Japão, após ele herdar os negócios de sua família com a morte de seu pai na bolsa de arroz de Dojima. Munehisa fazia uso de um sistema gráfico que veio ficar conhecido como Candlesstick.

Já no século XIX surgiu a Análise Técnica como conhecemos hoje, Charles Dow criou o “Índice Dow Jones” que serviu de um indicador da tendência geral do mercado de ações conforme Noronha (1995 [21]).

Efetuada-se uma pesquisa bibliográfica sobre estudos a respeito da análise técnica, listou-se de forma cronológica os seguintes pontos:

Murphy (1986 [22]) declarou que a Análise Técnica é um enfoque a previsão do mercado de ações que tem como fundamento o estudo do passado associado ao comportamento humano e a lei das probabilidades. Murphy declarou também que se trata do estudo do mercado a partir do uso de gráficos com foco em prever futuras movimentações de preços.

Malkiel (1991 [23]) declarou que os gráficos contam apenas o que os investidores tem feito no passado. Porém salientou que a esperança da análise gráfica

está na possibilidade de a partir de um estudo minucioso do que os investidores fizeram, poder antecipar ou prever o que a multidão de investidores tenderá a fazer no futuro. O autor citou ainda que os defensores da Análise Técnica acreditam que o mercado é 10% lógico e 90% psicológico, o que é um conceito inverso do pensamento dos defensores da Análise fundamentalista que acreditam que o mercado é 90% lógico e 10% psicológico.

Edwards, Magee e Bassetti (2001, p.77 [24]) argumentaram que o preço do mercado reflete não apenas as diferentes opiniões sobre valor dos analistas de ações, mas também todas as esperanças, medos, suposições e humores racionais e irracionais de centenas de compradores e vendedores, assim como suas necessidades e recursos. Em síntese, fatores que desafiam análises e para os quais não existiria estatística, mas que são todos sintetizados, pesados e expressos em uma única cifra, o preço. E portanto, alegaram que o preço seria a única cifra realmente conta para as análises.

Pring (2002 [25]) afirmou que o enfoque da Análise Técnica para os investimentos é essencialmente uma reflexão da ideia que os preços se movem em tendências que são determinadas pelas mudanças de atitudes dos investidores em relação a uma variedade de forças econômicas, monetárias, políticas e psicológicas. A arte da análise técnica, pois isso é uma arte, é identificar a reversão de uma tendência em seu estágio inicial e “cavalgar” essa tendência até que o peso das evidências mostre ou prove que a tendência reverteu.

Botelho (2003 [26]) argumentou que a Análise Técnica é mais uma arte do que uma ciência exata. Essa análise procura interpretar o comportamento atual da massa que corresponde à média das opiniões de todos os compradores e vendedores do mercado de ações. Busca-se encontrar indicações lógicas sobre a tendência do mercado para poder concluir para onde irão os preços de determinadas ações. O autor associa essas tendências diretamente a comportamentos humanos.

## 2.3 Epílogo entre as Análises Técnicas e Fundamentalistas

Como dito por Murphy (1986, p.5 [22]):

Enquanto a análise técnica se concentra no estudo da ação do mercado, a análise fundamentalista focaliza as forças econômicas da oferta e procura que fazem com que os preços aumentem, diminuam ou permaneçam estáveis.

Ambos os enfoques para a previsão de mercados visam à solução do mesmo problema, isto é, determinar a provável direção da evolução dos preços. Apenas enfocam o problema sob ângulos diferentes. O fundamentalista estuda a causa do movimento do mercado, enquanto que o grafista da análise técnica estuda o efeito.

Entende-se, portanto que as duas perspectivas de análises podem, entretanto ser complementares no auxílio à tomada de decisões de compra e venda de ações.

## Capítulo 3

### 3 Redes Neurais Artificiais

Apresentamos nesse trabalho a metodologia de aplicação de Redes Neurais Artificiais no processo de previsão do comportamento de ações a partir de dados oriundos de séries históricas dos preços e volumes negociados de ações presentes no Bovespa, Bolsa de valores de São Paulo. As RNA's são na realidade modelos computacionais que objetivam simular matematicamente o comportamento de sistemas nervosos biológicos dos seres humanos. Esses modelos de RNA's possuem características de adaptação por experiência, capacidade de aprendizado, habilidade de generalização, tolerância a falhas e facilidade de interpretação de suas arquiteturas, características essas que são muito relevantes conforme descrito por Silva, Spatti e Flauzino (2010 [27]).

Os Neurônios são as células biológicas principais do sistema nervoso, chamadas também de unidades básicas desse sistema. Conforme a Figura 3.1, um Neurônio é basicamente composto de dendritos, que são que terminais de entrada de informações; o corpo celular, que tem a função de processar as informações e por fim, o axônio, que corresponde aos terminais de saída responsável por conduzir as informações entre diferentes neurônios.

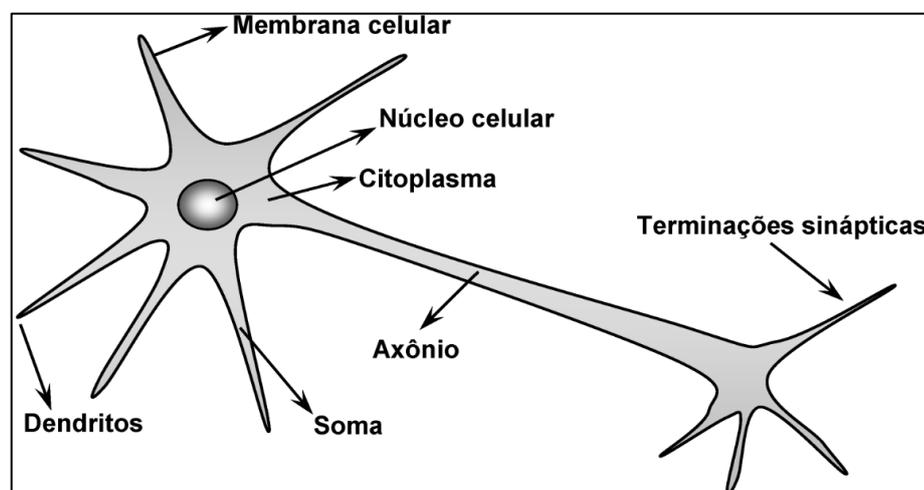


Figura 3.1: Esquema de um neurônio biológico (Silva et al, 2010 [27]).

Conforme Zorzetto (2012 [28]), “A contagem das células revelou que o cérebro humano tem, em média, 86 bilhões de neurônios”. Esse número é 14% menor que o estimado antes e próximo ao proposto por Williams e Herrup (1988 [29]), da Universidade Rutgers, Nova Jersey, EUA. Além disso, o mesmo artigo revela mais dois aspectos interessantes e curiosos do cérebro humano: o primeiro é sua desarmonia em relação à quantidade de neurônios versus o peso do cérebro em si.

Zorzetto (2012 [28]), continua esclarecendo que o componente menor do cérebro, intitulado cerebelo, que tem como sentido original do Latim, de “pequeno cérebro”. Já o cérebro propriamente dito, tem 1.200 gramas e ocupa mais da metade do crânio, mas abriga apenas 16 bilhões de neurônios versus 69 bilhões de neurônios do cerebelo, com seus apenas 150 gramas. Entenda-se neurônios como unidades básicas de processamento de dados. Conclui-se, portanto a partir desses fatos que o tamanho de um órgão não representa em si uma maior capacidade de processamento.

Já a segunda curiosidade se refere à quantidade de outros tipos celulares no cérebro, como a das células “da glia”. Essas células, antes consideradas apenas suporte físico dos neurônios, desempenham outras funções essenciais, como as de auxiliar na transmissão dos impulsos nervosos, nutrir os neurônios, defender o sistema nervoso central de microrganismos invasores e de também o de ocupar espaço obviamente.

Um dogma antigo era de que o total de “células da glia” superava em 10 vezes o de neurônios, o que originou a ideia de que só usamos 10% do cérebro. Entretanto, essa taxa elevada de células da glia permanecia sendo ensinada em livros didáticos, embora experimentos mais atuais já indicassem que a proporção correta na realidade é de 1 para 1, vide referência de Helen Barbas (2009), da Universidade de Boston.

Mais do que o número de células da glia, que são de 85 bilhões nos seres humanos, mais concentradas no cérebro que no cerebelo, o que mais surpreendeu foi o fato de que elas praticamente não sofreram mudanças morfológicas durante a dita “evolução”. O tamanho delas é quase constante entre os primatas e humanos, enquanto o dos neurônios varia até em 250 vezes. A pesquisadora chegou a afirmar que: “O funcionamento das células da glia deve estar ajustado de modo tão fundamental, que a natureza eliminou qualquer mudança que tenha surgido”. Essa afirmação leva a interpretar que somente uma parte do organismo cerebral teria

evoluído e outra parte vital já teria “hipoteticamente surgido” tão bem elaborada que dispensou a necessidade de evoluir, realmente intrigante tal afirmação.

O fato é que podemos cientificamente afirmar que usamos 100% do cérebro, e não apenas 10% como podíamos imaginar antigamente; apenas deve-se entender que cerca de 50% da massa cerebral tem o papel do processamento de dados propriamente dito, atividade executada pelos neurônios e os outros 50%, composto de células da glia, tem outros papéis igualmente importantes e necessários a manutenção de todo o sistema. Portanto, pode-se dizer que o sistema neurológico é composto de elementos celulares complexos qualitativamente e quantitativamente falando.

Já os neurônios artificiais são modelos matemáticos simplificados dos neurônios biológicos. Assim como as Redes Neurais Artificiais que de uma forma matemática mais simplificada que as redes biológicas, visam simular o comportamento de um sistema neural natural humano bem como seu processo de aprendizagem.

Na Figura 3.2 podemos ver um neurônio artificial simplificado. Onde a soma do produto de todas as entradas com seus respectivos pesos pode ser representada também pela equação (1) abaixo:

$$net_j = \sum_{i=1}^n x_i w_{ij} \quad (1)$$

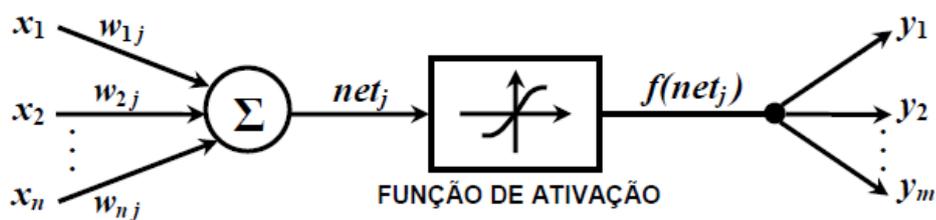


Figura 3.2: Modelo de Neurônio Artificial (Lopes, 2007 [31]).

Nesse modelo, os dendritos são representados pelos sinais de entrada  $x_1, \dots, x_n$ ; já os valores  $w_{1j}, \dots, w_{nj}$  representam os pesos sinápticos. O símbolo  $\Sigma$  representa a combinação linear que agrega todos os sinais de entrada que foram ponderados pelos pesos sinápticos que resultam no valor  $net_j$ , que é o valor de entrada da função de ativação, que por sua vez filtra a entrada ativando ou inibindo o neurônio. Já

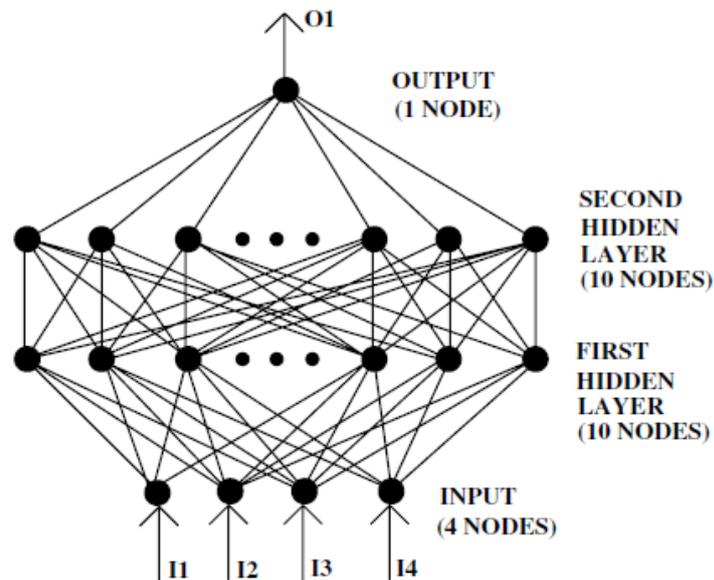
$f(\text{net}_j)$  é o valor de saída da função quando ativado o neurônio, que resulta nos  $m$  terminais de saída  $y_1, \dots, y_m$ .

Segundo Rao e Ghorpade (2006 [33]), as redes neurais artificiais são modelos computacionais de organismos neurobiológicos e que ainda um neurônio artificial, nada mais é que uma simulação matemática de um real neurônio biológico.

