



Universidade Estadual de Feira de Santana
Programa de Pós-Graduação em Computação Aplicada

Sistema Automático de Negociação para a Bolsa de Valores Utilizando Redes Neurais Multilayer Perceptron e Regressão Linear

José Torquato Sampaio Tavares

Feira de Santana

2018



Universidade Estadual de Feira de Santana
Programa de Pós-Graduação em Computação Aplicada

José Torquato Sampaio Tavares

**Sistema Automático de Negociação para a Bolsa
de Valores Utilizando Redes Neurais Multilayer
Perceptron e Regressão Linear**

Dissertação apresentada à Universidade Estadual de Feira de Santana como parte dos requisitos para a obtenção do título de Mestre em Computação Aplicada.

Orientador: Carlos Alberto Rodrigues

Feira de Santana

2018

Ficha Catalográfica – Biblioteca Central Julieta Carteado

T228s Tavares, José Torquato Sampaio
Sistema Automático de Negociação para a Bolsa de Valores utilizando
redes neurais Multilayer Perceptron e Regressão Linear / José Torquato
Sampaio Tavares. - Feira de Santana, 2018.

55 f.: il.

Orientador: Carlos Alberto Rodrigues
Dissertação (Mestrado) – Universidade Estadual de Feira de Santana,
Programa de Pós-graduação em Computação Aplicada, 2018.

1. Bolsa de valores - Negociação. 2. Redes neurais – Multilayer
perceptron. 3. Finanças quantitativas I. Rodrigues, Carlos Alberto ,
orient. II. Universidade Estadual de Feira de Santana. III. Título.

CDU: 336.761

José Torquato Sampaio Tavares

**SISTEMA AUTOMÁTICO DE NEGOCIAÇÃO PARA A BOLSA
DE VALORES UTILIZANDO REDES NEURAIS MULTILAYER
PERCEPTRON E REGRESSÃO LINEAR**

Dissertação apresentada à Universidade
Estadual de Feira de Santana como parte dos
requisitos para a obtenção do título de Mestre
em Computação Aplicada.

Feira de Santana, 05 de setembro de 2018

BANCA EXAMINADORA



Dr. Carlos Alberto Rodrigues (Orientador)
Universidade Estadual de Feira de Santana



Dr. Matheus Giovanni Pires
Universidade Estadual de Feira de Santana



Dr. Edgar Silva Junior
Universidade Estadual de Feira de Santana

Abstract

Predicting the behavior of the financial market has always attracted the interest of investors. Manual trading brings a number of difficulties for investors, so it is increasingly common to use automated trading systems. This work used MLP neural networks to try to predict the financial market. Two forms of training were used by the neural networks: one based on the Linear Regression Slope indicator and the other based on the index closing price the next day. A trading system with stop loss, take profit mechanisms and money management was built using the Percent Volatility strategy. The BOVA11 index was used for trading in demo accounts of a financial broker. The system was based on predictions of neural networks trained and selected periodically for trading. The trading period applied was from 07/01/2014 to 06/30/2018. Neural networks trained by closing price of the next day outperformed the one based on linear regression slope and the buy and hold strategy in the analyzed period.

Keywords: Trading systems, stock market, neural networks MLP, quantitative finance.

Resumo

Prever o comportamento do mercado financeiro sempre atraiu o interesse dos investidores. A negociação manual traz uma série de dificuldades para os investidores, por isso, é cada vez mais comum o uso de sistemas automáticos de negociação. Este trabalho utilizou redes neurais MLP para tentar prever o mercado financeiro. Duas formas de treinamento foram utilizadas pelas redes neurais: uma baseada no indicador *Linear Regression Slope* e a outra baseada no preço de fechamento do índice no dia seguinte. Foi construído um sistema de negociação com mecanismos de *stop loss*, *take profit* e gerenciamento de dinheiro, utilizando a estratégia *Percentil Volatility*. Foi utilizado o índice BOVA11 para negociação em contas demo de uma corretora financeira. O sistema baseou-se nas previsões das redes neurais treinadas e selecionadas periodicamente para negociação. O período de negociação utilizado foi de 01/07/2014 a 30/06/2018. A forma de treinamento baseada no preço de fechamento do dia seguinte superou a baseada em regressão linear e a estratégia *buy and hold* no período analisado.

Palavras-chave: Sistemas de negociação, bolsa de valores, redes neurais multicamadas, finanças quantitativas.

Prefácio

Esta dissertação de mestrado foi submetida a Universidade Estadual de Feira de Santana (UEFS) como requisito parcial para obtenção do grau de Mestre em Computação Aplicada.

A dissertação foi desenvolvida dentro do Programa de Pós-Graduação em Computação Aplicada (PGCA) tendo como orientador o Prof. Dr. **Carlos Alberto Rodrigues**.

Agradecimentos

Primeiramente gostaria de agradecer ao meu orientador Prof. Dr. Carlos Alberto Rodrigues, pelo conhecimento, direcionamento e por estar sempre disponível para o desenvolvimento deste trabalho.

À minha esposa Karolynne por toda a compreensão e apoio durante as madrugadas de estudo.

Aos meus pais que me apoiaram todos os dias e sempre acreditaram em mim.

Aos amigos da UFRB que deram força até o fim dessa etapa.

Sumário

Abstract	i
Resumo	ii
Prefácio	iii
Agradecimentos	iv
Sumário	vi
Lista de Publicações	vii
Lista de Tabelas	viii
Lista de Figuras	ix
Lista de Abreviações	x
1 Introdução	1
1.1 Objetivos	3
1.1.1 Objetivo Geral	3
1.1.2 Objetivos específicos	3
1.2 Organização do Trabalho	3
2 Revisão Bibliográfica	5
2.1 Mercado de Renda Variável	5
2.1.1 Mercado de ações	5
2.1.2 Fundos de Índice	6
2.1.3 Inclinação da Regressão Linear	7
2.1.4 Análise Fundamentalista	7
2.1.5 Análise Técnica	8
2.1.6 Sistemas de Negociação	14
2.2 Redes Neurais Artificiais	15
2.2.1 Redes <i>Multilayer Perceptron</i>	18
2.2.2 Métricas de Qualidade	18

2.3	Avaliação do Sistema de Negociação	20
2.3.1	<i>Compound Annual Return</i> (CAR)	20
2.3.2	<i>Maximum Drawdown</i> (MDD)	21
2.3.3	CAR/MDD	21
2.3.4	Fator de Lucro (<i>Profit factor</i>)	22
2.4	Revisão de Literatura	22
3	Metodologia	30
3.1	Ferramentas Utilizadas	31
3.2	Visão Geral	31
3.3	Treinamentos Periódicos	33
3.3.1	Variáveis de Entrada	34
3.3.2	Treinamento das Redes Neurais	36
3.3.3	Seleção das Redes Neurais	37
3.3.4	Negociação	38
4	Discussão dos Resultados	40
4.1	Experimentos	40
4.1.1	Seleção das Redes Neurais	41
4.1.2	Resultados das Negociações	43
4.1.3	Desempenho dos Previsores	47
5	Conclusão	49
5.1	Pesquisas Futuras	50
	Referências Bibliográficas	52

Lista de Publicações

Desenvolvimento de um Sistema Automático de Negociação para a Bolsa de Valores e Forex Utilizando Redes Neurais Multilayer Perceptron. José Torquato Tavares, Carlos Alberto Rodrigues. (2017). *In WPOS/ERBASE*

Lista de Tabelas

2.1	Resumo dos Trabalhos Relacionados	29
3.1	Treinamentos Periódicos	35
3.2	Variáveis de Entrada - Previsor por Preço de Fechamento do dia seguinte	35
3.3	Variáveis de Entrada - Previsor por LSR	36
4.1	Redes Seleccionadas - Preço de Fechamento	42
4.2	Redes Seleccionadas - LRS	43
4.3	Evolução do Capital por Período	43
4.4	Resumo do Desempenho das Estratégias de Negociação	44
4.5	Informações Anuais I- Previsor por Preço de Fechamento	45
4.6	Informações Anuais II- Previsor por Preço de Fechamento	45
4.7	Informações Anuais I- Previsor por LRS	46
4.8	Informações Anuais II - Previsor por LRS	46
4.9	Acurácia no Período de Negociação - Preço de Fechamento	48
4.10	Acurácia no Período de Negociação - LRS	48
4.11	Comparação de Resultados Nametala et al. x Sistema Proposto	48

Lista de Figuras

2.1	Comparativo dos gráficos IBOVESPA e BOVA11	7
2.2	Regressão Linear - 10 dias	8
2.3	Cotação BOVA 11 x Indicador LRS - 10 dias	9
2.4	<i>Candlesticks</i>	10
2.5	Cruzamento de Médias Móveis	11
2.6	<i>Parabolic SAR</i>	12
2.7	Neurônio	16
2.8	Funções de ativação	17
2.9	Estrutura de uma rede neural	19
2.10	Matriz de Confusão - 2 classes	20
2.11	<i>Maximum Drawdown</i>	21
3.1	Visão Geral do Sistema de Negociação	32
3.2	Treinamentos Periódicos - Divisão do tempo	33
3.3	<i>Trailing Stop</i> com indicador <i>Parabolic SAR</i>	39
4.1	Capital x Períodos	44
4.2	Capital x Tempo - Estratégias	47

Lista de Abreviações

Abreviação	Descrição
ANN	Artificial neural network
ATR	Varição Verdadeira Média (Average True Range)
CAR	Retorno Anual Composto (Compound Annual Return)
ESN	Rede Neural Echo State (Echo State Network)
FI	Fundo de Índices
HHV	Maior dos Maiores Valores (Highest High Value)
MACD	Média Móvel Convergente e Divergente (Moving Average Convergence Divergence)
MDD	Máximo Drawdown
MLP	Perceptron Multicamadas (Multilayer Perceptron)
LLV	Menor dos Menores Valores (Lowest Low Value)
LRS	Inclinação da Regressão Linear (Linear Regression Slope)
RBFN	Rede Neural de Função de Base Radial (Radial basis function neural network)
RNN	Rede Neural Recorrente (Recurrent Neural Network)
RSI	Índice de Força Relativa (Relative Strength Index)
RMSE	Raiz do erro quadrático médio (Root mean square error)
SVM	Support Vector Machine
SAR	Pára e Reverte (Stop And Reverse)

Capítulo 1

Introdução

O comportamento do mercado de renda variável possui muitas instabilidades e variações de preços. A previsão do comportamento dos preços das ações é uma tarefa complexa, mas pode auxiliar os investidores na tomada de decisões para realizar os seus investimentos.