Um neurônio artificial pode usualmente realizar apenas uma função matemática simples, como a de somar ou comparar dois valores. Um neurônio artificial típico recebe entradas ou de outros neurônios ou diretamente do ambiente, ou seja, nós de entrada, equivalente aos dendritos organicamente falando. Os caminhos que conectam os nós de entrada aos neurônios e as conexões entre os vários neurônios estão associados a um certo peso variável, que representa um fator de multiplicação para o sinal de entrada que representa o que citamos acima como peso sináptico da conexão. Esses pesos são inicialmente definidos com valores aleatórios e são posteriormente ajustados no processo de treinamento da rede em um modelo de retropropagação. Exemplificando o processo, o neurônio artificial então soma as entradas, que são na verdade uma soma ponderada de todos os sinais de entrada. A entrada assim obtida é usada para calcular um valor do nó de acordo com a “função de ativação” do neurônio. Este valor somatório do nó é então comparado com o valor limite do neurônio, se o valor do nó for mais alto, então o neurônio vai para o “estado de excitação” e o sinal é passado para a próxima camada de neurônios.

Uma rede neural artificial é desenvolvida usando um número de neurônios artificiais pelo método de tentativa e erro. Muitas configurações diferentes de neurônios artificiais podem ser feitas para desenvolver diferentes redes de trabalho. Portanto a configuração de uma RNA é desenvolvida por tentativa e erro. E a mesma é posteriormente treinada usando-se um algoritmo de aprendizagem predeterminado.

Um exemplo de rede de retropropagação multicamadas, escolhida para o presente estudo é mostrada na Figura 3.3.



#### LEGEND

**O1 : OUTPUT: STRESS LEVEL**  
**I1 : INPUT : INTERFACE STRENGTH**  
**I2 : INPUT : SQUARE TERM OF INTERFACE STRENGTH (*derived term*)**  
**I3 : INPUT : FAILURE MODE**  
**I4 : INPUT : STRAIN LEVEL**

Figura 3.3: Modelo de rede neural (Rao et al, 2006 [33]).

A rede acima consiste de uma entrada, uma saída e duas camadas ocultas intermediárias. Cada camada consiste em um ou mais neurônios. Dos nós de entrada se recebem os sinais de entrada na forma de sinais de excitação normalizados. Esta entrada é posteriormente processada dentro da rede, passando-o para a camada superior ou para a saída. A entrada para os nós de cada camada passa pelos neurônios na camada inferior através de sua respectiva força de conexão. Essas forças de conexão são chamadas de pesos sinápticos. Na abordagem geral, esses pesos são definidos inicialmente com valores aleatórios. Esses valores são então modificados automaticamente de acordo com o algoritmo de aprendizagem, durante o processo de aprendizagem propriamente dito. Este tipo de aprendizagem requer um pesado número de ciclos de treinamento, dependendo do tamanho dos dados de treinamento, sua não linearidade e tamanho da rede.

### 3.1 Algoritmo Backpropagation

Antes de falar do algoritmo Backpropagation propriamente dito, tem-se que citar primeiramente sua origem nas Redes Perceptron de Multicamadas (PMC). Esse tipo de rede é caracterizada pela presença de pelo menos uma camada intermediária de neurônios escondida, que fica posicionada entre a camada de entrada e saída. Portanto essas redes possuem pelo menos duas camadas de neurônios antes da saída.

As redes tipo PMC são bastante versáteis quanto às possibilidades de aplicação em diferentes tipos de problemas como os de aproximação de funções, otimização de sistemas, identificação e controle de processos e ainda tanto para reconhecimento de padrões quanto para previsão de séries temporais, essas duas últimas aplicações são as que realmente nos interessam no estudo previsão do comportamento de ações da bolsa de valores.

As redes PMC possuem a arquitetura feedforward, o que significa que o fluxo de informações que se inicia na camada de entrada e percorre uma ou mais camadas intermediárias e finaliza seu percurso na camada de saída, segue seu fluxo em uma só direção, portanto sem nenhum tipo de retroalimentação, conforme Figura 3.4.

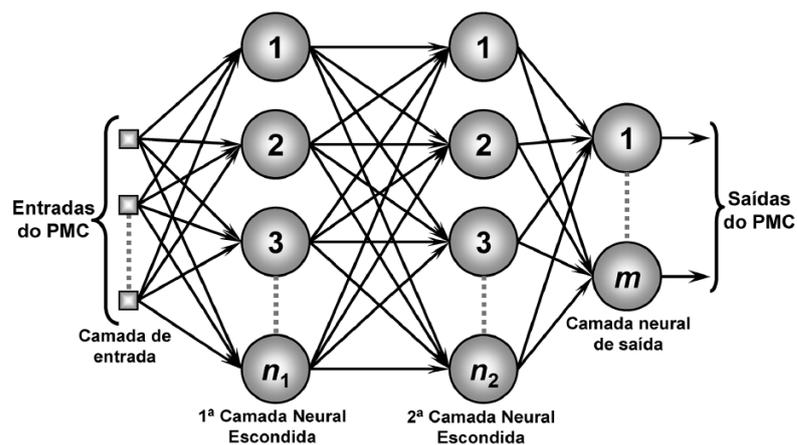


Figura 3.4: Ilustração de uma Rede PMC (Silva et al, 2010 [27]).

A figura acima ilustra um tipo de rede “Perceptron” conhecida como “Adaline”, a mesma consiste em uma topologia que possui uma rede de saída, que pode ser composta de diversos ( $m$ ) neurônios.

A questão central de aplicação de uma rede para a resolução de um determinado problema, se encontra da escolha da melhor topologia da rede que se permita obter os resultados com menor erro e mais assertivos. Essa questão se refere à escolha da quantidade de camadas intermediárias, bem como da quantidade de seus respectivos neurônios, por exemplo. A escolha da topologia da rede depende de diversos fatores como a classe do problema a ser solucionado, a disposição espacial das amostras e os valores iniciais atribuídos bem como seus pesos sinápticos, conforme descrito por Lopes (2010 [32]).

Porém, mesmo que se escolha a melhor topologia de uma rede PMC para um determinado problema, a escolha dos melhores valores para os pesos sinápticos desde a primeira iteração é uma tarefa, na grande maioria das vezes, de extrema dificuldade. Para contornar essa situação é que se aplica o treinamento supervisionado associado ao algoritmo de aprendizagem intitulado Backpropagation ou algoritmo de retropropagação do erro. Pois dessa forma é possível a partir da avaliação do erro na saída, retroalimentar o algoritmo corrigindo-se os pesos sinápticos para a obtenção de um resultado cada vez mais próximo da solução do problema a cada iteração do sistema.

Esse processo de treinamento das redes PMC utilizando-se o algoritmo de retropropagação pode ser descrito por duas fases específicas: a primeira fase é a propagação a diante “forward” e a segunda fase é a propagação reversa “backward”.

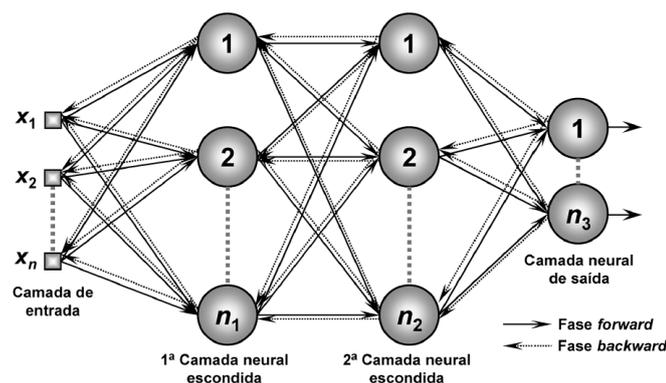


Figura 3.5: Ilustração das duas fases de treinamento da rede PMC (Silva et al, 2010 [27]).

Conforme ilustrado na Figura 3.5, na primeira fase, que consiste na propagação adiante, os sinais de entrada,  $\{X_1 a X_n\}$  oriundos de uma amostra do

conjunto de treinamento são aplicados aos neurônios da camada de entrada e propagados a primeira camada, posteriormente a segunda camada e finalmente produzem suas respectivas saídas na última camada intitulada “Camada neural de saída”. Vale ressaltar que nessa fase de propagação as respostas são obtidas através dos valores iniciais dos pesos simpáticos e limiares de seus neurônios, portanto esses permanecerão inalterados a cada execução dessa mesma fase.

Como se trata de um processo de aprendizado supervisionado, logo após essa primeira fase, as respostas obtidas serão comparadas com as respostas já disponíveis e seus respectivos erros calculados. O resultado desses cálculos será posteriormente utilizado para ajustar tanto os pesos sinópticos quanto os limiares de todos os neurônios do sistema. Justamente esse ajuste é que corresponde à segunda fase citada, a “propagação reversa”.

Segundo Lopes (2010 [32]), durante a programação do algoritmo backpropagation, aplicam-se as atualizações dos pesos sinápticos na direção negativa do gradiente da função de erro quadrático.

Podemos entender o Método do Gradiente pela interpretação geométrica da Figura 3.6 onde o  $X^0$  seria um ponto sobre a superfície mais externa circular fechada  $U(X^0)$ . O gradiente negativo é a direção perpendicular que encontra  $X^1$  de modo que  $U(X^1)$  seja menor que  $U(X^0)$ . E  $\lambda$  a distância percorrida entre  $X^0$  e  $X^1$ .

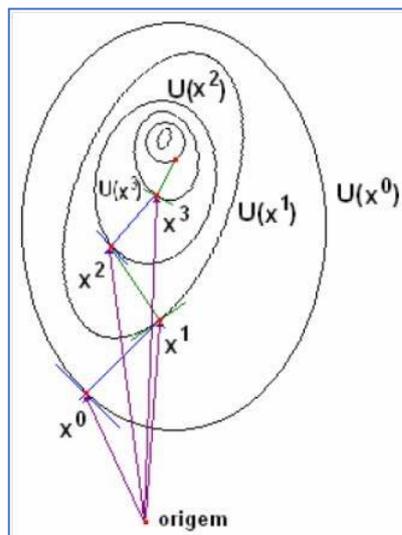


Figura 3.6: Interpretação Geométrica do Método do Gradiente. (Demidovich et al,1976 [34]).

Em síntese o método do gradiente, aplicado para a atualização dos pesos sinápticos, permite a cada nova iteração, que se chegue cada vez mais próximo da solução do problema ou modelo pois a cada iteração se diminui o erro da saída do sistema.

Portanto é correto afirmar que as sucessivas fases de “propagação adiante” e “propagação reversa” permitem que os pesos sinápticos e limiares dos neurônios sejam ajustados a cada iteração; ocasionando uma gradativa redução na soma dos erros entre as respostas da rede comparados as respostas desejadas, conhecidas previamente.

### 3.1.1 Derivação do Algoritmo Backpropagation

Vamos exemplificar matematicamente a derivação do algoritmo *backpropagation*, definindo para tanto diversas variáveis para a topologia da Figura 3.7 a seguir. Ainda vamos considerar cada um dos neurônios pertencentes a cada camada considerado conforme a terminologia da Figura 3.8, onde a função de ativação contínua e diferenciável em todo seu domínio é representada como sendo  $g(\cdot)$ .

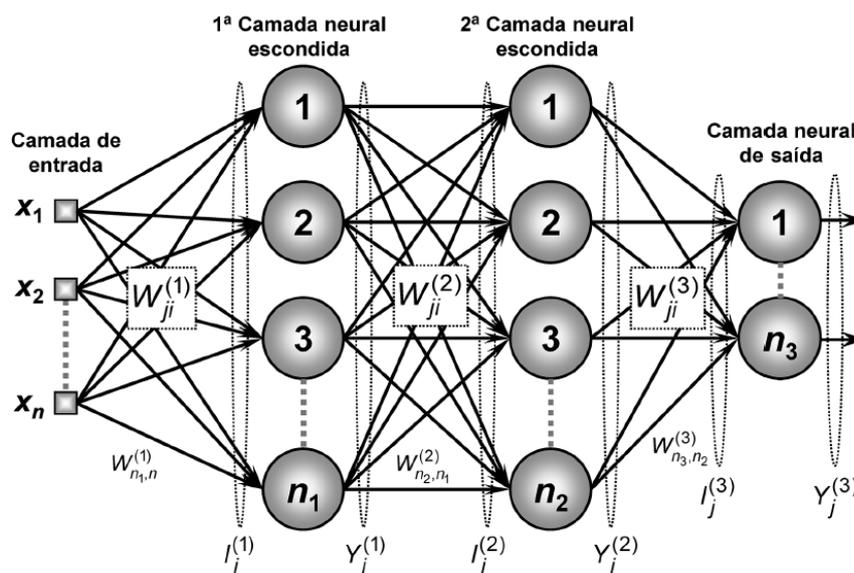


Figura 3.7: Notação para derivação do algoritmo backpropagation (Silva et al, 2010 [27]).

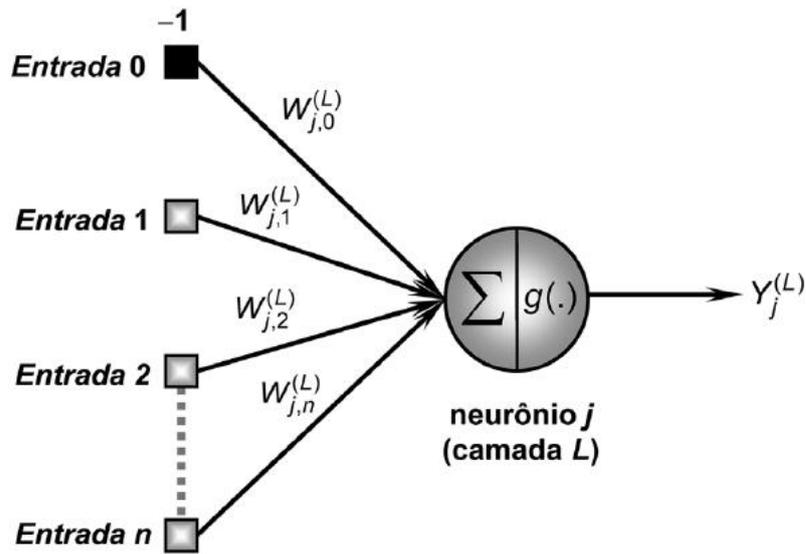


Figura 3.8: Configuração do neurônio utilizado para derivação do algoritmo (Silva et al, 2010 [27])

Com base nas duas figuras acima Figura 3.7 e Figura 3.8, podemos descrever matematicamente a seguinte equação:

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i \quad (3.1)$$

Sendo que  $I_j^{(1)}$  o vetor cujo os elementos correspondem a entrada ponderada em relação ao  $j$ -ésimo neurônio da primeira camada. Ele corresponde ao somatório da matriz de pesos sinápticos  $W_{ji}^{(1)}$  composta do valor do peso conectando o  $j$ -ésimo peso sináptico de cada neurônio da camada de entrada (1) ao  $i$ -ésimo sinal das entradas provenientes da camada de entrada multiplicado pela matriz dos valores  $x_i$  da  $i$ -ésima entrada da camada de entrada.

$$I_j^{(2)} = \sum_{i=0}^n W_{ji}^{(2)} \cdot Y_i^{(1)} \quad (3.2)$$

Já  $I_j^{(2)}$  corresponde ao vetor dos elementos que correspondem a entrada ponderada em relação ao  $j$ -ésimo neurônio da primeira camada escondida. Ele corresponde ao somatório da matriz de pesos sinápticos composta do valor do peso conectando o  $j$ -ésimo sinal de cada neurônio da primeira camada escondida ao  $i$ -

ésimo sinal da camada (2) multiplicado pela matriz dos valores  $Y_j^{(1)}$  do j-ésimo neurônio de saída da primeira camada escondida.

$$I_j^{(3)} = \sum_{i=0}^n W_{ji}^{(3)} \cdot Y_i^{(2)} \quad (3.3)$$

E por último  $I_j^{(3)}$  corresponde ao vetor dos elementos correspondem a entrada ponderada em relação ao j-ésimo neurônio da segunda camada escondida. Ele corresponde ao somatório da matriz de pesos sinápticos composta do valor do peso conectando o j-ésimo de cada neurônio da segunda camada escondida ao i-ésimo sinal da camada (3), multiplicado pela matriz dos valores  $Y_j^{(2)}$  do j-ésimo neurônio de saída da segunda camada escondida.

Salienta-se ainda que o vetor de saída desse sistema corresponde ao vetor  $I_j^{(3)}$  aplicado a função de transferência de cada neurônio da camada de saída, conforme equação abaixo:

$$Y_j^{(3)} = g(I_j^{(3)}) \quad (3.4)$$

Uma vez que se obtém os valores da saída do sistema, resultado da propagação a diante “forward”, passa-se a etapa de cálculo do erro, que permitirá a correção dos pesos sinápticos e o início da fase de propagação reversa “backward”, conforme descrito anteriormente.

O erro consiste em medir o desvio entre os valores previamente conhecidos e as respostas produzidas pelos neurônios de saída da rede. A equação 3.5 abaixo descreve o vetor de erros a ser aplicado.

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (3.5)$$

Onde  $d_j$  consiste nos valores previamente conhecidos e  $Y_j^{(3)}(k)$  consiste no valor de saída do j-ésimo neurônio de saída considerando-se a k-ésima amostra de treinamento.

Já a medição da evolução do desempenho global do algoritmo backpropagation pode ser descrita, para o um conjunto de treinamento de “p” amostras, pela equação 3.6 do erro médio total quadrático:

$$E_M = \frac{1}{2} \sum_{k=1}^p E(k) \quad (3.6)$$

### 3.1.2 Ajuste dos Pesos Sinápticos

Chegamos então à etapa de ajuste, etapa essa muito importante do backpropagation pois consiste em ajustar os pesos sinápticos objetivando minimizar o erro entre as saídas produzidas inicialmente pela rede, na direção das suas respectivas saídas desejadas e conhecidas, caso de uma rede supervisionada. Porém, como essa correção ou ajuste é realizado?

Partindo-se da definição de gradiente podemos definir para acamada de saída que:

$$\nabla E^{(3)} = \frac{\partial E}{\partial W_{ji}^{(3)}} \quad (3.7)$$

Aplicando-se a regra de diferenciação da cadeia e a partir das definições (3.5), (3.4) e (3.3) pode definir que:

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \cdot \frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} \quad (3.8)$$

E ainda que:

$$\frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} = Y_i^{(2)}; \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} = g'(I_j^{(3)}); \frac{\partial E}{\partial Y_j^{(3)}} = -(d_j - Y_j^{(3)}) \quad (3.9)$$

Portanto podemos escrever:

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \cdot Y_i^{(2)} \quad (3.10)$$

Considerando que o gradiente local em relação ao j-ésimo neurônio da camada de saída é:

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \quad (3.11)$$

E ainda considerando que o ajuste da matriz de pesos sinápticos, para minimizar o erro deve ser efetuado na direção oposta ao gradiente, portanto podemos escrever que:

$$\Delta W_{ji}^{(3)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(3)}} \therefore \Delta W_{ji}^{(3)} = \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (3.12)$$

Pode-se então escrever que a matriz de pesos sinápticos da camada de saída corrigida " $W_{ji}^{(3)}(t+1)$ " é igual à matriz inicial " $W_{ji}^{(3)}(t)$ ", mais a taxa de aprendizagem " $\eta$ ", multiplicada pelo gradiente local da saída " $\delta_j^{(3)}$ ", multiplicado por sua vez pela matriz saída da segunda camada neural escondida, no caso " $Y_i^{(2)}$ ". Portanto, obtemos a equação abaixo:

$$W_{ji}^{(3)}(t+1) = W_{ji}^{(3)}(t) + \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (3.13)$$

De forma análoga podemos ajustar as camadas intermediárias. No caso da segunda camada escondida de nosso modelo o ajuste é efetuado seguindo a seguinte equação:

$$W_{ji}^{(2)}(t+1) = W_{ji}^{(2)}(t) + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (3.14)$$

Onde a matriz de pesos sinápticos da segunda camada escondida corrigida " $W_{ji}^{(2)}(t+1)$ " é igual à matriz inicial " $W_{ji}^{(2)}(t)$ ", mais a taxa de aprendizagem " $\eta$ ", multiplicada pelo gradiente local da camada intermediária " $\delta_j^{(2)}$ ", multiplicado por sua vez pela matriz saída da primeira camada neural escondida " $Y_i^{(1)}$ ".

E por último, também de forma análoga, podemos descrever o ajuste dos pesos sinápticos da primeira camada escondida conforme a equação abaixo:

$$W_{ji}^{(1)}(t+1) = W_{ji}^{(1)}(t) + \eta \cdot \delta_j^{(1)} \cdot x_i \quad (3.15)$$

Onde a matriz de pesos sinápticos da primeira camada escondida corrigida " $W_{ji}^{(1)}(t+1)$ " é igual à matriz inicial " $W_{ji}^{(1)}(t)$ ", mais a taxa de aprendizagem " $\eta$ ", multiplicada pelo gradiente local da primeira camada " $\delta_j^{(1)}$ ", multiplicado por sua vez pela matriz das entradas da primeira camada neural escondida " $x_i$ ".

Nesta dissertação utiliza-se o denominado termo de momentum para tornar o processo de convergência mais eficiente. Este parâmetro adicional tem como objetivo acrescentar a ponderação do quanto as matrizes sinápticas foram alteradas entre duas iterações anteriores e sucessivas.

Considerando-se os neurônios pertencentes à L-ésima camada e inserindo-se no algoritmo backpropagation convencional o termo de momentum:

$$W_{ji}^{(L)}(t+1) = W_{ji}^{(L)}(t) + \alpha \cdot (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t-1)) + \eta \cdot \delta_j^{(L)} \cdot Y_i^{(L-1)} \quad (3.16)$$

Onde,  $\alpha \cdot (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t-1))$  é o termo de momentum e  $\eta \cdot \delta_j^{(L)} \cdot Y_i^{(L-1)}$  o termo de aprendizagem. A taxa de momentum propriamente dita é  $\alpha$  e seu valor compreendido entre zero e um. Portanto, quando o valor da taxa de momentum for igual a zero, a equação se torna equivalente a um algoritmo *backpropagation* convencional. Porém, quando  $\alpha$  possui valores diferentes de zero, o mesmo passa a ser relevante, sendo que tal valor afetará o processo de convergência conforme Silva et al (2010 [27]).

Mais precisamente, quando a solução atual, refletida por suas matrizes de peso, estiver longe da solução final, entenda-se do mínimo da função erro, a variação na direção oposta ao gradiente da função erro quadrático entre duas iterações sucessivas será também grande. Isto implica que a diferença entre as matrizes de pesos dessas duas iterações será bem considerável e, nesta situação, pode-se imprimir um passo maior de incremento para  $W^{(L)}$  em direção ao mínimo da função erro. Exatamente essa tarefa é a que está a cargo do termo de momentum, pois o mesmo é responsável pela medição desta variação (Silva et al, 2010 [27]).

Já quando a solução atual estiver bem próxima da solução final, as variações nas matrizes de peso serão pequenas, pois a variação do erro quadrático entre duas iterações sucessivas será também pequena e conseqüentemente, a contribuição do termo momentum para esse processo de convergência é bem pouco relevante. A partir deste instante, todos os ajustes nas matrizes de peso acabam sendo conduzidos (quase que na totalidade) apenas pelo termo de aprendizagem, assim como ocorre em um algoritmo *backpropagation* convencional (Silva et al, 2010 [27]).

A Figura 3.9 mostra a contribuição do termo de momentum (TM) e do termo de aprendizagem (TA) visando a convergência em direção ao mínimo  $W(OT)$  da função erro quadrático.

Portanto, através da inserção do termo de momentum, o processo de convergência da rede se torna bem mais eficiente, pois se leva em consideração o critério de quão afastada está a solução atual da solução final, dita ótima. Valores compreendidos entre  $(0,05 \leq \eta \leq 0,75)$  e  $(0 \leq \alpha \leq 0,9)$  são normalmente recomendados para treinamento de redes PMC.

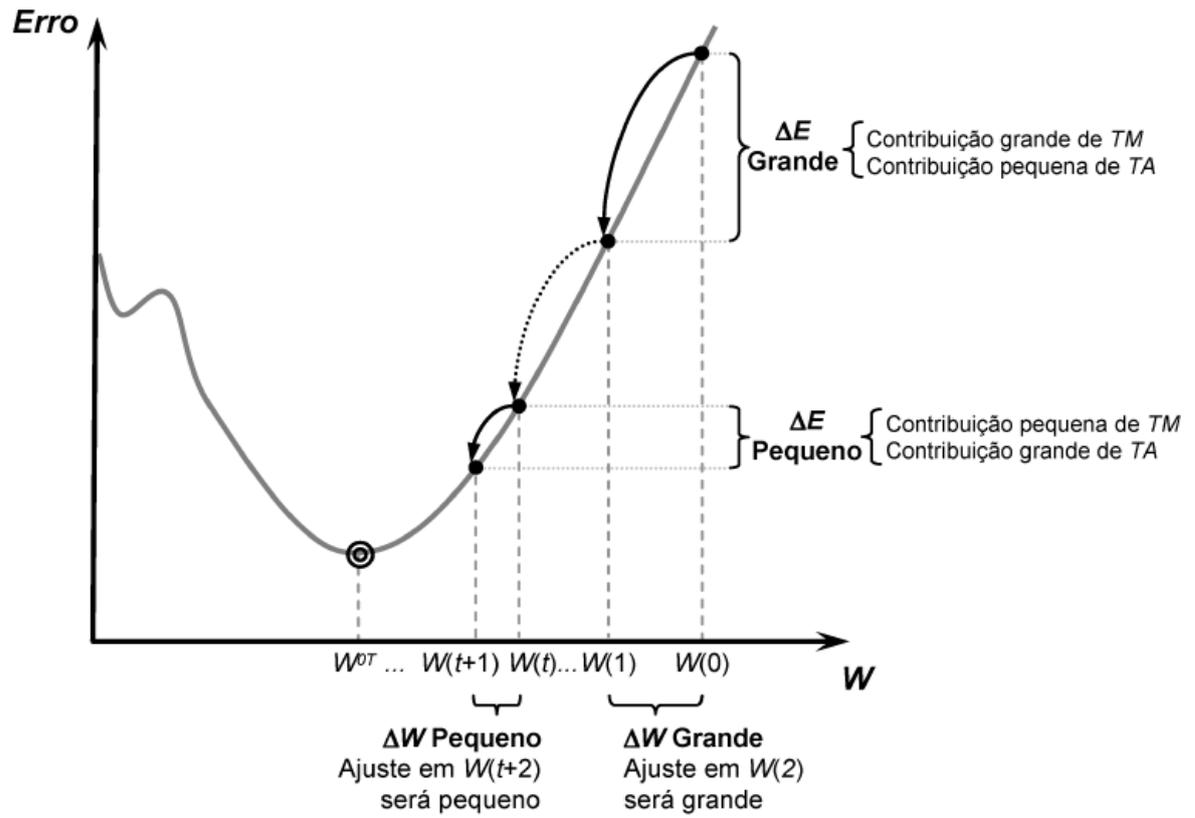


Figura 3.9: Ilustração do método de inserção do termo de momentum (Silva et al, 2010 [27]).