Geralmente, para auxiliar os investidores, são utilizadas duas abordagens: a análise fundamentalista e a análise técnica [Kirkpatrick e Dahlquist 2006]. A análise fundamentalista considera os índices econômicos do mercado, solidez da empresa, contexto social e econômico do país, além de outras informações e notícias que possam interferir no mercado financeiro [Piazza 2009]. Já a análise técnica baseia-se em dados históricos dos preços das ações para tentar prever o comportamento futuro dos preços [Zhu e Zhou 2009]. A análise técnica considera que toda a informação necessária já está contida no próprio valor das ações e por isso utiliza dados históricos para tentar estudar as tendências dos preços, apostando que elas se repetirão no futuro.

A análise técnica conta com diversos indicadores na previsão do comportamento do mercado, dentre eles, indicadores de tendência, de volume, de volatilidade e os *candlesticks* [Murphy 2003]. O ideal, para maior confiabilidade da estratégia de negociação, é combinar os indicadores para confirmar a tendência do comportamento do mercado.

Prever o comportamento do mercado financeiro sempre atraiu o interesse dos investidores, já que o acerto nestas previsões resultam em lucros no investimento realizado. O mercado financeiro sofre forte influência das informações que vão desde dados econômicos e situação política de um país a catástrofes da natureza e, com a rápida propagação e o grande volume de informações disponível influenciando o mercado, torna-se mais difícil prever o impacto que estas informações podem causar nos preços das ações, inclusive para investidores experientes.

Além das dificuldades já citadas para saber como investir, é sempre uma dúvida para o investidor definir como será gerenciado o seu dinheiro a ser aplicado e quanto

deve-se investir no momento em determinada ação para que o investimento seja realizado de uma forma mais segura.

Nesse contexto, é cada vez mais comum o uso de sistemas automáticos de negociação, que emitem ordens de compra e venda de ações de acordo com regras estabelecidas no sistema como detecção de padrões de preços ou tendências do mercado. Dessa forma, as negociações são influenciadas pelos dados históricos, não sendo tomadas decisões com base no estado emocional ou psicológico do investidor. Cerca de 40% das operações na bolsa de valores do Brasil e 70% nos Estados Unidos são realizadas automaticamente¹. Atualmente, existem fundos que atuam exclusivamente com negociações automáticas, como o Renaissance, administrado pelo matemático James Simon, que no ano de 2016 atraiu mais de 7 bilhões de dólares em novos investimentos e atualmente gerencia mais de 36 bilhões de dólares².

O uso de redes neurais, dentre as diversas aplicações em diferentes áreas, na previsão de séries temporais é recorrente e muito estudada por se comportarem bem em tratamento de problemas complexos e não-lineares, como no caso da bolsa de valores. Vários trabalhos utilizam redes neurais na previsão de séries temporais [Chiang et al. 2016, Qiu e Song 2016, Vanstone et al. 2012], sendo uma das técnicas mais utilizadas para prever tendências do mercado financeiro justamente pelo seu bom desempenho [Atsalakis e Valavanis 2009, Martinez et al. 2009].

A análise técnica tradicional, sofre com algumas deficiências. Por exemplo, é difícil aplicar diretamente análise técnica em ações individuais, especialmente para iniciantes. Como exemplo, existe a técnica de cruzamento de médias móveis, em que, para cada ação o investidor utiliza intervalos de tempo diferentes para as médias, baseando-se na sua própria experiência [Lin et al. 2011]. Existem várias formas de aplicar análise técnica, utilizando Índice de Força Relativa, médias móveis, MACD, dentre outros indicadores [Kirkpatrick e Dahlquist 2006, Edwards e Magee 2009].

Nem todos os indicadores são eficazes para todas as ações [Lin et al. 2011] e cada mercado possui suas particularidades, ou seja, um algoritmo que funciona em um ativo pode não funcionar bem ao investir em outro e os parâmetros utilizados para calcular os indicadores técnicos também podem variar, de acordo com a ação escolhida. Como o comportamento dos preços está sempre mudando, muitas estratégias utilizadas pelos investidores acabam não retornando bons resultados com o passar do tempo, devido a isto, há a necessidade de mudanças de estratégias periódicas, talvez até com mudanças nas combinações de indicadores técnicos que auxiliam na estratégia de negociação para acompanhar o dinamismo do mercado.

Neste trabalho foi desenvolvido um sistema de negociações automáticas para a bolsa de valores brasileira, levando em consideração indicadores da análise técnica para gerar sinais de compra e venda, de modo que o investidor não precise dedicar todo o

¹<http://www.tecmundo.com.br/financas/105182-40-operacoes-bolsa-valores-brasil-feitas-robos.htm>

²<http://www.wsj.com/articles/renaissance-technologies-hedge-fund-on-a-7-billion-winning-streak-1476141061>

tempo no acompanhamento dos preços para tomar decisões, eliminando a influência psicológica e emocional ao se investir. Foram testadas duas formas de treinamento das redes neurais: utilizando o indicador da inclinação da regressão linear dos preços dos ativos (*Linear Regression Slope*) e através dos preços de fechamento do dia seguinte dos ativos. Para que o sistema se adapte às condições mais recentes do mercado foi realizada periodicamente toda a etapa de treinamento e seleção dos previsores. Como diferencial em relação aos outros trabalhos relacionados estudados, além da adoção da inclinação da regressão linear para treinamento das redes, neste trabalho foi realizada a adoção de um mecanismo de *trailing stop* baseado no indicador técnico *Parabolic SAR*.

1.1 Objetivos

1.1.1 Objetivo Geral

O presente trabalho tem como objetivo principal propor um sistema automático de negociações na bolsa de valores baseados em indicadores da análise técnica para a previsão de preços utilizando redes neurais treinadas com o indicador da inclinação da regressão linear e com o preço de fechamento do ativo no dia seguinte aplicando treinamentos periódicos dos previsores.

1.1.2 Objetivos específicos

Os objetivos específicos deste trabalho são:

- Avaliar o desempenho do sistema desenvolvido com relação às negociações e ao lucro obtido pelos diferentes previsores de tendência e em relação à métrica retorno risco;
- Propor uma metodologia de negociação baseada em treinamentos periódicos da rede para que o sistema consiga capturar as possíveis mudanças recentes no mercado;
- Comparar o desempenho das estratégias utilizadas no sistema apresentado com a estratégia *buy-and-hold* e com resultados existentes em sistemas semelhantes na literatura;
- Realizar simulações e implementar um sistema de negociações automáticas (robô) com os algoritmos desenvolvidos e que possa ser testado em contas de uma corretora da bolsa de valores e em contas de demonstração;

1.2 Organização do Trabalho

Este trabalho está dividido em seis capítulos, contando com esta introdução.

No capítulo 2 é apresentada a fundamentação teórica sobre os temas abordados neste trabalho e uma análise dos trabalhos relacionados. No capítulo 3, será apresentada a metodologia aplicada desde a plataforma de desenvolvimento até os detalhes dos experimentos realizados, como o uso dos treinamentos periódicos das redes neurais e a visão geral do sistema com o detalhamento dos seus respectivos módulos. No capítulo 4, serão apresentados e discutidos os resultados encontrados. No capítulo 5 serão discutidas as considerações finais sobre este trabalho, as conclusões obtidas e sugestões de pesquisas futuras.

Capítulo 2

Revisão Bibliográfica

Neste capítulo serão apresentados estudos e conceitos relacionados ao tema proposto neste trabalho.

2.1 Mercado de Renda Variável

Ativos de renda variável são os investimentos em que os retornos de capital não podem ser estimados no momento da aplicação. Seus retornos dependem das expectativas do mercado financeiro, podendo variar positivamente ou negativamente. Os investimentos de renda variável mais comuns são as ações, imóveis e *commodities* (moedas, ouro, dentre outros).

2.1.1 Mercado de ações

As ações são a menor parcela de capital de uma empresa e, ao adquirir ações, o investidor torna-se seu sócio. Os lucros obtidos pelo investidor estão diretamente ligados à capacidade da empresa em gerar lucro e, conseqüentemente, à oferta e procura das ações no mercado [Assaf Neto 2000].

Basicamente, existem duas formas de se negociar ações no mercado de ações, apresentadas a seguir:

- **Compra e Venda:** Uma ação de uma empresa é comprada por um valor e, após um período, a ação é vendida. Quando o preço de venda é maior que o preço de compra, é obtido o lucro na diferença de valores. Caso contrário, o investidor tem prejuízo na operação;
- **Compra e Venda a descoberto:** Nesta modalidade, um investidor inicia a negociação vendendo a ação, sem efetivamente possuí-la. Após um período, o investidor compra a ação vendida e, caso o preço de compra seja menor que o

preço de venda, é obtido lucro com a diferença. Caso o preço de compra seja maior do que o preço da venda (se o preço da ação subiu no período), o investidor tem prejuízo na operação. Nesta forma de negociação, os investidores podem ter lucros, mesmo que a bolsa esteja em queda.

Os investidores do mercado de ações geralmente adotam estratégias de investimento que envolvem operações de compras e vendas de ações, podendo ser as operações tradicionais ou a descoberto. As operações podem ser realizadas com alta frequência, podendo operar várias vezes por minuto em alguns casos (esse tipo de operação não é muito comum no mercado brasileiro), baixa frequência (geralmente se refere a qualquer estratégia que detenha ativos por mais de um dia de negociação.), ou apenas uma única vez (conhecido como *Buy and Hold*). A estratégia *Buy and Hold* é considerada uma estratégia de investidores mais conservadores, que compram ações de empresas que consideram confiáveis, e aguardam o retorno a longo prazo.