# Capítulo 4

## 4 Metodologia

Para esse trabalho aplicou-se os conceitos básicos de Análise Técnica, definiu-se uma arquitetura específica para a rede, recuperou-se séries históricas disponíveis em sites de finanças, efetuou-se tratamento dos dados com suporte de planilhas eletrônicas e realizou-se a aprendizagem da RNA com suporte de funções já implementadas no “*Matlab*”.

Abaixo apresenta-se o fluxograma metodológico aplicado nesse estudo:

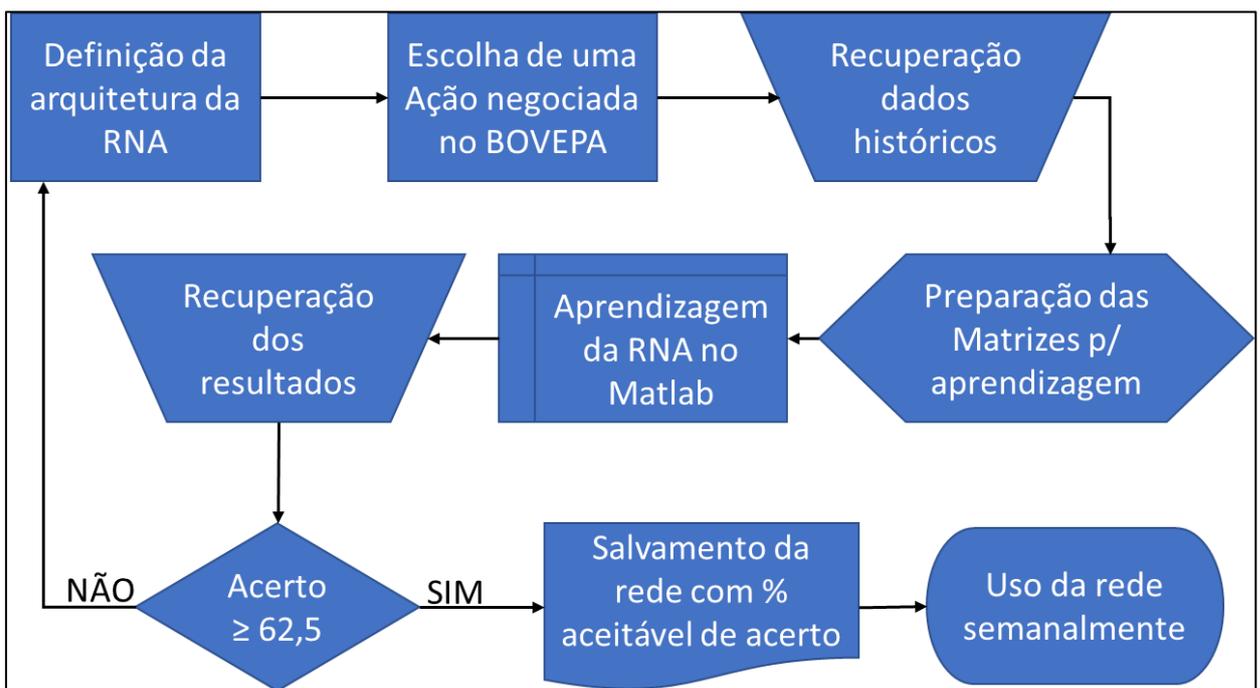


Figura 4.1: Fluxograma Metodológico Aplicado.

Portanto a etapa inicial é a da definição da arquitetura de rede, quantidade de entradas, quantidade de camadas intermediárias, quantidade de neurônios dessas camadas, bem como as funções de treinamento e transferência. Ainda na etapa de definição da RNA, definiu-se a taxa de aprendizagem com valores compreendidos

entre ( $0,05 < \eta < 0,75$ ), o número máximo de iterações, o erro aceitável e por fim o momentum compreendido entre ( $0 < \alpha < 0,9$ ).

Na segunda etapa, se efetua a escolha das ações a serem apreendidas pela RNA e em seguida se recupera os dados históricos dos mesmos. Na sequência são preparadas, a partir dos dados históricos brutos, as matrizes que são utilizadas como entradas para a aprendizagem da rede utilizando-se o algoritmo proposto no Matlab.

Uma vez obtendo-se, após a convergência e aprendizagem da rede, os respectivos resultados de cada ação da bolsa de valores; realiza-se o teste do percentual de acerto dessa rede. Se o percentual de acerto for superior ao que se deseja obter, a rede é salva para ser utilizada sem a necessidade de uma nova aprendizagem nas semanas vindouras.

## **4.1 Conceitos Básicos de Análise Técnica**

Conceituando o que são os “Candles”, velas em português, amplamente utilizados em gráficos de análises técnicas para análise do comportamento de ações de diversas bolsas de valores existentes em diversos países, inclusive no Brasil. São representações gráficas da evolução de preços de um papel, comumente usadas para as análises técnicas que representam a variação dos preços negociados de um determinado papel. Eles podem sintetizar a variações de preços de diferentes intervalos de tempo, ou seja, cada candle pode representar um mês, ou uma semana, ou um dia, ou horas, minutos das negociações de preço de um determinado papel da Bolsa de Valores.

Na figura adiante uma breve síntese das informações contidas em um só “candle”.

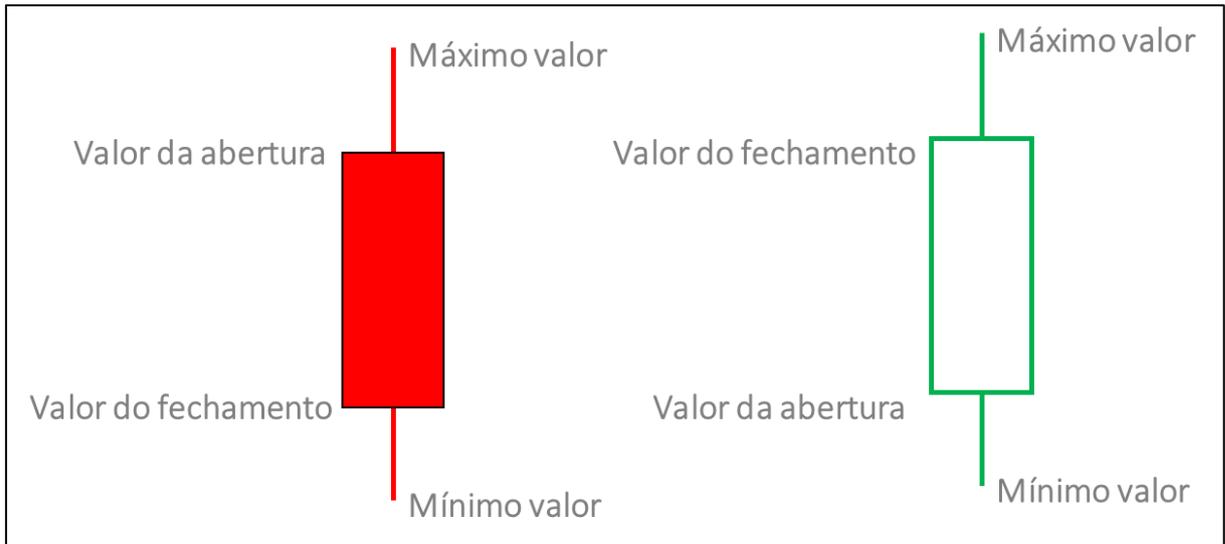


Figura 4.2: Ilustração dos candles.

Considerando que o trabalho objetivou auxiliar pessoas com baixa disponibilidade de tempo durante a semana no horário administrativo normal de trabalho, para o trabalho em questão utilizou-se candles semanais que permitem determinar entradas e saídas de operações de Position Trade.

Os valores de máximo, mínimo, abertura e fechamento, representam o comportamento de preço de um papel ao longo de uma semana específica de negociações. Salienta-se ainda que quando o valor de um “papel” abre a semana com um valor inferior ao valor de fechamento na mesma semana, colore-se o candle de amarelo ou verde, o que representa um resultado positivo de valorização nesse intervalo de tempo. Já o comportamento contrário, ou seja, em que o valor de abertura é superior ao valor de fechamento indica a desvalorização do “papel” ao longo do período e seu candle correspondente é indicado com a cor vermelha.

Muitos traders, entenda-se pessoas que operam compras e vendas no mercado financeiro, usam os conhecimentos de análise gráfica para tomada de decisão de quando operar na Bolsa de Valores.

Abaixo apresentamos um exemplo de gráfico de um conhecido papel da bolsa de valores de São Paulo:



Gráfico 4.1: Exemplo de Gráfico de ações da WEGE3 com Candles semanais e volumes negociados. Fonte: [finance.yahoo.com/](https://finance.yahoo.com/) do dia 16/04/2023 as 9h48.

## 4.2 Definição de uma Arquitetura de Rede Neural Específica

Com relação a arquitetura de Rede considerou-se sete dados de entrada para cada intervalo semanal recuperado, sendo eles: valor máximo negociado, valor de abertura; valor de fechamento; valor mínimo negociado; fechamento ajustado; volume negociado e a média aritmética dos últimos 8 fechamentos, esses dados foram os escolhidos como entradas pois segundo a “Teoria de Dow” todas as informações relevantes disponíveis, sobre um determinado ativo, contidas em seu próprio preço. Acrescentando-se apenas aos preços o volume negociado, que indica o qual relevante foi a movimentação dos preços de uma determinada semana e por fim a média aritmética pois é um indicador básico e simples de tendência de valorização e desvalorização de um determinado papel comumente aplicado no mercado.

Salienta-se ainda que para esse estudo específico não foram realizados testes com outros parâmetros de entrada além dos acima já descritos.

Portanto, conforme a Figura 4.3, a rede utilizada possuiu a arquitetura de uma camada de entrada com sete entradas, uma primeira camada escondida, uma segunda camada escondida e uma camada de saída com apenas uma saída que se

refere a tendência de valorização ou desvalorização do papel (termo sinônimo de uma ação negociada na Bolsa de Valores).

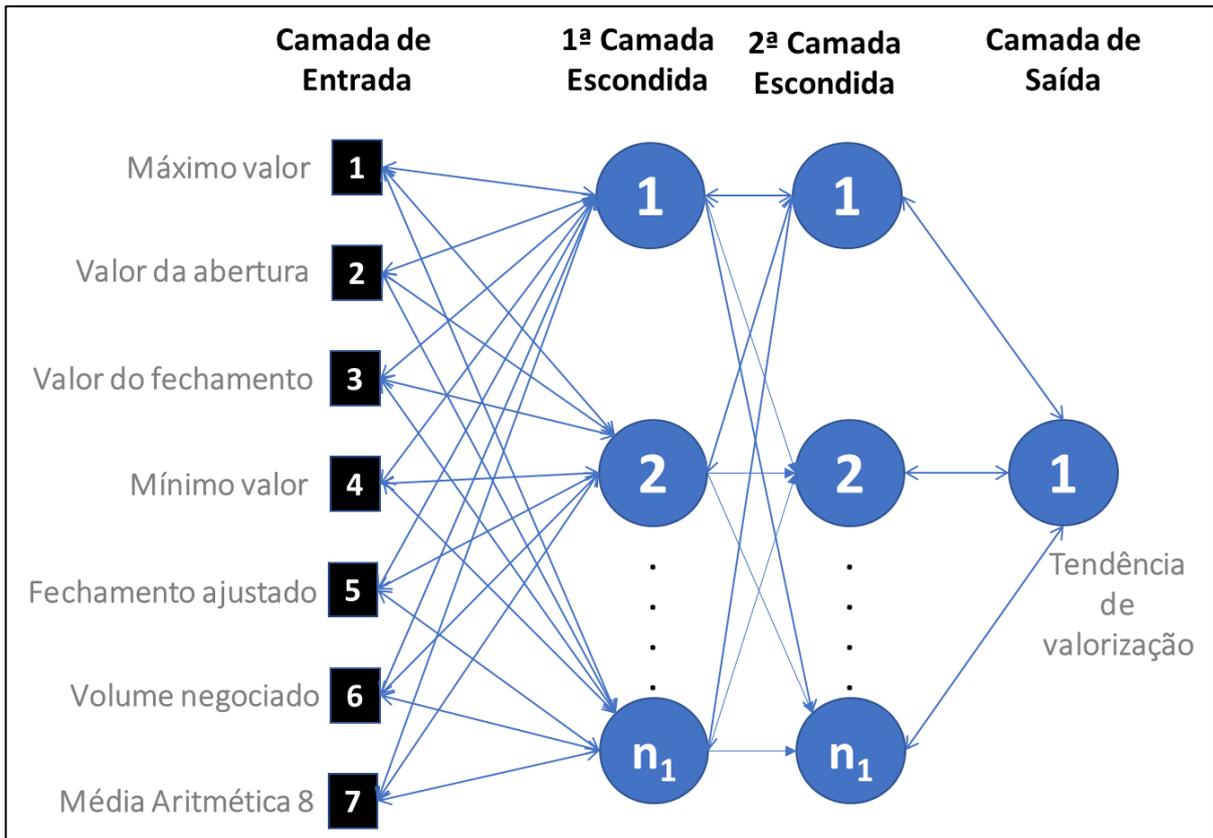


Figura 4.3: Arquitetura da rede neural artificial escolhida para esse trabalho.