Para escolher uma estratégia de investimento, é importante para o investidor saber qual será o comportamento das ações da empresa escolhida para investir. Existem duas abordagens mais comuns para tentar estudar comportamento dos preços, a análise técnica e a análise fundamentalista, descritas nas próximas seções.

2.1.2 Fundos de Índice

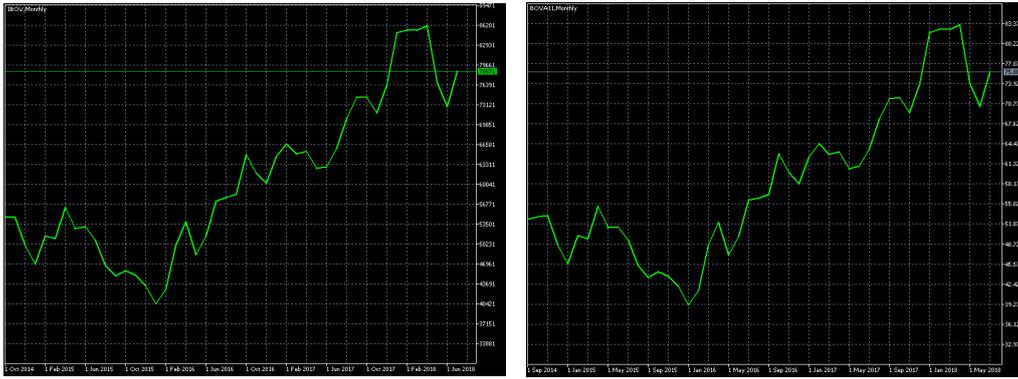
Fundos de Índice (FI), também conhecidos como *Exchange-Traded Funds* (ETFs) são fundos de investimento negociados em bolsas de valores que possuem o objetivo de acompanhar o desempenho de um índice de referência do mercado, como o IBOVESPA. As negociações podem ser realizadas em tempo real, sendo permitidas operações de compra e venda, como nas negociações no mercado de ações.

O índice IBOVESPA (IBOV) é formado atualmente por uma carteira de mais de 60 ações, cada uma delas com pesos diferentes para compor o índice, de acordo com seu peso nos volumes de negócios e financeiro movimentados na bolsa.

Para o investidor comum simular uma carteira igual ao IBOVESPA seria necessário um grande volume de recursos para adquirir cada um dos mais de 60 ativos na mesma proporção que cada um deles compõem o índice.

O BOVA11 é o maior Fundo de Índice no mercado brasileiro e utiliza IBOVESPA como índice de referência, tendo como objetivo obter uma performance próxima ao IBOV. Para simular o índice, o dinheiro investido é aplicado na compra de ações diversificadas exatamente nas mesmas proporções do IBOVESPA. Ao adquirir o BOVA11, o investidor conseguirá, de forma mais simples, investir em um fundo com comportamento similar ao IBOVESPA sem precisar investir em várias ações, com diferentes proporções e com um menor valor de investimento.

As figuras 2.1(a) e 2.1(b) mostram os gráficos do índice BOVESPA e do fundo BOVA11 no mesmo período. Analisando o comportamento dos gráficos, é possível



(a) Gráfico BOVESPA.

(b) Gráfico BOVA11

Figura 2.1: Comparativo dos gráficos IBOVESPA e BOVA11

constatar a semelhança entre os preços e como o BOVA11 consegue reproduzir o índice da BOVESPA.

2.1.3 Inclinação da Regressão Linear

O indicador Inclinação da Regressão Linear (*Linear Regression Slope*) ou LRS é utilizado para indicar a direção e medir a força de uma tendência.

Uma regressão linear é uma reta que melhor se ajusta a uma série de pontos [Neter et al. 1996], que no caso do problema descrito neste trabalho, seriam os preços diário dos ativos. A figura 2.2 mostra uma regressão linear para o período de 10 dias de preços do BOVA11. A reta pode ser interpretada como uma linha de tendência, baseada sempre nos períodos de preços em que ela se ajusta.

O indicador LRS representa o coeficiente angular desta reta, ou seja, assumindo valores positivos em uma tendência de alta (inclinação crescente) e negativos em uma tendência de baixa (inclinação decrescente).

A figura 2.3 mostra o comportamento do indicador (gráfico inferior), utilizando o período de 10 dias através da série de preços do índice BOVA11 (gráfico superior), podendo ser visualizada sua variação, de acordo com a variação dos preços.

2.1.4 Análise Fundamentalista

A análise fundamentalista estuda os fatores econômicos que podem influenciar os movimentos do mercado, baseando-se nos fundamentos da empresa, como, por exemplo, patrimônio líquido, grau de endividamento e o pagamento de dividendos para dar um diagnóstico da saúde financeira da empresa. Se as informações sobre a empresa forem positivas, os preços das ações tendem a aumentar, caso contrário, os preços

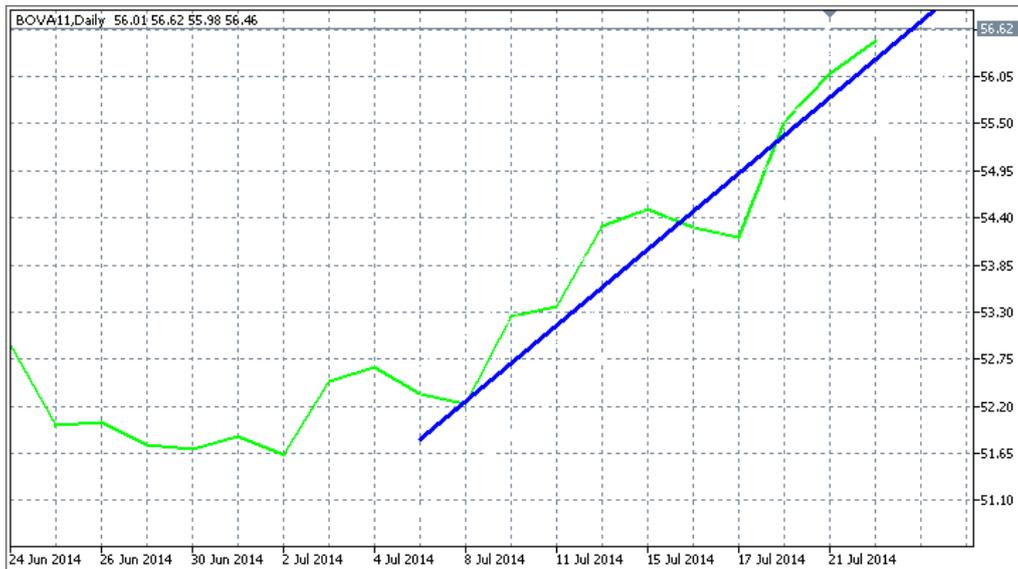


Figura 2.2: Regressão Linear - 10 dias

tendem a cair [Piazza 2009]. Este tipo de análise é mais comumente usada em um espectro de previsão de longo prazo [Cavalcante et al. 2016]. Como exemplo de alguns indicadores da análise fundamentalista estão o pagamento anual de dividendos por ação, a relação Preço/Lucro de suas ações e até critérios qualitativos, como reconhecimento da marca da empresa.

2.1.5 Análise Técnica

A análise técnica não se baseia em índices e informações sobre a empresa, levando em conta o histórico de preços das ações para tentar prever o comportamento futuro [Zhu e Zhou 2009]. Para realizar essa previsão, vários dados sobre as ações podem ser considerados, como os preços máximo, médio e mínimo em um determinado período de tempo, o volume, padrões de gráficos (*candlesticks*) e diversos indicadores que são calculados através desses dados [Piazza 2009].

Candlesticks

Os *candlesticks* são gráficos que representam os preços máximo, mínimo, de abertura e de fechamento de um ativo em um determinado período de tempo (figura 2.4). Eles possuem esse nome porque o seu formato lembra o de uma vela. Esses gráficos podem representar o comportamento de uma ação durante um período de tempo desejado, podendo ser o comportamento de um dia, uma semana, ou um minuto, por exemplo.

A parte grossa do gráfico é chamada de corpo e representa o intervalo entre o preço de abertura e fechamento. Quando o corpo do *candlestick* é preenchido, o gráfico