### 4.3 Escolha das Ações do BOVESPA

Com relação as ações escolhidas para a realização desse estudo, apoiou-se em sugestões da plataforma L&S (<https://ls.com.vc/>) para o período de 2021/2022. Durante o período de realização dos estudos foram consideradas doze diferentes papéis negociados no mercado que foram: AMAR3, AMBP3, ENEV3, HASH11 (Fundo de Índice Crypto), KEPL3, LAND3, RRRP3, PRIO3, SLCE3, TRPL4, TTEN3, USIM5 e WEGE3. Com esses doze papéis foram realizadas diferentes iterações testando-se diferentes configurações de redes, entenda-se diferentes quantidades de neurônios das camadas escondidas, taxas de aprendizagem, números máximos de iterações, diferentes erros aceitáveis e constantes de momentum.

Observou-se durante mais de seis meses de experimentos de aprendizagem da RNA com o modelo proposto, que a obtenção de uma convergência com um índice de acerto, superior a 62,5% é uma tarefa possível, porém de difícil realização. Isso ocorre pela própria natureza aleatória da escolha dos melhores valores para os pesos sinápticos desde a primeira iteração, portanto mesmo utilizando-se backpropagation nem todo processo de aprendizagem obtém sucesso em sua convergência e mais ainda, dos que obtém sucesso, nem toda aprendizagem finalizada é posteriormente testada e obtém índice de acerto superior a 62,5%. Dentre todos os experimentos realizados, escolheu-se dois papéis que obtiveram, os melhores índices de acerto, que foram: PRIO3 e AMAR3, durante o período disponível para este trabalho. Acredita-se que uma convergência da RNA é possível, porém os fatores de tempo e velocidade de processamento do equipamento utilizado foram limitantes para uma conclusão satisfatória para todos os outros papéis da bolsa citados anteriormente.

#### **4.4 Recuperando dados Históricos**

Os dados históricos de cada uma das ações estudadas foram recuperados no Site Yahoo Finance (<https://finance.yahoo.com/> em 20 de fevereiro de 2023). O período dos dados correspondia a um ano de variações dos seus respectivos preços e a frequência escolhida foi a semanal. Abaixo a figura exemplo de uma extração dessa natureza.

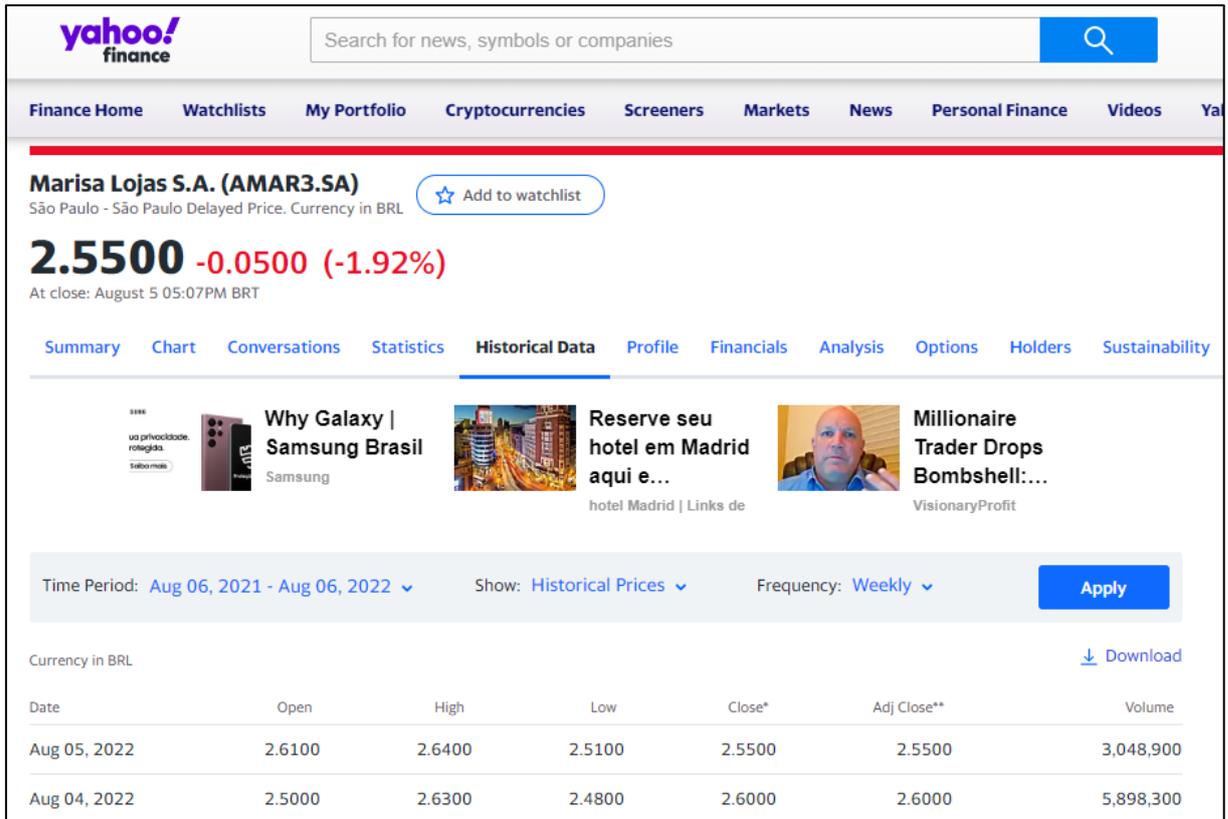


Figura 4.4: Exemplo da configuração usada para recuperação de dados históricos.

Os arquivos foram recuperados em formato (.CSV) para tratamento posterior em planilhas eletrônicas.

## 4.5 Preparação das Matrizes para a aprendizagem da RNA

Considerou-se que um ano de dados históricos de movimentações semanais de preços de uma determinada ação, corresponde a dados de 53 semanas.

Para a criação das matrizes de “entrada” de dados da rede, de “saída” de dados da rede e a de “teste”, estratifica-se as 53 semanas que correspondem a aproximadamente um ano segundo o diagrama da Figura 4.5.

A partir dos dados das 53 semanas recuperadas em formato (.CSV) e com auxílio de uma planilha eletrônica, efetuou-se com as primeiras oito semanas, o cálculo da média aritmética de oito períodos do valor de fechamento para a 9ª semana e descartou-se as 8 primeiras que, portanto, não foram utilizadas para a criação da matriz de “entrada” de dados.

Posteriormente calcula-se as médias aritméticas de todas as 45 semanas seguintes, pois as médias aritméticas não são disponibilizadas junto com os dados históricos, porém são necessárias e utilizadas como uma das sete entradas da rede.

Em seguida, obtém-se os resultados das saídas entre a 9ª e a 44ª semanas. Que nada mais são que valores 1(um) ou 0(zero) quando respectivamente, na semana subsequente, ouve historicamente uma valorização ou uma desvalorização dessa ação.

Em seguida, salva-se como a matriz de “entrada”, sem os dados de saída acima citados, porém com os seis dados históricos, mais as médias aritméticas calculadas anteriormente, que correspondem aos dados de 36 semanas, vide Figura 4.5.

Salva-se como matriz de “saída” somente os dados correspondentes as valorizações ou desvalorizações entre as 9ª a 44ª semanas.

Por último, salva-se a matriz “teste” com os dados entre a 45ª a 52ª semanas, sem os dados de saída, porém com os seis dados históricos mais as médias calculadas. E finalmente se descarta a 53ª semana para efeito da utilização de seus dados nas matrizes aplicadas a rede.

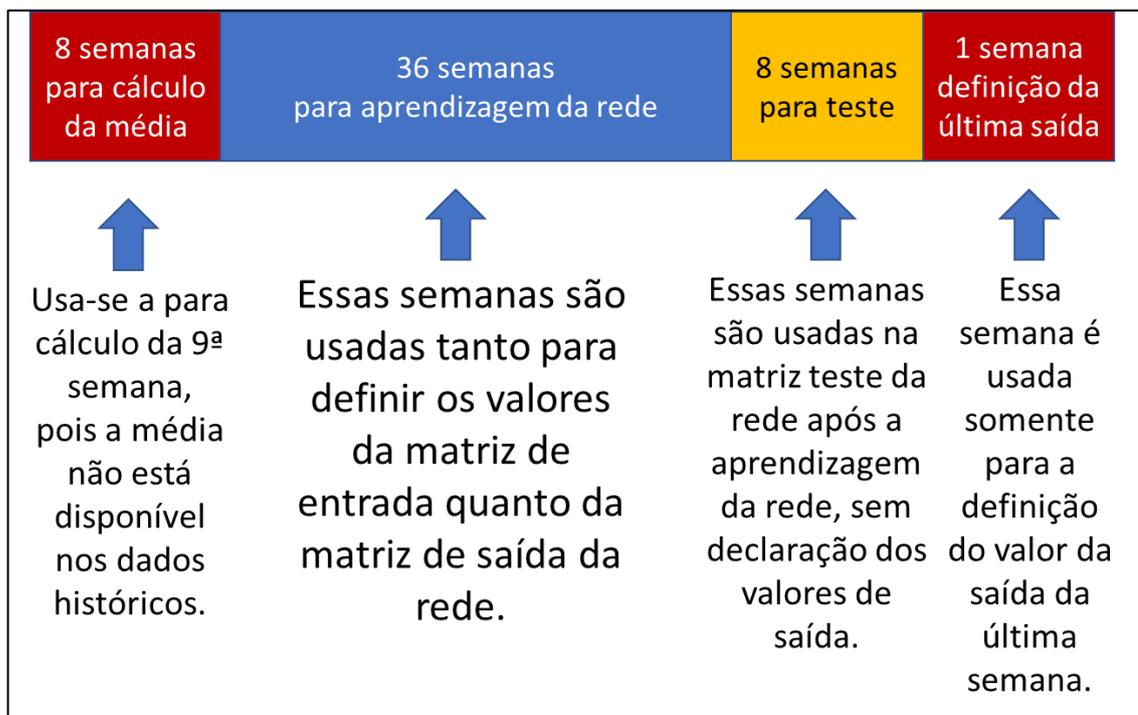


Figura 4.5: Ilustração da preparação das matrizes de entrada, saída e teste.

Após o tratamento desses dados, são criados os arquivos: de “entrada” de dados para aprendizagem para as 36 semanas; de “saída” para as mesmas 36 semanas e de “teste” com as 8 semanas usadas para o teste da rede, descartando-se, portanto, as 8 primeiras semanas e a última.

## 4.6 Aprendizagem da RNA no Matlab

Aplicou-se a função “newff” usada especificamente para a criação de uma rede “*feed-forward backpropagation*”, ou seja, uma rede de propagação a diante e de propagação reversa.

Essa função possui a seguinte sintaxe:

```
net = newff(PR,S1 S2...SN1,{TF1 TF2...TFN1},BTF,BLF,PF)
```

Onde:

- PR - matriz R x 2 de valores mínimo e máximo para os elementos de entrada.
- Si - tamanho de cada camada i, para N1 camadas.
- TFi - função de transferência de cada camada i, o padrão é 'tansig'.
- BTF - função de treinamento da rede de retropropagação, o padrão é 'traingdx'. No nosso estudo aplicou-se a função padrão.
- BLF - função de aprendizagem de peso / polarização de retropropagação, padrão = 'aprendizagem'. Função não aplicada nesse estudo.
- PF - Função de desempenho, o padrão é 'mse'. Função também não aplicada nesse estudo.

Essa função retorna uma rede “*feed-forward backpropagation*” de N camadas.

A função de transferência TFi podem ser qualquer função de transferência diferenciável, como tansig, logsig ou purelin.

A função de treinamento BTF pode ser qualquer uma das funções de treinamento de *backpropagation*, como *trainlm*, *trainbfg*, *trainrp*, *traingd*, etc.

Para o cálculo do PR utilizou-se a seguinte função:

PR= *minmax* (P) leva um argumento, sendo P uma matriz R e seu resultado os valores mínimo e máximo para cada linha de P.

Para a função de transferência utilizamos a função “*logsig*”, que é uma log-sigmóide.

E para a função de treinamento da rede de retropropagação, usamos a ‘*traindx*’, que é uma função gradiente descendente com impulso e retropropagação de taxa de aprendizagem adaptativa. Ainda salientamos que para essa função utilizamos os seguintes parâmetros:

“*net.trainParam.lr*” que corresponde a Taxa de Aprendizagem.

“*net.trainParam.epochs*” que corresponde ao número máximo de iterações para a fase de treinamento.

“*net.trainParam.goal*” que corresponde a Meta de desempenho ou erro estipulado.

“*net.trainParam.mc*” que corresponde ao constante de Momentum. O fator de momento é um coeficiente que é aplicado a um termo extra na atualização dos pesos sinápticos.

## 4.7 Recuperação dos resultados

Após a aprendizagem da rede utilizou-se o arquivo de teste para verificação da eficácia da rede. A partir dos resultados obtidos pela própria RNA, comparou-se semana a semana as saídas reais conhecidas antecipadamente, vide figura exemplo abaixo.

| Date                               | 25/10/2021 | 01/11/2021 | 08/11/2021 | 15/11/2021 | 22/11/2021 | 29/11/2021 | 06/12/2021 | 13/12/2021 |
|------------------------------------|------------|------------|------------|------------|------------|------------|------------|------------|
| Open                               | 4,58       | 4,17       | 4,78       | 4,9        | 4,52       | 3,98       | 3,26       | 4,14       |
| High                               | 4,86       | 4,82       | 5,28       | 4,98       | 4,6        | 3,98       | 4,44       | 4,25       |
| Low                                | 4,11       | 4,16       | 4,52       | 4,05       | 3,76       | 3,05       | 3,22       | 3,54       |
| Close                              | 4,11       | 4,79       | 4,9        | 4,48       | 3,87       | 3,31       | 4,4        | 3,81       |
| Adj Close                          | 4,11       | 4,79       | 4,9        | 4,48       | 3,87       | 3,31       | 4,4        | 3,81       |
| Volume                             | 34,35      | 22,84      | 45,26      | 40,96      | 43,38      | 46,6       | 77,38      | 37,39      |
| Media 8                            | 5,56       | 5,3        | 5,17       | 5,07       | 4,9        | 4,68       | 4,42       | 4,29       |
| Saida                              | 1          | 1          | 0          | 0          | 0          | 1          | 0          | 0          |
|                                    | 1          | 1          | 1          | 1          | 1          | 1          | 0          | 0          |
| <b>Percentual de acerto= 62,5%</b> |            |            |            |            |            |            |            |            |

Figura 4.6: Exemplo de teste dos resultados.

A Figura 4.6 acima corresponde a avaliação das semanas de teste após a aprendizagem de uma RNA. Partiu-se da tabela teste em que as saídas eram previamente conhecidas e comparou-se esses valores com os resultados obtidos pela RNA como saídas para essas mesmas semanas. Todas as saídas que obtiveram acerto foram coloridas em verde e as saídas que não obtiveram acerto coloridas em vermelho. Posteriormente se calculou o percentual de acerto que no exemplo acima foi correspondente a 5 acertos em 8 semanas, ou seja 62,5% de acerto. Uma vez obtendo-se acerto dessa ordem ou superior, as RNA já apreendidas foram salvas com o comando “save” para utilização posterior.

## 4.8 Materiais e Metodologia

Para a realização das simulações foi utilizando o software MATLAB 2020b em um Laptop marca COMPAQ, cuja CPU tinha as seguintes características: Intel Core I3-5005U de 2.00GHz.

Definiu-se como saída a ser obtida, a estimativa de valorização ou desvalorização desses papeis. Essa saída, portanto, foi usada como apoio a decisão de compra ou venda dos papeis estudados.

Utilizou-se os seguintes critérios de compra e venda seguidos a partir da saída da RNA:

1. Compra-se 100% dos recursos na abertura da semana em que o algoritmo indicar prognóstico de candle positivo para a semana seguinte.
2. Mantem-se a posição quando algoritmo indicar prognóstico de candle positivo após candle anterior também positivo.
3. Vende-se 100% da posição na abertura quando algoritmo indicar prognóstico de candle negativo para uma semana seguinte.
4. Espera-se e nenhuma operação é realizada quando algoritmo indicar candle negativo após candle anterior também negativo.

## 4.9 Objetivos específicos

O seguinte experimento teve como objetivos:

- Criar um algoritmo com o princípio de redes neurais artificiais para prever aumento ou diminuição do valor de determinadas ações da Bolsa de Valores de São Paulo.
- Utilizar series históricas para aprendizagem da rede tipo backpropagation.
- Utilizar os principais dados dos *candles* semanais, bem como o cálculo das médias de oito períodos anteriores e os volumes negociados para a aprendizagem da rede.
- Simular resultados de aplicações de compra e venda guiadas pelo modelo de RNA proposto.

# Capítulo 5

## 5 Resultados

Dentre todas as ações apresentadas no capítulo 4.3, as ações que se obtive aprendizagens satisfatórias e usadas para as simulações de rendimento foram: PRIO3 e AMAR3.

Foram comparados resultados de 3 métodos distintos:

- Uma compra no início do período de um ano e uma venda no final do período.
- Compras e vendas orientadas pela média aritmética de 8 semanas.
- Compras e vendas orientadas pela RNA.

Salienta-se que os dados de entrada consistiam em candles semanais de janeiro a dezembro de 2020, período esse escolhido, apenas por se tratar do ano anterior ao início dos experimentos práticos desse trabalho.

### 5.1 Primeiro papel estudado – PRIO3

Esse papel corresponde ao da empresa Petro Rio S.A.; brasileira que atua no ramo de petróleo e gás.

Escolheu-se o período de um ano para a aprendizagem, sempre levando-se em conta dados correspondentes a resultados semanais desse papel para o estudo.

No Gráfico 5.1 apresenta-se o período específico em que foram realizadas as simulações de operações na bolsa de valores para PRIO3.



Gráfico 5.1: Gráfico das ações da PRIO3 durante o período analisado.

A primeira hipótese considerou apenas uma compra e uma venda simples, respectivamente no início e no final do período estudado. Nesse primeiro caso, considerando-se hipótese de capital inicial no valor de R\$10.000,00, conforme a Tabela 5.1 adquiriu-se a quantidade equivalente ao montante de recursos disponível dividido pelo valor do papel na abertura da semana, sempre levando-se em conta valores inteiros para as quantidades. Os resultados obtidos nessa simulação foram:

Tabela 5.1: Operações de compra e venda simples da PRIO3.

| Operação simples de uma compra e venda |                  |            |                      |
|--|------------------|------------|----------------------|
| Operação                               | Preço Papel      | Quantidade | Valor Operado        |
| <b>1ª Compra</b>                       | <b>R\$ 18,90</b> | <b>529</b> | <b>R\$ 9.998,10</b>  |
| <b>1ª Venda</b>                        | <b>R\$ 19,70</b> | <b>529</b> | <b>R\$ 10.421,30</b> |

Tabela 5.2: Resultados operações de compra e venda simples da PRIO3.

| Hipótese           | Compra Simples       |
|--------------------|----------------------|
| <b>Início</b>      | <b>R\$ 9.998,10</b>  |
| <b>Término</b>     | <b>R\$ 10.421,30</b> |
| <b>Valorização</b> | <b>4%</b>            |

Já na segunda hipótese simulou-se operações de compra e venda usando-se como fator de decisão, apenas a tendência de alta ou de queda da média aritmética de 8 períodos, um dos métodos mais simples de operação de ações existente no mercado. Nesse segundo caso, considerando-se hipótese de capital inicial no valor de R\$10.000,00, os resultados obtidos foram: os resultados foram:

Tabela 5.3: Operações usando a Média Aritmética da PRIO3.

| <b>Operação de compra pela média 8 semanas</b> |                    |                   |                      |
|--|--------------------|-------------------|----------------------|
| <b>Operação</b>                                | <b>Preço Papel</b> | <b>Quantidade</b> | <b>Valor Operado</b> |
| <b>1ª Compra</b>                               | <b>R\$ 17,97</b>   | <b>556</b>        | <b>R\$ 9.991,32</b>  |
| <b>1ª Venda</b>                                | <b>R\$ 19,09</b>   | <b>556</b>        | <b>R\$ 10.614,04</b> |
| <b>2ª Compra</b>                               | <b>R\$ 17,65</b>   | <b>601</b>        | <b>R\$ 10.614,04</b> |
| <b>2ª Venda</b>                                | <b>R\$ 18,03</b>   | <b>601</b>        | <b>R\$ 10.842,56</b> |
| <b>3ª Compra</b>                               | <b>R\$ 20,49</b>   | <b>529</b>        | <b>R\$ 10.842,56</b> |
| <b>3ª Venda</b>                                | <b>R\$ 18,20</b>   | <b>529</b>        | <b>R\$ 9.630,77</b>  |
| <b>4ª Compra</b>                               | <b>R\$ 26,98</b>   | <b>357</b>        | <b>R\$ 9.630,77</b>  |
| <b>4ª Venda</b>                                | <b>R\$ 21,53</b>   | <b>357</b>        | <b>R\$ 7.685,34</b>  |

Tabela 5.4: Resultados operações usando a Média Aritmética da PRIO3.

| <b>Hipótese</b>    | <b>Compra pela Média 8</b> |
|--------------------|----------------------------|
| <b>Início</b>      | <b>R\$ 9.991,32</b>        |
| <b>Término</b>     | <b>R\$ 7.685,34</b>        |
| <b>Valorização</b> | <b>-23%</b>                |

Já a hipótese 3 foi, aplicar-se uma RNA com sete entradas, duas camadas intermediárias de 100 neurônios cada e uma saída. Após o período de aprendizagem usando-se o método de retropropagação, obtivemos um nível de acerto de 62.5%. Considerando-se o mesmo capital inicial de R\$ 10.000,00, fizemos a partir do cálculo da previsão semana a semana das séries históricas usando a rede salva pós o

processo de aprendizagem. E nesse último caso, partindo-se também da hipótese de capital inicial no valor de R\$10.000,00, os resultados obtidos foram:

Tabela 5.5: Operações usando RNA da PRIO3.

| Operação guiada pela RNA |                  |            |                      | % por Operação |
|--------------------------|------------------|------------|----------------------|----------------|
| Operação                 | Preço Papel      | Quantidade | Valor Operado        |                |
| <b>1ª Compra</b>         | <b>R\$ 18,27</b> | <b>547</b> | <b>R\$ 9.993,69</b>  | 2%             |
| <b>1ª Venda</b>          | <b>R\$ 18,71</b> | <b>547</b> | <b>R\$ 10.234,37</b> |                |
| <b>2ª Compra</b>         | <b>R\$ 18,32</b> | <b>559</b> | <b>R\$ 10.234,37</b> | 4%             |
| <b>2ª Venda</b>          | <b>R\$ 19,09</b> | <b>559</b> | <b>R\$ 10.664,53</b> |                |
| <b>3ª Compra</b>         | <b>R\$ 17,65</b> | <b>604</b> | <b>R\$ 10.664,53</b> | 16%            |
| <b>3ª Venda</b>          | <b>R\$ 20,49</b> | <b>604</b> | <b>R\$ 12.380,52</b> |                |
| <b>4ª Compra</b>         | <b>R\$ 19,11</b> | <b>648</b> | <b>R\$ 12.380,52</b> | 7%             |
| <b>4ª Venda</b>          | <b>R\$ 20,54</b> | <b>648</b> | <b>R\$ 13.306,95</b> |                |
| <b>5ª Compra</b>         | <b>R\$ 17,36</b> | <b>767</b> | <b>R\$ 13.306,95</b> | 64%            |
| <b>5ª Venda</b>          | <b>R\$ 28,45</b> | <b>767</b> | <b>R\$ 21.807,76</b> |                |

Tabela 5.6: Resultados operações usando RNA da PRIO3.

| Hipótese           | Compra pela RNA      |
|--------------------|----------------------|
| <b>Início</b>      | <b>R\$ 9.993,69</b>  |
| <b>Término</b>     | <b>R\$ 21.807,76</b> |
| <b>Valorização</b> | <b>118%</b>          |

Portanto as operações guiadas pela RNA obtiveram o melhor resultado comparadas com as operações de compra e venda simples e as operações guiadas pela média aritmética de 8 períodos.

Conforme a Figura 5.1 a configuração da rede que obteve melhor percentual de acerto no teste foi:

```

redesoma_PRI03.m x Semana_PRI03.m x redesoma_TRPL4.m x +
%montando a rede
- net=newff(minmax(ent),[7,200,200,1], {'logsig','logsig','logsig','logsig'}, 'traingdx');
% parametros do RNA
- net.trainParam.show=10; %intervalo de iterações mostradas;
- net.trainParam.lr=0.01; % taxa de aprendizagem;
- net.trainParam.epochs=200000; %max de iteração;
- net.trainParam.goal=0.00001;%erro estipulado;
- net.trainParam.mc=0.777;%taxa de momentum;

```

Figura 5.1: Arquitetura da rede aplicada em PRI03.

## 5.2 Segundo papel estudado – AMAR3

Esse papel corresponde ao da empresa Lojas Marisa; brasileira que atua no ramo varejista de vestuário.

Escolheu-se o período de um ano para a aprendizagem, sempre levando-se em conta dados correspondentes a resultados semanais desse papel para o estudo.

No Gráfico 5.2 apresenta-se o período específico em que foram realizadas as simulações de operações na bolsa de valores para AMAR3.