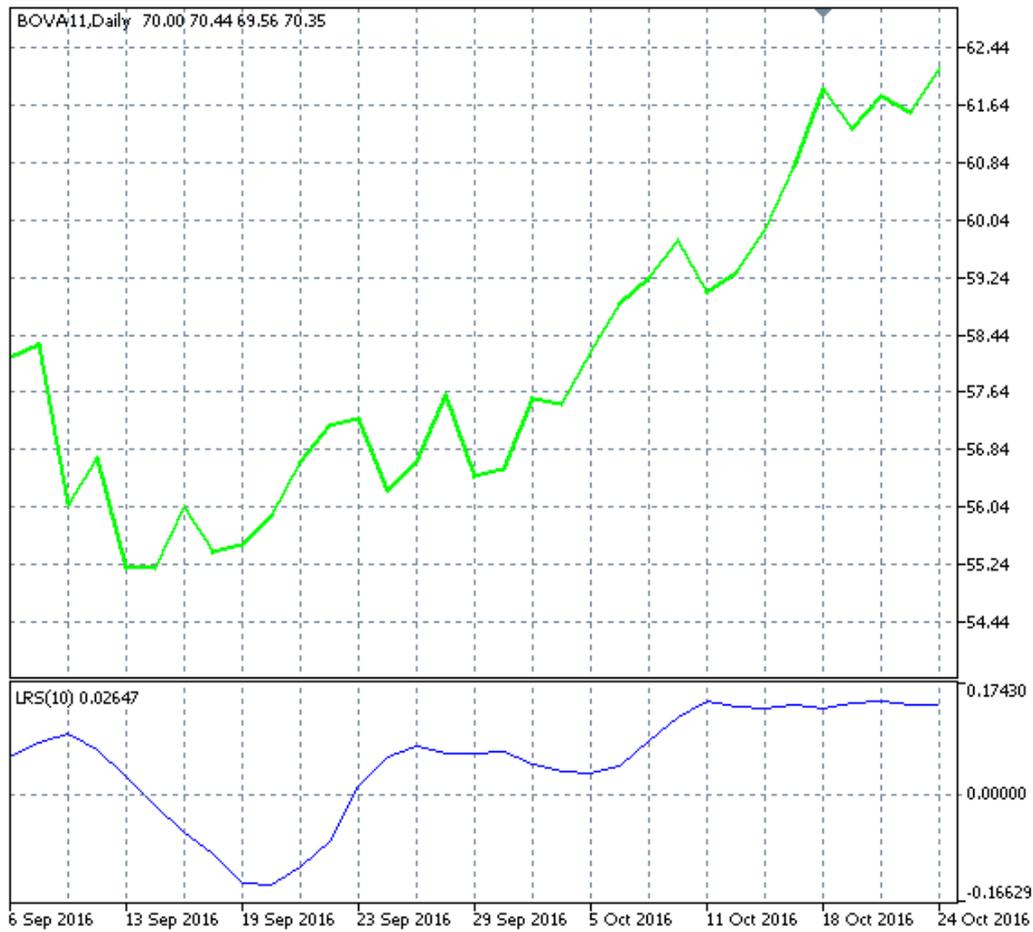


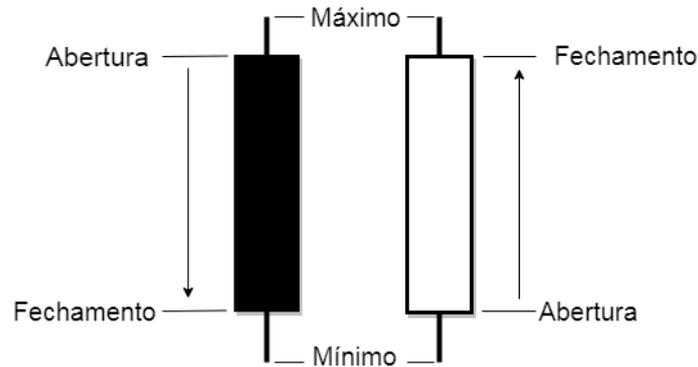
Figura 2.3: Cotação BOVA 11 x Indicador LRS - 10 dias

representa um período de baixa (preço de abertura maior que o preço de fechamento), já o corpo sem preenchimento, representa um período de altas nos preços (preço de abertura menor que o preço de fechamento). As linhas acima e abaixo do corpo são chamadas de sombras e representam os extremos (menor e maior preço, respectivamente) do preço no período.

Existem vários padrões de sequências de *candlesticks* que servem para identificar tendências de alta e de baixa.

Médias Móveis

A média móvel é um dos indicadores mais tradicionais da análise técnica, podendo confirmar tendência de preços logo no seu início, mas podem fornecer informações imprecisas quando o mercado está sem tendência definida. Na prática, as médias móveis são uma média das cotações dos últimos n dias [Murphy 2003], dada pela

Figura 2.4: *Candlesticks*

fórmula 2.1, sendo P_i o preço de fechamento do i -ésimo dia e n o número de dias.

$$MA = \sum_{i=1}^n \frac{P_i}{n} \quad (2.1)$$

Empiricamente, através de experiência acumulada pelos investidores, foi definido que, para realizar análises de médio prazo, geralmente são utilizadas médias móveis de 20 a 50 dias. Já para análise de longo prazo, são utilizadas médias móveis de 100 a 200 dias [Murphy 2003].

O cruzamento de médias móveis pode ser utilizado por investidores para previsão do comportamento do mercado. Geralmente são utilizadas duas médias móveis, uma rápida (50 dias, por exemplo) e outra mais lenta (200 dias, por exemplo) e a previsão de tendência é dada da seguinte forma [Murphy 2003]: sempre que a média móvel rápida (menor número de dias) cruzar de baixo para cima a média móvel lenta, é um indicativo de compra. Caso o cruzamento ocorra de forma contrária, é gerado um sinal de venda. Geralmente o cruzamento de médias móveis é associado a alguma outra regra que confirme a tendência, como o volume de ações negociadas.

O volume é um indicador que apresenta o número de ações negociadas em um período especificado. Caso o volume cresça nos últimos dias, a tendência é confirmada [Murphy 2003]. A figura 2.5 ilustra um cruzamento entre uma média móvel de 20 dias com uma média móvel de 200 dias, em que a média móvel rápida cruza a média móvel lenta de cima para baixo, indicando, portanto um sinal de venda.

Índice de Força Relativa

O Índice de Força Relativa ou *Relative Strength Index* (RSI) [Wilder 1978] é outro indicador bastante popular. Ele pertence à classe dos osciladores, expressando a força relativa do movimento dos preços, sendo comumente utilizado quando o mercado não apresenta uma tendência definida [Murphy 2003].

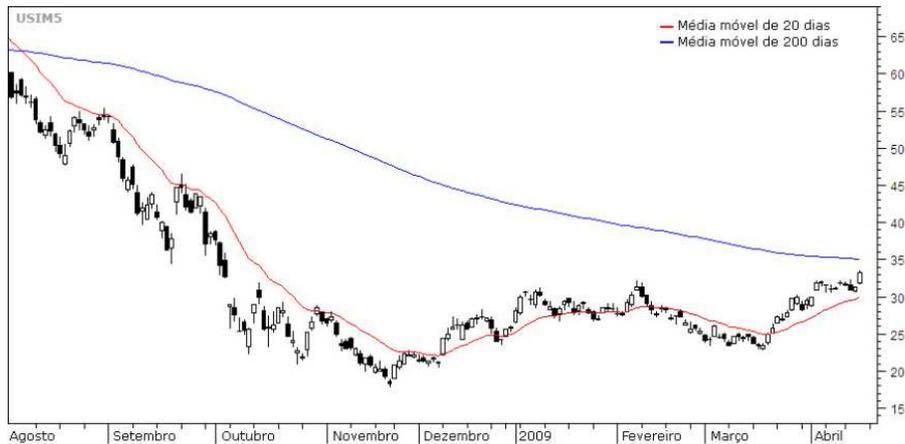


Figura 2.5: Cruzamento de Médias Móveis
Fonte: [Teixeira 2009].

O RSI pode assumir valores no intervalo de 0 a 100. Caso o índice esteja acima de 70 para um ativo, significa que o seu preço está sobrecomprado, e deve-se considerar a venda do ativo. Da mesma forma, se o índice estiver abaixo dos 30 pontos, o ativo é considerado sobrevendido e é indicado realizar a sua compra. Muitos investidores consideram que o intervalo do índice pode variar, considerando acima de 80 para venda em um mercado em alta e abaixo de 20 para compra quando o mercado estiver em queda [Murphy 2003].

$$RSI = 100 - \frac{100}{1 + RS} \quad (2.2)$$

$$RS = \frac{mediaGanho}{mediaPerda} \quad (2.3)$$

As equações 2.2 e 2.3 são utilizadas para calcular o RSI, onde as variáveis *mediaGanho* e *mediaPerda* são a soma dos ganhos em *n* períodos divididos pela quantidade de períodos e as perdas em *n* períodos divididas pela quantidade de períodos, respectivamente.

MACD

O MACD (*Moving Average Convergence Divergence*) [Appel 1985] é formado pela diferença entre 02 (duas) médias móveis exponenciais, sendo uma de longo prazo e outra de curto prazo. Geralmente, o MACD é obtido subtraindo o valor de uma média móvel exponencial de 26 períodos ao valor obtido de uma média móvel exponencial de 12 períodos.

$$MACD_i = MME_i(p_1) - MME_i(p_2) \quad (2.4)$$

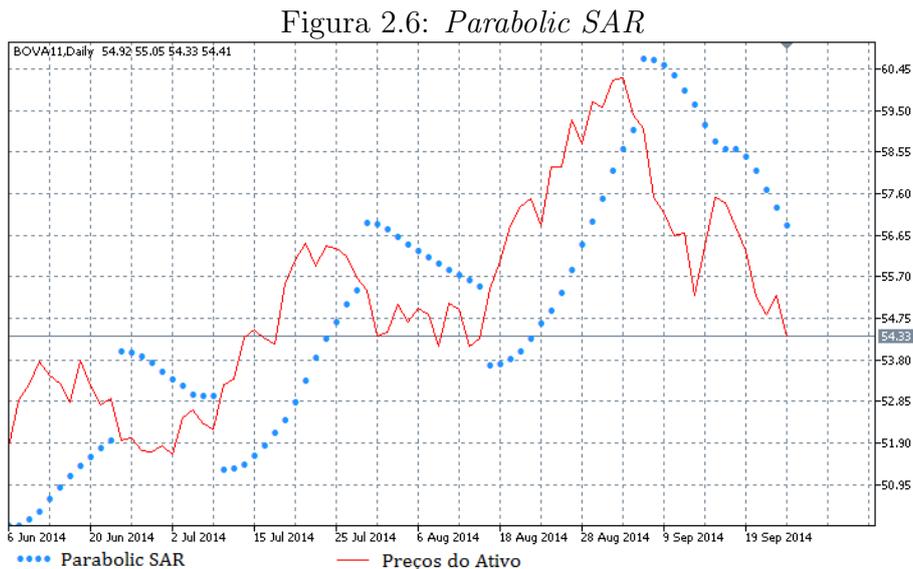
Ao se aplicar a equação 2.4 (em que MME_i é a média móvel exponencial no i -ésimo dia e p_1 e p_2 são os seus períodos) é obtida uma linha que oscila acima ou abaixo de zero, podendo-se assim, interpretar os resultados obtidos por este indicador. Se o valor do MACD for maior que zero, o resultado da média móvel exponencial de curto prazo (12 períodos) é maior que o valor da média móvel de longo prazo (26 períodos), o que sinaliza que os preços mais recentes são mais altos que os preços dos dias anteriores, sinalizando uma tendência de alta do mercado. O contrário vale para quando o MACD for menor que zero (tendência de baixa).