Gráfico 5.2: Gráfico das ações da AMAR3 durante o período analisado.

A primeira hipótese considerou apenas uma compra e uma venda simples, respectivamente no início e no final do período estudado. Nesse primeiro caso, considerando-se hipótese de capital inicial no valor de R\$10.000,00, os resultados obtidos foram: os resultados foram:

Tabela 5.7: Operações de compra e venda simples da AMAR3.

| <b>Operação simples de uma compra e venda</b> |                    |                   |                      |
|---|--------------------|-------------------|----------------------|
| <b>Operação</b>                               | <b>Preço Papel</b> | <b>Quantidade</b> | <b>Valor Operado</b> |
| <b>1ª Compra</b>                              | <b>R\$ 5,52</b>    | <b>1.811</b>      | <b>R\$ 9.996,72</b>  |
| <b>1ª Venda</b>                               | <b>R\$ 3,73</b>    | <b>1.811</b>      | <b>R\$ 6.755,03</b>  |

Tabela 5.8: Resultados operações de compra e venda simples da AMAR3.

| <b>Hipótese</b>    | <b>Compra Simples</b> |
|--------------------|-----------------------|
| <b>Início</b>      | <b>R\$ 9.996,72</b>   |
| <b>Término</b>     | <b>R\$ 6.755,03</b>   |
| <b>Valorização</b> | <b>-32%</b>           |

Já na segunda hipótese simulou-se operações de compra e venda usando-se como fator de decisão, apenas a tendência de alta ou de queda da média aritmética de 8 períodos, um dos métodos mais simples de operação de ações existente no mercado. Nesse segundo caso, considerando-se hipótese de capital inicial no valor de R\$10.000,00, os resultados obtidos foram: os resultados foram:

Tabela 5.9: Operações usando a Média Aritmética da AMAR3.

| <b>Operação de compra pela média 8 semanas</b> |                    |                   |                      |
|--|--------------------|-------------------|----------------------|
| <b>Operação</b>                                | <b>Preço Papel</b> | <b>Quantidade</b> | <b>Valor Operado</b> |
| <b>1ª Compra</b>                               | <b>R\$ 5,91</b>    | <b>1.692</b>      | <b>R\$ 9.999,72</b>  |
| <b>1ª Venda</b>                                | <b>R\$ 6,05</b>    | <b>1.692</b>      | <b>R\$ 10.236,60</b> |
| <b>2ª Compra</b>                               | <b>R\$ 6,60</b>    | <b>1.551</b>      | <b>R\$ 10.236,60</b> |
| <b>2ª Venda</b>                                | <b>R\$ 7,85</b>    | <b>1.551</b>      | <b>R\$ 12.175,35</b> |

Tabela 5.10: Resultados operações usando a Média Aritmética da AMAR3.

| Hipótese    | Compra pela Média 8 |
|-------------|---------------------|
| Início      | R\$ 9.999,72        |
| Termino     | R\$ 12.175,35       |
| Valorização | 22%                 |

Portanto as operações nesse período, usando-se o método simples da média aritmética de 8 semanas indicaram no período duas compras e duas vendas e permitiu a obtenção de um resultado positivo correspondente a uma valorização de 22% do capital inicial. O que correspondeu a um ganho em reais de R\$ 2175,63.

Já a hipótese 3 foi, aplicar-se uma RNA com sete entradas, duas camadas intermediárias de 100 neurônios cada e uma saída. Após o período de aprendizagem usando-se o método de retropropagação, obtivemos um nível de acerto de 62.5%. Considerando-se o mesmo capital inicial de R\$ 10.000,00, fizemos a partir do cálculo da previsão semana a semana das séries históricas usando a rede salva pós o processo de aprendizagem. E nesse caso os resultados obtidos foram:

Tabela 5.11: Operações usando RNA da AMAR3.

| Operação guiada pela RNA |             |            |               | % PRIMEIRA APRENDIZAGEM |
|--------------------------|-------------|------------|---------------|-------------------------|
| Operação                 | Preço Papel | Quantidade | Valor Operado |                         |
| 1ª Compra - MAR          | R\$ 5,68    | 1.760      | R\$ 9.996,80  | 4%                      |
| 1ª Venda - ABR           | R\$ 5,91    | 1.760      | R\$ 10.401,60 |                         |
| 2ª Compra - MAI          | R\$ 6,21    | 1.675      | R\$ 10.401,60 | 20%                     |
| 2ª Venda - MAI           | R\$ 7,45    | 1.675      | R\$ 12.478,57 |                         |
| 3ª Compra - AGO          | R\$ 7,85    | 1.590      | R\$ 12.478,57 | -7%                     |
| 3ª Venda - AGO           | R\$ 7,31    | 1.590      | R\$ 11.620,17 |                         |
| 4ª Compra                | R\$ 7,25    | 1.603      | R\$ 11.620,17 | -26%                    |
| 4ª Venda                 | R\$ 5,40    | 1.603      | R\$ 8.655,02  |                         |

Tabela 5.12: Resultados operações usando RNA da AMAR3.

| <b>Hipótese</b>    | <b>Compra pela RNA</b> |
|--------------------|------------------------|
| <b>Início</b>      | <b>R\$ 9.996,80</b>    |
| <b>Término</b>     | <b>R\$ 8.655,02</b>    |
| <b>Valorização</b> | <b>-13%</b>            |

Observa-se que o algoritmo RNA proposto orientou quatro compras e quatro vendas ao longo do mesmo período analisado anteriormente e obteve de um resultado negativo correspondente a uma desvalorização de -13% do capital inicial. Observou-se, portanto, que ocorreu uma forte degeneração da rede durante as operações de compra e venda ao longo do ano.

Portanto nesse caso, a RNA não foi capaz de superar as aplicações orientadas pela média aritmética de 8 períodos, apesar de ter sido melhor que a operação simples de compra e venda no mesmo período.

Objetivando-se recuperar a assertividade da rede já a partir da 2ª operação, que ocorreu já no quarto mês após a aprendizagem da rede, se efetuou um processo de reaprendizagem da mesma de forma empírica, com um deslocamento de 3 meses nos dados de entrada. Inicialmente os dados de entrada consistiam em candles semanais de janeiro a dezembro de 2020, período escolhido apenas por se tratar do ano anterior ao início dos experimentos práticos desse trabalho. Já na segunda aprendizagem utilizou-se, portanto, os meses de abril de 2020 a março de 2021.

A mesma arquitetura de rede da primeira aprendizagem foi também aplicada na segunda aprendizagem e pode-se observar uma nítida recuperação da assertividade da rede na segunda operação, conforme abaixo apresentado:

Tabela 5.13: Operações usando RNA atualizada em 3 meses da AMAR3.

| Operação guiada pela RNA atualizada em 3 meses |                 |              |                      | % RNA atualizada em 3 meses |
|--|-----------------|--------------|----------------------|-----------------------------|
| Operação                                       | Preço Papel     | Quantidade   | Valor Operado        |                             |
| <b>1ª Compra - MAR</b>                         | <b>R\$ 5,68</b> | <b>1.760</b> | <b>R\$ 9.996,80</b>  | 4%                          |
| <b>1ª Venda - ABR</b>                          | <b>R\$ 5,91</b> | <b>1.760</b> | <b>R\$ 10.401,60</b> |                             |
| <b>2ª Compra - MAI</b>                         | <b>R\$ 6,21</b> | <b>1.675</b> | <b>R\$ 10.401,60</b> | 42%                         |
| <b>2ª Venda - JUN</b>                          | <b>R\$ 8,80</b> | <b>1.675</b> | <b>R\$ 14.739,79</b> |                             |
| <b>3ª Compra - JUN</b>                         | <b>R\$ 9,37</b> | <b>1.573</b> | <b>R\$ 14.739,79</b> | -8%                         |
| <b>3ª Venda - JUL</b>                          | <b>R\$ 8,58</b> | <b>1.573</b> | <b>R\$ 13.497,05</b> |                             |
| <b>4ª Compra - AGO</b>                         | <b>R\$ 7,79</b> | <b>1.733</b> | <b>R\$ 13.497,05</b> | 1%                          |
| <b>4ª Venda - AGO</b>                          | <b>R\$ 7,85</b> | <b>1.733</b> | <b>R\$ 13.601,01</b> |                             |
| <b>5ª Compra - AGO</b>                         | <b>R\$ 7,31</b> | <b>1.861</b> | <b>R\$ 13.601,01</b> | -19%                        |
| <b>5ª Venda - SET</b>                          | <b>R\$ 5,90</b> | <b>1.861</b> | <b>R\$ 10.977,56</b> |                             |
| <b>6ª Compra - SET</b>                         | <b>R\$ 5,77</b> | <b>1.903</b> | <b>R\$ 10.977,56</b> | -1%                         |
| <b>6ª Venda - OUT</b>                          | <b>R\$ 5,70</b> | <b>1.903</b> | <b>R\$ 10.844,38</b> |                             |
| <b>7ª Compra - OUT</b>                         | <b>R\$ 4,58</b> | <b>2.368</b> | <b>R\$ 10.844,38</b> | 4%                          |
| <b>7ª Venda - NOV</b>                          | <b>R\$ 4,78</b> | <b>2.368</b> | <b>R\$ 11.317,94</b> |                             |
| <b>8ª Compra - NOV</b>                         | <b>R\$ 4,90</b> | <b>2.310</b> | <b>R\$ 11.317,94</b> | -8%                         |
| <b>8ª Venda - NOV</b>                          | <b>R\$ 4,52</b> | <b>2.310</b> | <b>R\$ 10.440,22</b> |                             |
| <b>9ª Compra - NOV</b>                         | <b>R\$ 3,98</b> | <b>2.623</b> | <b>R\$ 10.440,22</b> | -6%                         |
| <b>9ª Venda - DEZ</b>                          | <b>R\$ 3,73</b> | <b>2.623</b> | <b>R\$ 9.784,43</b>  |                             |

Tabela 5.14: Resultados operações usando RNA da AMAR3 com 2ª aprendizagem combinada.

| Hipótese           | Compra pela RNA     |
|--------------------|---------------------|
| <b>Início</b>      | <b>R\$ 9.996,80</b> |
| <b>Término</b>     | <b>R\$ 9.784,43</b> |
| <b>Valorização</b> | <b>-2%</b>          |

Pode-se comprovar, portanto, que uma nova aprendizagem se deslocando os dados de entrada em 3 meses combinada com a primeira aprendizagem permitiu uma recuperação da assertividade da rede na segunda operação, porém a partir da terceira operação, que ocorreu no sétimo mês, novamente se constatou uma forte degeneração da rede. O resultado melhorou, mas ainda não foi suficiente para superar a média aritmética de 8 períodos.

Entretanto conhecendo-se, desde a primeira experiência, que o padrão desse papel na bolsa sofre forte degradação após apenas 3 meses uma proposta coerente seria parar as operações no sexto mês ou uma nova reaprendizagem da rede agora deslocando-se mais 3 meses nos dados de entrada. Considerando-se esse entendimento, apresenta-se abaixo o resultado somente das duas primeiras operações, que antecederam o sétimo mês.

Tabela 5.15: Operações usando RNA atualizada em 3 meses da AMAR3, considerando-se operações até sexto mês da primeira aprendizagem.

| Operação guiada pela RNA atualizada em 3 meses |                 |              |                      | % RNA atualizada em 3 meses |
|--|-----------------|--------------|----------------------|-----------------------------|
| Operação                                       | Preço Papel     | Quantidade   | Valor Operado        |                             |
| <b>1ª Compra - MAR</b>                         | <b>R\$ 5,68</b> | <b>1.760</b> | <b>R\$ 9.996,80</b>  | 4%                          |
| <b>1ª Venda - ABR</b>                          | <b>R\$ 5,91</b> | <b>1.760</b> | <b>R\$ 10.401,60</b> |                             |
| <b>2ª Compra - MAI</b>                         | <b>R\$ 6,21</b> | <b>1.675</b> | <b>R\$ 10.401,60</b> | 42%                         |
| <b>2ª Venda - JUN</b>                          | <b>R\$ 8,80</b> | <b>1.675</b> | <b>R\$ 14.739,79</b> |                             |

Tabela 5.16: Resultados operações usando RNA da AMAR3 com 2ª aprendizagem combinada, considerando-se operações até sexto mês da primeira aprendizagem.

| Hipótese           | Compra pela RNA      |
|--------------------|----------------------|
| <b>Início</b>      | <b>R\$ 9.996,80</b>  |
| <b>Término</b>     | <b>R\$ 14.739,79</b> |
| <b>Valorização</b> | <b>47%</b>           |

Salienta-se que a reaprendizagem somente foi executada com o papel AMAR3 pois se detectou um baixo desempenho na primeira aprendizagem para o período estudado.

A configuração da rede que obteve o melhor percentual de acerto no teste e que foi usada tanto para a primeira aprendizagem quanto para a segunda foi a seguinte:

```
redesoma_AMAR.m  x  +
%montando a rede

net=newff(minmax(ent), [7,100,100,1], {'logsig','logsig','logsig','poslin'}, 'traingdx');

% parametros do RNA
net.trainParam.show=10; %intervalo de iterações mostradas;
net.trainParam.lr=0.4; % taxa de aprendizagem;
net.trainParam.epochs=200000; %max de iteração;
net.trainParam.goal=0.0001;%erro estipulado;
net.trainParam.mc=0.97;%taxa de momentum;
```

Figure 5.2: Arquitetura da rede aplicada em AMAR3.