A equação 2.5 mostra a fórmula da média móvel exponencial. O valor de MME_1 é igual ao preço de fechamento do primeiro dia e o valor de d_i é o valor do preço atual.

$$MME_i(p_1) = (d_i - MME_{i-1}(p_1)) \frac{2}{1 + p_1} + MME_{i-1}(p_1) \quad (2.5)$$

Parabolic SAR

O Indicador Parabolic SAR [Wilder 1978] foi desenvolvido para analisar as tendências de mercado. O indicador é construído sobre o gráfico de preços, semelhante às médias móveis, com a diferença de que o valor do *Parabolic SAR* se move com uma maior rapidez. Quando o valor do indicador está abaixo dos preços, provavelmente a tendência do mercado é de alta, caso o valor esteja acima dos preços, a tendência do mercado provavelmente é decrescente, ou seja, se o preço cruza a linha do indicador, há uma mudança de tendência. A figura 2.6 mostra como o indicador Parabolic SAR (pontos) acompanha a tendência de preços (linha).



O *Parabolic SAR* é calculado de maneira antecipada, de forma que os preços de um dia definem o SAR do dia seguinte. A equação 2.6 mostra o cálculo do indicador, onde os valores de SAR_i e de SAR_{i+1} representam os valores de hoje e de amanhã do SAR, respectivamente.

O PE (Ponto Extremo) na equação, é o recorde obtido em cada tendência de alta ou de baixa observada, o que representa o preço mais alto atingido em uma tendência de alta de uma ação, e o preço mais baixo atingido em uma tendência de baixa.

O valor do α representa o fator de aceleração, normalmente é adotado o valor padrão de 0,02 pelos analistas financeiros. O valor do SAR_i , quando $i=1$ é igual ao preço máximo da ação no dia anterior caso a tendência do SAR esteja indicando tendência de baixo (ou o preço mínimo do dia anterior, caso o SAR esteja indicando uma tendência de alta).

$$SAR_{i+1} = SAR_i + \alpha(PE - SAR_i) \quad (2.6)$$

Highest High Value e Lowest Low Value

Os indicadores *Highest High Value* (HHV) e *Lowest Low Value* (LLV) retornam, respectivamente, o preço mais alto e o mais baixo em um determinado período de tempo [Skapura 1996].

Average True Range

O indicador *Average True Range* (Variação Verdadeira Média) [Wilder 1978] ou ATR mede a volatilidade dos preços de determinado ativo em um determinado período. Para isso, é considerado sempre o maior valor absoluto entre as opções (equação 2.7):

- O maior preço atual (*high*) menos o preço de fechamento anterior ($close_{prev}$);
- O preço de fechamento anterior ($close_{prev}$) menos o menor preço atual (*low*);
- Maior preço atual (*high*) menos o menor preço atual (*low*).

$$TR = \max[| (high - close_{prev}) |, | (close_{prev} - low) |, (high - low)] \quad (2.7)$$

O indicador ATR no tempo t é calculado através da média das maiores diferenças entre esses valores em n períodos, como mostra a equação 2.8, onde ATR_{t-1} é igual ao ATR do intervalo de tempo anterior, n é o período de utilizado e TR_t é obtido pela equação 2.7.

$$ATR_t = \frac{ATR_{t-1}(n - 1) + TR_t}{n} \quad (2.8)$$

O primeiro valor do ATR é calculado pela equação 2.9.

$$ATR = \frac{1}{n} \sum_{i=1}^n TR_i \quad (2.9)$$

Existem diversas estratégias e formas para o investidor negociar ações, utilizando a análise fundamentalista ou a análise técnica e seus indicadores combinados, mas para a estratégia se tornar eficaz, é preciso escolhê-la e aplicá-la para descobrir se ela é lucrativa, o que pode ser trabalhoso e dar muito prejuízo aos investidores. Nesse cenário, surgem os sistemas de negociação (*trading systems*), que buscam auxiliar os investidores na tomada de decisão de como e quanto investir no mercado financeiro.

2.1.6 Sistemas de Negociação

Os sistemas automáticos de negociação, também conhecidos como robôs, são programas implementados em alguma linguagem de programação que automatiza estratégias de negociação para o investidor. O uso de robôs investidores têm se tornado popular atualmente, já existindo diversas corretoras, inclusive no Brasil, compatíveis com as principais plataformas de sistemas automáticos de negociação, como o Metatrader 5, possibilitando que o próprio investidor implemente os seus robôs, ou possa comprá-los prontos.

Basicamente, um sistema de negociação na bolsa de valores se divide em três partes principais [Vanstone et al. 2012]:

- Regras de entrada e saída de negociações;
- Controle de Riscos;
- Gerenciamento de Dinheiro.

Abaixo, serão detalhados cada uma dessas partes do sistema.

Regras de entrada e saída de negociações

O sistema de negociação deve possuir regras de entrada e saída de uma negociação. O ideal é que o sistema adote uma estratégia que se antecipe às reversões de tendência do mercado financeiro, por exemplo, comprando uma ação antes de uma tendência de alta e vendendo antes de uma tendência de queda.

Controle de Riscos

O sucesso no mercado financeiro não depende apenas de uma boa estratégia de negociação. A estratégia, por melhor que seja, não trará sempre lucro em cada posição de investimento e, por isso é necessário criar uma saída, caso o investimento esteja

causando prejuízo. Da mesma forma, ao investir em uma ação que está gerando lucro, é razoável que este lucro seja resgatado antes que o mercado mude de tendência e a posição vencedora se torne em uma posição perdedora.

Para as situações relatadas anteriormente, existem os mecanismos de *stop loss* e *take profit*. Basicamente, estes tipos de ordem permitem que o investidor defina o valor do preço da ação para saída da posição em caso de prejuízo (*stop loss*) e o valor da ação que garanta um lucro aceitável (*take profit*), de forma que seja possível gerir os investimentos para que não haja muita perda nas posições perdedoras e que os lucros estejam garantidos nas posições vencedoras.

Uma estratégia que incrementa a gestão de riscos é um mecanismo de *Trailing Stop* que permite ajustar os valores de *stop loss* após ser lançada uma ordem em um ativo. O *Trailing Stop* é projetado para proteger os ganhos, permitindo que um trade permaneça aberto e continue a lucrar, desde que o preço esteja se movendo na direção certa, mas fechando operação se o preço mudar de direção, tentando garantir uma menor perda ou até mesmo lucro, mesmo que haja reversão da tendência do mercado.

Por exemplo, se o investidor adquire uma ação no valor de R\$13,00 e o valor de *stop loss* seja R\$12,00 e o mercado segue em alta, o *Trailing Stop* ajusta o valor do *stop loss* para um valor mais alto, podendo até mesmo superar o valor inicial da posição (R\$13,00), garantindo dessa forma, que mesmo que haja uma reversão do mercado, o investidor diminua suas perdas ou até mesmo lucre com o mercado desfavorável.

Gerenciamento de Dinheiro

O gerenciamento de dinheiro, também conhecido como dimensionamento de posição, refere-se ao quanto será investido no negócio a ser iniciado, levando em consideração o capital da conta e o risco potencial da transação [Vanstone et al. 2012]. Neste trabalho, foi utilizada a estratégia *Percent Volatility* para gerenciamento do dinheiro, que pode ser visto com mais detalhes no capítulo 3.

Com as diversas possibilidades de estratégia para operar na bolsa de valores e considerando a dificuldade de prever o comportamento do mercado financeiro, os sistemas de negociação têm utilizado a inteligência computacional, em especial as redes neurais, para tentar prever o comportamento futuro do mercado de ações para auxiliar o investidor nas suas aplicações.

2.2 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) são técnicas computacionais inspiradas no sistema nervoso dos seres humanos que adquirem conhecimento através de experiências anteriores utilizando modelos matemáticos [Haykin 2001]. A arquitetura das redes

neurais é formada por neurônios e conexões entre eles. Cada neurônio é uma unidade de processamento e a sua saída serve de entrada para o nó da camada seguinte.

Um neurônio possui um conjunto de conexões (sinapses), cada uma com um peso próprio, um somador, para somar os sinais de entrada, já ponderados pelos pesos das sinapses e uma função de ativação para restringir a amplitude de saída do neurônio (Haykin, 2001), como mostra a figura 2.7. Os pesos sinápticos são ajustados durante o treinamento da rede.

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (2.10)$$

$$y_k = \varphi(v_k + b_k) \quad (2.11)$$

Nas equações 2.10 e 2.11, x_1, x_2, \dots, x_m são as entradas da rede, $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k , v_k é a saída do somador, b_k é o bias, que é utilizado para aumentar os graus de liberdade, permitindo que a rede se adapte melhor aos dados fornecidos a ela. O $\varphi(\cdot)$ é a função de ativação utilizada no neurônio que produz o seu sinal de saída.

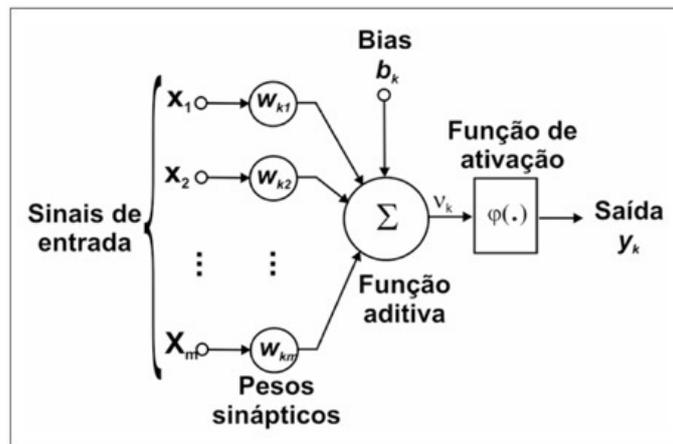


Figura 2.7: Neurônio

Fonte: [Haykin 2001].

As redes neurais podem ser classificadas de acordo com a estruturação dos neurônios ou quanto ao aprendizado. De acordo com a estruturação dos neurônios elas podem ser classificadas como:

- **Camada Única:** As redes de camada única são a forma mais simples de uma rede em camadas. Nela estão presentes apenas a camada de entrada ligada a uma camada de saída. A designação de “camada única” é referente à camada de saída dos nós, onde estão os nós computacionais da rede. A camada de entrada não é contabilizada porque nela não é realizado nenhum tipo de processamento dos dados.

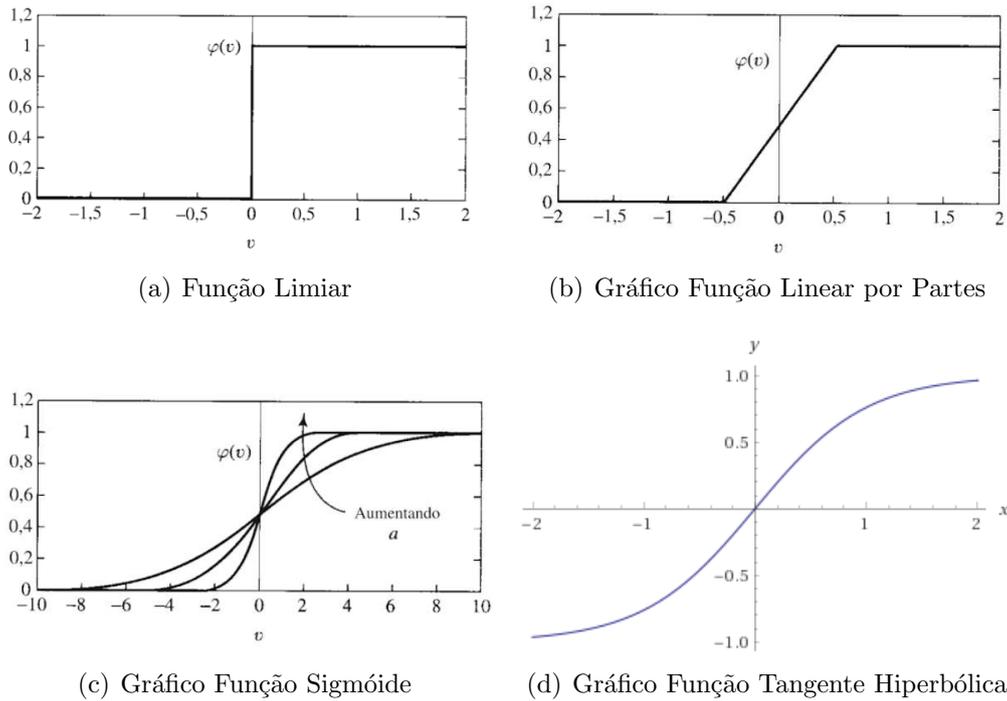


Figura 2.8: Funções de ativação

Fonte: [Haykin 2001].

- Multicamadas com propagação para frente, também conhecida como perceptron multicamadas, em que todos os neurônios de uma camada possuem conexão com os neurônios da camada subsequente (ver figura 2.9);
- Recorrentes, Segundo Haykin [Haykin 2001], são redes que possuem pelo menos um laço de realimentação, ou seja, a saída de um neurônio pode servir de entrada para neurônios da sua própria camada (incluindo o próprio) ou para neurônios de camadas anteriores.

As figuras 2.8(a), 2.8(b), 2.8(c), 2.8(d), mostram os gráficos de algumas das principais funções de ativação, respectivamente, a função limiar, função linear por partes, função sigmóide e a função tangente hiperbólica.

De acordo com o aprendizado as redes podem ser: supervisionadas, não supervisionadas e de aprendizado com reforço. No aprendizado supervisionado um conjunto de exemplos, representados pelos atributos de entrada, é fornecido ao algoritmo de aprendizado, sendo que cada exemplo possui uma classe associada. O objetivo geral do treinamento supervisionado é fazer a indução de um mapeamento geral dos exemplos com a classe correta. Portanto, o sistema de aprendizado deve simular uma função que tenta mapear a saída para cada um dos exemplos fornecidos à rede durante o treinamento de forma que essa função consiga mapear as saídas para dados desconhecidos.

No treinamento por reforço, o mapeamento entre entrada e saída é realizado através

de uma interação contínua com o ambiente de modo a maximizar alguma noção de recompensa cumulativa utilizando, por exemplo, alguma função heurística para determinar a qualidade da resposta da rede a uma determinada entrada através de recompensas ou penalização. A maximização (minimização) da recompensa (penalidade) ao longo do treinamento conduz a rede para que seus parâmetros sejam recalibrados adequadamente.

No aprendizado não supervisionado é fornecido um conjunto de exemplos ao sistema de aprendizado referentes aos atributos de entrada, sem que eles necessariamente estejam classificados. O objetivo é que seja construído um modelo que seja capaz de realizar agrupamentos nos exemplos com características similares.

2.2.1 Redes *Multilayer Perceptron*

Nesta seção serão descritas as redes *Multilayer Perceptron* supervisionadas com propagação para frente, que foram as escolhidas para serem utilizadas neste trabalho. A figura 2.9 mostra uma rede neural multicamadas. Cada camada é classificada como:

- Camada de Entrada: Os padrões são adicionados à rede neural por esta camada;
- Camadas Intermediárias ou Escondidas: Nesta camada é feita a maior parte do processamento. As redes multicamadas possuem uma ou mais camadas escondidas.
- Camada de Saída: o resultado é apresentado nesta camada.

As redes neurais *MultiLayer Perceptron* (MLP) são redes *feedforward* (a propagação dos sinais ocorre em um único sentido, da entrada para a saída) e se caracterizam por possuírem uma ou mais camadas intermediárias, que permitem o tratamento de problemas complexos e não-lineares [Haykin 2001]. O algoritmo de treinamento mais utilizado nas MLPs é o *backpropagation*, que consiste nos seguintes passos:

A entrada da rede é apresentada e o sinal é propagado para a frente até a camada de saída da rede, então é calculado o erro, que corresponde à diferença entre o resultado real e o resultado gerado pela rede. A partir do erro, é propagado um sinal para as camadas anteriores para que sejam calculados novos pesos sinápticos. O algoritmo é repetido até que o erro chegue a um valor pré-definido ou que seja configurado um número máximo de repetições [Haykin 2001].

2.2.2 Métricas de Qualidade

As métricas descritas a seguir são popularmente usadas na comparação de modelos de classificação. Cada uma delas busca avaliar um aspecto diferente do modelo.

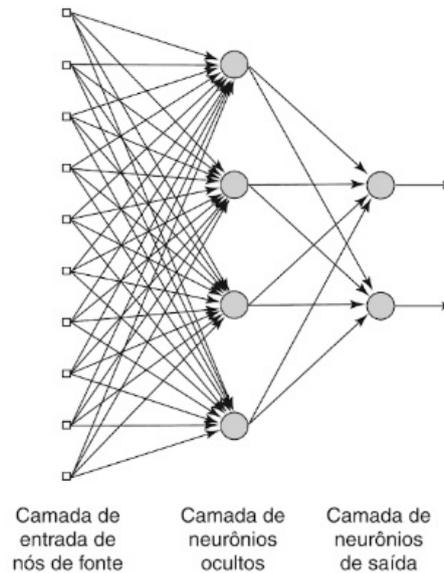


Figura 2.9: Estrutura de uma rede neural
Fonte: [Haykin 2001].

Matriz de Confusão

A matriz de confusão, representada na figura 2.10 é um recurso importante para análise do desempenho do previsor. Os valores que compõem a matriz são obtidos fornecendo os elementos do conjunto de teste ao classificador e a sua predição é comparada com a classe verdadeiramente correta.

Após a comparação, os valores são classificados em quatro possíveis opções:

- Verdadeiro Positivo (VP): segmentos que pertencem à classe positiva e foram classificados como positivos.
- Falso Positivo (FP): segmentos que pertencem à classe negativa e foram classificados como positivos.
- Falso Negativo (FN): segmentos que pertencem à classe positiva e foram classificados como negativos.
- Verdadeiro Negativo (VN): segmentos que pertencem à classe negativa e foram corretamente classificados como negativos.

A acurácia refere-se à quantidade de exemplos tanto da classe positiva e da negativa que foram classificados corretamente. A acurácia deve ser avaliada com cuidado caso o conjunto esteja com classes desbalanceadas. Por exemplo, se o conjunto de dados apresentar majoritariamente uma classe, mesmo se a rede apresentasse uma predição fixa para a classe em maior número, a acurácia seria alta, mas não necessariamente seria um bom previsor. A equação 2.12 mostra como calcular a acurácia.

		Valores Reais	
		Positivos	Negativos
Valores Previstos	Positivos	VP	FP
	Negativos	FN	VN

Figura 2.10: Matriz de Confusão - 2 classes

$$Ac = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.12)$$

A precisão é calculada através da equação 2.13. Representa a quantidade de exemplos que, dentre todos classificados como positivos pelo predictor, pertencem à classe positiva;

$$Prec = \frac{VP}{VP + FP} \quad (2.13)$$

O Recall representa o percentual elementos positivos que foram classificados corretamente em relação aos todos os positivos reais (ver fórmula 2.14).

$$Recall = \frac{VP}{VP + FN} \quad (2.14)$$

2.3 Avaliação do Sistema de Negociação

Para avaliar o sistema de negociação, foram utilizadas algumas métricas que serão descritas a seguir.

2.3.1 *Compound Annual Return (CAR)*

O *Compound Annual Return* (Retorno Anual Composto) é o percentual do quanto o sistema de negociação entrega de lucro por ano. É um percentual do ganho médio do período em que a estratégia foi testada.