### 5.3 Operação Combinada das 2 Ações Apreendidas

Simulando-se uma operação combinada com as duas ações obteve-se um resultado ainda melhor usando-se a RNA como suporte a tomada de decisão, pois em momentos que os recursos poderiam estar parados, estavam sendo aplicados no melhor momento de uma das duas ações simuladas, vide exemplo na Figura 5.3.

Esse método consiste em semana a semana, se verificar qual dos dois papéis está com indicação de compra e partindo-se do mesmo volume de capital de R\$ 10.000,00 e efetuar compras e vendas da ação que estiver com indicação de compra primeiro e/ou em melhor condição de compra.

Portanto um ponto adicional a tomada de decisão de compra, no caso de mais de uma ação estar na condição de compra na mesma semana segundo a RNA, foi o cálculo da desvalorização de cada ação em relação ao valor de abertura da mesma na semana anterior. A ação com maior desvalorização foi a considerada em melhor condição de compra e, portanto, escolhida para compra.



Figure 5.3: Exemplo de operações combinadas com 2 ações.

A Figura 5.3 apenas ilustra o critério das operações combinadas, iniciou-se com a compra do papel AMAR3, porem já na segunda operação a compra foi orientada para o papel PRIO3. Assim durante o período simulado comprou-se um ou outro papel seguindo o critério explicitado acima.

Tabela 5.17: Simulação operação da combinada.

| Operação guiada pela RNA atualizada em 3 meses |                  |              |                      | % RNA atualizada em |
|--|------------------|--------------|----------------------|---------------------|
| Operação                                       | Preço Papel      | Quantidade   | Valor Operado        |                     |
| <b>1ª Compra</b>                               | <b>R\$ 5,68</b>  | <b>1.760</b> | <b>R\$ 9.996,80</b>  | <b>4%</b>           |
| <b>1ª Venda</b>                                | <b>R\$ 5,91</b>  | <b>1.760</b> | <b>R\$ 10.401,60</b> |                     |
| <b>2ª Compra</b>                               | <b>R\$ 17,65</b> | <b>589</b>   | <b>R\$ 10.401,60</b> | <b>16%</b>          |
| <b>2ª Venda</b>                                | <b>R\$ 20,49</b> | <b>589</b>   | <b>R\$ 12.075,29</b> |                     |
| <b>3ª Compra</b>                               | <b>R\$ 19,11</b> | <b>632</b>   | <b>R\$ 12.075,29</b> | <b>7%</b>           |
| <b>3ª Venda</b>                                | <b>R\$ 20,54</b> | <b>632</b>   | <b>R\$ 12.978,88</b> |                     |
| <b>4ª Compra</b>                               | <b>R\$ 17,36</b> | <b>748</b>   | <b>R\$ 12.978,88</b> | <b>64%</b>          |
| <b>4ª Venda</b>                                | <b>R\$ 28,45</b> | <b>748</b>   | <b>R\$ 21.270,11</b> |                     |
| <b>5ª Compra</b>                               | <b>R\$ 4,58</b>  | <b>4.644</b> | <b>R\$ 21.270,11</b> | <b>4%</b>           |
| <b>5ª Venda</b>                                | <b>R\$ 4,78</b>  | <b>4.644</b> | <b>R\$ 22.198,93</b> |                     |
| <b>6ª Compra</b>                               | <b>R\$ 20,70</b> | <b>1.072</b> | <b>R\$ 22.198,93</b> | <b>4%</b>           |
| <b>6ª Venda</b>                                | <b>R\$ 21,53</b> | <b>1.072</b> | <b>R\$ 23.089,04</b> |                     |
| <b>7ª Compra</b>                               | <b>R\$ 3,26</b>  | <b>7.083</b> | <b>R\$ 23.089,04</b> | <b>14%</b>          |
| <b>7ª Venda</b>                                | <b>R\$ 3,73</b>  | <b>7.083</b> | <b>R\$ 26.417,82</b> |                     |

Na Tabela 5.17 pode-se observar todas as operações de compra e venda realizadas nessa operação combinada, que escolheu sempre uma das ações considerada para compra e venda de ativos, conforme critério explicitado acima.

Abaixo o resultado da operação combinada, que foi melhor que o resultado do melhor papel simulado isoladamente anteriormente.

Tabela 5.18: Resultados operações combinadas usando RNA.

| <b>Hipótese</b>    | <b>Compra pela RNA</b> |
|--------------------|------------------------|
| <b>Início</b>      | <b>R\$ 9.996,80</b>    |
| <b>Termino</b>     | <b>R\$ 26.417,82</b>   |
| <b>Valorização</b> | <b>164%</b>            |

Entendeu-se que a realização de testes em períodos de tempo inferiores a um ano, por experiência prática não seriam tão relevantes considerando-se candles semanais como dados de entrada da RNA, portanto períodos menores não foram objeto desse estudo.

# Capítulo 6

## 6 Conclusões e trabalhos futuros

Nesse trabalho foi feita uma breve revisão bibliográfica dos fundamentos para aplicações no mercado financeiro, em que foi apresentado o contexto histórico tanto da análise fundamentalista, quanto da análise técnica do mercado de ações. Revisão essa em que ficou notório que, a análise técnica toma como base o comportamento estatístico de séries históricas de uma determinada ação da bolsa de valores, bem como suas características de repetibilidade de padrões matemáticos anteriores, fato este que está diretamente alinhado com as características das RNAs.

Apresentou-se em seguida o conceito das redes neurais artificiais, se concentrando na rede do tipo “**Perceptron Multi Camadas com Backpropagation**” que foi a técnica aplicada na modelagem matemática desse trabalho.

Foi feita, portanto uma modelagem matemática de modo a utilizar a rede neural artificial proposta, para a finalidade de previsão do comportamento da valorização ou desvalorização de ações da Bolsa de Valores de São Paulo.

Criou-se uma metodologia para se realizar a tarefa de previsão de comportamento das ações e os resultados obtidos foram muito satisfatórios e encorajadores.

Entendeu-se como promissor no futuro se continuar aprimorando e estudando ainda mais as potencialidades da RNA e ainda ampliar a aplicação desse modelo para outros papéis.

Como oportunidades de estudos e aplicações futuras listamos:

- Aprofundar estudo de diferentes arquiteturas de rede objetivando obter sucesso no acerto pós aprendizagem com qualquer ação da bolsa de valores.
- Aplicação de uma sistemática de reaprendizagem da rede a cada ciclo em que se observa em um determinado papel uma degradação significativa da rede.

- Estudar a possibilidade de usar também a RNA para análise de históricos de análises fundamentalistas, isso para o auxílio na escolha dos melhores papéis a se investir.
- Aplicação de redes neurais e Neuro Fuzzy associados aprimorar ainda mais a previsão do comportamento de ações.
- Estudar um maior número de diferentes papéis e analisar consistência dos resultados entre eles, validando, portanto, uma maior e mais diversa amostragem.
- Realizar experimentos também com bancos de dados de candles diários que, portanto, permitiriam efetuar operações diárias, inclusive as intituladas “de alavancagem” que são operações que permitem ganhos de compras, mesmo quando a previsão de desvalorização de uma ação se concretiza, ou seja, se ganha tanto com ações em alta como com ações em queda.
- Criação de uma comunidade em que possam ser compartilhados resultados da RNA para beneficiar a maior quantidade de pessoas interessadas no mercado de ações, com foco nos trabalhadores assalariados em atividade.

## Referências

- [1] STORMER, A.W. **Treinamento Legado Financeiro: bolsa de valores para profissionais liberais**, 2014.
- [2] GRAHAM, B., DODD, D. L. F., & COTTLE, S. **Security analysis**, 1934.
- [3] FLEURIET, M; ZEIDAN, E. **O Modelo dinâmico de gestão financeira**, 2015.
- [4] BALL, R. & BROWN, P. **An empirical evaluation of accounting income numbers**, Journal of accounting research, 6(2), 159–178, 1968.
- [5] BEAVER, W. H. **The information content of annual earnings announcements**, Journal of accounting research, 6(2), 67–92, 1968.
- [6] ALTMAN, E. I., **Financial ratios, discriminant analysis and the prediction of corporate bankruptcy**, The journal of finance, 23(4), 589–609, 1968.
- [7] FAMA, E. F. **Efficient capital markets: A review of theory and empirical work**, The journal of Finance, 25(2), 383–417, 1970.
- [8] COLLINS, D., & KOTHARI, S. **A theoretical and empirical analysis of determination of earnings response coefficients**. Journal of Accounting and Economics, 11(2), 143–181, 1989.
- [9] OU, J., & PENMAN, S. **Accounting measures, price-earnings ratio, and the information content of security prices**. Journal of Accounting Research, 27(2), 111–144, 1989a.
- [10] OU, J., & PENMAN, S. **Financial statement analysis and the prediction of stock returns**. Journal of Accounting and Economics, 11(3), 295–329, 1989b.
- [11] LEV, B., & THIAGAJARAN, R. **Fundamental information analysis**. Journal of Accounting Research, 31(2), 190–215, 1993.
- [12] ABARBANELL, J. S., & E BUSHEE, B. J. **Abnormal returns to a fundamental analysis strategy**. The Accounting Review, 73(1), 19–45, 1998.
- [13] BENEISH, M. D., LEE, C. M. C., & TARPLEY, R. L. **Contextual fundament analysis through the prediction of extreme returns**. Review of Accounting Studies, 6(2–3), 165–189, 2001.
- [14] LIU, J., NISSIM, D., & E THOMAZ, J. **Equity valuation using multiples**. Journal of Accounting Research, 40(1), 135–172, 2002.

- [15] ERTIRMUR, Y., LIVNAT, J., & MARTIKAINEN, M. **Differential market reaction to revenue and expensive surprise.** *Review of Accounting Studies*, 8(3), 185–211, 2003.
- [16] NICHOLS, D. C., & WAHLEN, J. M. **How do earnings numbers relate to stock returns? A review of classic accounting research with updated evidence.** *Accounting Horizons*, 18(4), 263–286, 2004.
- [17] JAGADEESH, N., & LIVNAT, J. **Revenue surprise and stock returns.** *Journal of Accounting and Economics*, 41(1-2), 147–171, 2006.
- [18] ZHANG, G., & CHEN, P. **How do accounting variables explain stock price movements? Theory and evidence.** *Journal of Accounting and Economics*, 43(2), 219–244, 2007.
- [19] SANDHAR, S. K. **Accounting numbers as a predictor of stock returns: a case study of NSE Nifty.** *Journal of Accounting Research & Audit Practices*, 9(1 e 2), 33–43, 2010.
- [20] RAUT, S. **Candlestick trading bible** (English Edition), 2020.
- [21] NORONHA, M. **Análise Técnica: Teorias, Ferramentas e Estratégias**, 1995.
- [22] MURPHY J.J. **Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications** (New York Institute of Finance) (English Edition), 1986.
- [23] MALKIEL, BURTON G. **A Random Walk Down Wall Street**, New York, W. W. Norton & Company, 1991.
- [24] EDWARDS, ROBERT D. MAGEE, JOHN. BASSETTI, W. H. C. **Technical Analysis of Stock Trends.** New York, CRC Press LLC, 2001.
- [25] PRING, M.J. **Technical Analysis Explained.** New York, McGraw-Hill, 2002.
- [26] BOTELHO, F.A. **Análise Técnica & Estratégia Operacional.** São Paulo, Enfoque Gráfico, 2003.
- [27] SILVA, I. N. D., SPATTI, H., FLAUZINO, R. **Redes neurais artificiais, curso prático para engenharia e ciências aplicadas.** Artliber Editora, 2010.
- [28] ZORZETTO, R. **Recontagem de neurônios põe em xeque ideias da neurociência,** *Revista Pesquisa FAPESP* - Edição 192 de fevereiro, 2012.
- [29] WILLIAMS, R.W., HERRUP, K **The control of neuron number,** *Annual review of neuroscience*, 1988.
- [30] HILGETAG, C.C., BARBAS, H. **Are there ten times more glia than neurons in the brain?** *Brain Struct Funct* 213, 365–366, 2009.

- [31] LOPES, P.S. **Detecção de danos em estruturas por meio de técnicas de redes neurais artificiais e algoritmos genéticos.** Dissertação de mestrado em Engenharia Mecânica. Universidade Federal de Itajubá - Itajubá, 2007.
- [32] LOPES, P.S. **Modelagem de problema inverso de detecção de danos por técnicas de identificação de parâmetros e de otimização.** Tese de doutorado em Engenharia Mecânica. Universidade Federal de Itajubá - Itajubá, 2010.
- [33] RAO,H.S.; GHORPADE,V.G. **A genetic algorithm based back propagation network for simulation of stress-strain response of ceramic matrix composites.** Computers and Structures, Vol 84, pp. 330-339, 2006.
- [34] DEMIDOVICH B. P., MARON I. A., **Computational Mathematics.** Second Edition, Mir Publishers, 1976.