2.3.2 *Maximum Drawdown*(MDD)

O *Maximum Drawdown* (Máximo Drawdown), é um indicador de risco que evidencia a maior perda ocorrida desde um ponto de alta até um ponto de mínima em uma série histórica [Vanstone et al. 2012]. A figura 2.11 demonstra o MDD em uma série de preços.

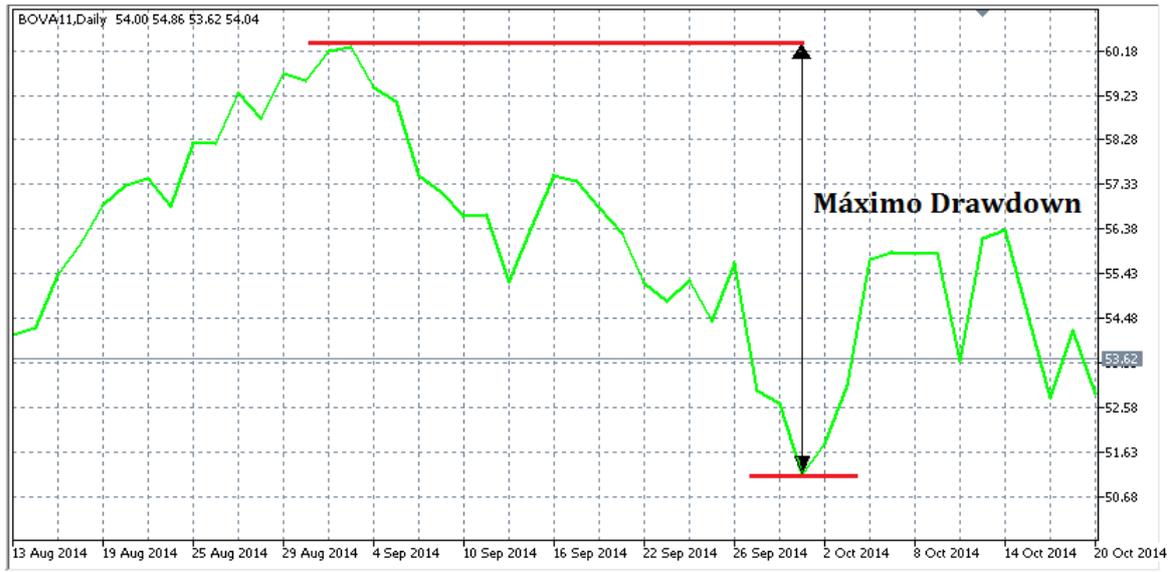


Figura 2.11: *Maximum Drawdown*

O objetivo deste indicador é mensurar a maior queda de valor de um ativo, entre um valor máximo e um rebaixamento deste valor em uma data posterior. O MDD pode ser usado como uma medida de risco da estratégia de investimento utilizada. Sua fórmula é mostrada na equação 2.15, em que mínimo (*min*) é o ponto mais baixo da série de preços analisada e máximo (*max*) é o ponto mais alto antes da série atingir o valor mínimo.

$$MDD = \left| \frac{(min - max)}{max} \right| \quad (2.15)$$

2.3.3 CAR/MDD

A divisão entre as duas taxas, CAR e MDD representa a relação entre o retorno e o risco e serve para avaliar o sistema ou mesmo comparar com outros sistemas de negociação.

2.3.4 Fator de Lucro (*Profit factor*)

O fator de lucro (PF) pode ser simplesmente definido como lucros brutos (LB) divididos por perdas brutas (PB), como pode ser visto na equação 2.16. É um índice calculado de forma simples e que permite avaliar se o sistema está sendo lucrativo.

$$PF = \frac{LB}{PB} \quad (2.16)$$

2.4 Revisão de Literatura

Durante o levantamento bibliográfico, foram identificados trabalhos que utilizam redes neurais na tentativa de prever o comportamento no mercado de ações. Esta seção irá discutir as diversas abordagens adotadas pelos trabalhos pesquisados.

Nas últimas décadas, as RNAs se tornaram muito populares no contexto da previsão do mercado financeiro. A capacidade de lidar com dados não-lineares e descontinuidades típicas das séries temporais tornam as redes neurais uma boa opção de aplicação na tentativa de prevê-lo. Vários tipos de RNAs propostas na literatura foram projetados e aplicados na previsão do mercado financeiro.

Em Macedo et. al [Macedo et al. 2013] foi proposto um sistema automático de negociação para auxiliar o investidor na tomada de decisões utilizando um previsor de preços baseado em uma rede neural que utiliza a arquitetura *MultiLayer Perceptron* (MLP). A rede foi projetada com 3 neurônios na camada de entrada, 2 camadas intermediárias, sendo 6 neurônios em cada e 1 neurônio na camada de saída. Em todos os neurônios foi utilizada a função de ativação sigmóide. Também foi implementado um previsor baseado em regressão linear para que seus resultados fossem comparados aos da rede neural. As variáveis de entrada utilizadas na rede neural foram o preço de abertura da ação no dia, o preço de fechamento no dia anterior e a variação, em porcentagem, do preço do ativo no dia anterior. Para realizar a previsão de um dia n , são utilizados os 5 dias anteriores para validação e o sexto dia anterior até o primeiro dia disponível da amostra dos dados históricos para realização do treinamento.

O sistema proposto por Macedo et al. [Macedo et al. 2013] funciona da seguinte forma: O investidor deve informar o risco que quer correr ao utilizar o sistema, podendo ser baixo ($k=0,1$), médio ($k=0,2$) ou alto ($k=0,3$). O valor do risco é dado em centavos de real. Quanto maior o risco, mais chances de obter lucro ou prejuízo.

Após obter as informações de risco do investidor, na segunda etapa do sistema é realizada a previsão do preço médio da ação escolhida (através dos previsores citados anteriormente). Na etapa seguinte, é calculado o preço de compra e venda das ações, de acordo com o risco escolhido e o preço previsto na segunda etapa, sendo o preço

de compra igual ao preço médio previsto (pelo previsor) subtraído do risco (k) e o preço de venda igual ao preço médio previsto somado ao valor do risco. No geral, as previsões realizadas pela regressão linear foram mais satisfatórias que as previsões da rede neural, possuindo um erro médio consideravelmente menor. Analisando os lucros obtidos por cada um dos previsores, percebe-se que apesar da eficiência nas previsões, o previsor baseado em regressão linear não é o que obtém mais lucros, ganhando em alguns ativos e perdendo em outros para o previsor de redes neurais.

Em Chiang et al. [Chiang et al. 2016] foi desenvolvido um sistema adaptativo para prever a direção dos preços das ações. A informação da direção dos preços é utilizada como um sinal para auxiliar os investidores a operarem na bolsa. O valor de saída da rede neural é normalizado entre 0 e 1, seguindo as regras:

- 0.5 a 1 - é categorizado como 1 e significa que o preço da ações está subindo.
- 0 a 0.5 - é categorizado como 0 e significa que o preço da ações está em queda.

O sistema irá sugerir ao investidor para comprar ou manter a ação quando a saída for 1 ou vender quando a saída for zero. Foi utilizada a Otimização por enxame de partículas (ou PSO) para encontrar um conjunto inicial ótimo de pesos para a rede. O PSO é um método computacional que otimiza um problema, melhorando uma solução candidata iterativamente, através da avaliação de uma função de aptidão.

A estrutura da rede neural utilizada consiste em 3 camadas com retroalimentação e uma camada escondida. O número de neurônios utilizados na camada escondida foi de $2N-1$, onde N é o número de entradas. Na camada de saída há apenas um neurônio: a direção do movimento da ação. Foi utilizado o backpropagation como algoritmo de treinamento. Diferentes combinações de entradas foram avaliadas durante os ensaios de modelagem, e foi selecionado o modelo final baseado na performance de predição. O sistema proposto superou a estratégia buy-and-hold, em média, em 136,53%.

Em Lin, Yang e Song [Lin et al. 2011] foi utilizado um Algoritmo Genético para ajudar a melhorar a análise técnica tradicional, gerando uma combinação de parâmetros que tentam identificar os melhores parâmetros para cada indicador em diferentes ativos. Os indicadores técnicos melhorados pelo algoritmo genético servem de entrada para uma rede neural, responsável pela predição do comportamento do mercado. A função de aptidão da rede neural foi projetada para mensurar o quão perto os pontos sugeridos pelos sistemas estão dos pontos de reversão de tendências. O sistema de trade proposto é baseado em uma rede neural recorrente (RNN)-*Echo State Network* (ESN).

Comparando com as redes neurais convencionais, o treinamento da ESN é simples e não é necessário se preocupar com a convergência local como nas redes neurais tradicionais [Lin et al. 2011]. Foram utilizados indicadores da análise técnica como entrada, em que, cada indicador fornece a sua previsão de quando a tendência será invertida de acordo com o preço de fechamento atual da ação. Então, todos os sinais de cada indicador servem de entrada para a rede neural ESN que irá avaliar se é

apropriado comprar ou vender uma determinada ação com o preço de fechamento atual. Foi utilizada uma rede Neural ESN com 100 neurônios na camada escondida. O desempenho do sistema proposto superou a estratégia buy-and-hold, obtendo lucros significativos em mercados em alta e em baixa.

O sistema proposto no trabalho Huang, Nakamori e Wang [Huang et al. 2005] foi baseado na previsão do movimento financeiro do índice NIKKEI 225 do mercado de ações japonês utilizando SVM (*Support Vector Machine*). Foram feitas comparações com outras estratégias de predição, dentre elas as redes neurais de Elman [Elman 1990]. Os experimentos mostraram que o SVM superou todos os outros métodos de predição. As SVMs são um tipo específico de algoritmo de aprendizado caracterizado pela resistência ao problema da superajustagem. Outra característica é que, diferente das redes neurais, o SVM encontra o único mínimo global para o problema [Huang et al. 2005].

A rede neural de Elman [Elman 1990] é uma rede neural parcialmente recorrente, em que as conexões são principalmente feedforward, mas também incluem um conjunto de conexões de backward, cuidadosamente escolhidas, que permitem que a rede lembre-se de sugestões recentes [Huang et al. 2005].

Como a economia japonesa é diretamente ligada à economia americana, foram utilizadas como entrada o índice S&P 500 (um dos mais importantes do mercado americano). Outra entrada para o modelo foi a cotação do Iene em relação ao dólar. O modelo de predição baseado em SVM foi o que possuiu melhor taxa de acerto na predição de tendências do índice NIKKEI 225, com 73% de acerto, contra 69% de acerto do modelo baseado nas redes neurais de Elman [Huang et al. 2005].

Em Thenmozhi e Chand [Thenmozhi e Sarath Chand 2016] também foi proposto um sistema baseado em SVM adotando modelos que considerassem a influência do mercado de ações global no mercado local. O modelo apresentado superou outros modelos baseados apenas em análise técnica e dados históricos de cotações em todos os sete mercados testados (*Shanghai Stock Index, Hang Seng Index, FTSE-100, Straits Times Index, SP CNX Nifty, S&P500, DJIA*).

O foco do trabalho Qiu e Song [Qiu e Song 2016] é prever a tendência do próximo dia do preço de uma ação. Para isso, foi proposto um modelo baseado em redes neurais artificiais aplicada ao índice da bolsa de valores japonesa. Foi utilizado o algoritmo backpropagation para treinamento, que é utilizado amplamente na área de previsões financeiras.

Contudo, alguns trabalhos relatam que o algoritmo backpropagation pode facilmente convergir para um mínimo local por causa do ruído e dimensionalidade complexa dos dados do mercado de ações [Qiu e Song 2016]. Os algoritmos genéticos foram utilizados em Qiu e Song com o intuito de determinar o conjunto ótimo de pesos e vieses para superar o problema da convergência local. Foram utilizadas as cotações do período 23/01/2007 a 18/10/2012 para treinamento e 19/10/2012 a 30/12/2013 para validação do modelo.

Dois conjuntos de variáveis de entrada foram utilizados e realizadas diferentes combinações de parâmetros pelo algoritmo genético. As melhores taxas de acerto foram com o segundo conjunto de variáveis, que obteve a melhor acurácia na predição de tendência do índice japonês (81.27%).

Em Sugumar e Rengarajan [Sugumar e Rengarajan 2014] foi desenvolvida uma abordagem de predição do mercado financeiro utilizando agrupamento fuzzy C-means e redes neurais artificiais. Os indicadores técnicos são calculados e agrupados através da técnica de agrupamento fuzzy. A proposta de agrupar os dados é que cada grupo terá características homogêneas, diminuindo a complexidade do treinamento. Após o agrupamento, cada grupo servirá de treinamento para uma rede neural.

Os erros do resultado de cada rede neural são combinados com os graus de associação que foram gerados pelo módulo de agrupamento fuzzy. Esses dados são utilizados por outra rede neural que será a responsável por realizar a previsão. Os resultados do sistema proposto foram comparados e superaram os resultados de um sistema existente que utiliza apenas uma rede neural[Sugumar e Rengarajan 2014].

No trabalho Ticknor [Ticknor 2013] foi proposta uma rede neural com regularização bayesiana para tentar prever o comportamento do mercado financeiro. São utilizados cotações diárias e indicadores técnicos como entrada para prever o preço de fechamento com um dia de antecedência. A rede neural com regularização bayesiana atribui uma natureza probabilística aos pesos da rede, permitindo que a rede penalize automaticamente e de forma otimizada modelos excessivamente complexos. A técnica proposta reduz o potencial de *overfitting* e *overtraining*, melhorando a qualidade da predição e a generalização da rede.

Em Oliveira, Nobre e Zárate [de Oliveira et al. 2013] foi construído um modelo baseado em redes neurais para o mercado financeiro para prever os preços de fechamentos de ações na BM&F BOVESPA combinando análise técnica, análise fundamental e análise de séries temporais. Foi utilizada a ação da Petrobrás (PETR4) como estudo de caso. Como resultado, o trabalho obteve 93,62% de predições de direção correta na amostra de testes.

De acordo com Martinez et al. [Martinez et al. 2009], a maioria dos trabalhos que propuseram o uso de RNAs para resolver o problema de previsão financeira utilizaram uma rede neural MLP treinada com o algoritmo de retropropagação com grande sucesso. Nesse trabalho, os autores utilizaram uma MLP para aprender a relação entre alguns indicadores técnicos e para prever cotações diárias máximas e mínimas. Os preços previstos pela rede neural foram usados em um sistema de negociação no mercado de ações real.

Dhar, Mukherjee e Ghoshal [Dhar et al. 2010] utilizou uma MLP para prever o fechamento do índice de ações *Indian Stock Exchange*. A MLP utilizada nesse trabalho foi uma rede de três camadas treinada com o algoritmo de retropropagação. Os autores investigaram várias combinações de parâmetros de rede, como, o número de neurônios de entrada, neurônios ocultos e taxa de aprendizado para

encontrar a melhor configuração de MLP em termos de precisão. Oliveira et al. [de Oliveira et al. 2011] utilizaram uma MLP com três camadas para prever os preços das ações da Petrobrás (PETR4). Uma versão do algoritmo retropropagação, chamado *backpropagation* resiliente, foi usado para treinar a MLP. O melhor resultado foi obtido utilizando dados de 05 dias de cotações para prever o horizonte de 1 dia, obtendo erro médio quadrático de 0,0129.

Jasemi, Kimiagari e Memariani [Jasemi et al. 2011] usaram uma MLP para aprender padrões em gráficos *candlesticks* japoneses. O foco deste trabalho foi descobrir sinais de reversão nos preços, que são indicados na análise dos *candles* por alguns padrões em gráficos conhecidos entre os investidores, como estrela da manhã, martelo invertido, harami, englobamento, entre outros. Esses sinais de reversão representam pontos de compra ou venda de acordo com a análise dos *candles*. Os resultados dos modelos apresentados, com as configurações baseadas em dados brutos e baseadas em sinal, demonstraram eficiência na previsão quando comparadas com as tendências reais.

Kayal [Kayal 2010] investigou o uso de uma rede MLP na previsão do mercado de câmbio (FOREX) utilizando alguns indicadores técnicos, como médias móveis simples e exponenciais, RSI e o desvio padrão de vários períodos diferentes. Chen e Du [Chen e Du 2009] utilizou uma rede neural MLP para, através de índices financeiros e balanços de empresas, classificar empresas com dificuldades financeiras, atingindo 82,14% de acerto nas previsões.

Em Vanstone, Finnie e Hahn [Vanstone et al. 2012] foi aplicada uma MLP para criar um sistema automático de negociação para o mercado de ações australiano. A rede neural implementada usou como entrada quatro variáveis fundamentalistas: relação preço / lucro, valor contábil, retorno sobre o patrimônio líquido e taxa de pagamento de dividendos. A rede retorna um sinal que representa os retornos esperados da empresa e alimenta um sistema de negociação que decide quando comprar ou vender as suas ações. O sistema apresentou um bom desempenho em termos de rentabilidade, mas, foram aplicadas as distribuições de Monte-Carlo que mostraram que os retornos da estratégia são muito voláteis.

Apesar de todas as vantagens do MLP na previsão de séries temporais financeiras, este modelo é altamente sensível a vários parâmetros de rede, como variáveis de entrada e saída, arquitetura neural (*feedforward* ou recorrente), número de camadas ocultas, número de neurônios ocultos, taxa de aprendizado, função de transferência, algoritmo de treinamento, entre outros. Para estudar esse problema, Lasfer, El-Baz e Zualkernan [Lasfer et al. 2013] estudou a escolha dos melhores parâmetros para uma MLP aplicada em séries temporais financeiras. Esta pesquisa foi realizada através do desenvolvimento de experimentos e realizando análises estatísticas. O objetivo desta análise foi encontrar quais parâmetros mais influenciam na precisão da previsão e descobrir a relação entre os parâmetros.

O trabalho de Majhi, Panda e Sahoo [Majhi et al. 2009] propôs o uso de uma rede neural artificial de ligação funcional (FLANN) e a rede neural artificial de ligação

funcional em cascata (CFLANN) para prever as taxas de câmbio. Essas redes neurais são mais robustas e apresentam menor custo computacional quando comparadas com a MLP treinada com a retropropagação.

Mahdi, Hussain e Al-Jumeily [Mahdi et al. 2009] compararam duas variações de MLP, uma MLP auto-organizada (SOMLP), uma rede FLANN e uma MLP convencional. Os resultados mostraram que os maiores lucros foram obtidos usando as redes FLANN e SOMLP no mercado FOREX.

Ghazali et al. [Ghazali et al. 2009] também investigou o uso de redes neurais no contexto do FOREX. Nesse trabalho, foi proposta uma rede neural chamada rede neural polinomial de crista dinâmica (DRPNN). Em um conjunto de experimentos, a DRPNN apresentou melhor desempenho quando comparado com a rede neural polinomial de crista (RPNN) e com a rede neural pi-sigma (PSNN) para alguns pares de moedas.

Em Shahpazov, Velez e Doukovska [Shahpazov et al. 2013] foram abordados três modelos de redes neurais para prever alguns índices do mercado búlgaro: uma MLP foi treinada com o algoritmo de retropropagação, uma rede neural RBF com função radial gaussiana e uma rede neural de regressão geral (GRNN). A rede neural de regressão geral superou os outros dois modelos nos experimentos realizados.

Em Rodríguez-González et al. [Rodríguez-González et al. 2011] foi utilizada uma rede neural generalizada feedforward (GFNN) treinada com retropropagação para o aprendizado do RSI de algumas ações listadas na bolsa de valores espanhola IBEX 35. Os valores de RSI previstos são usados em um sistema de negociação que indica quando comprar ou vender ações.

Liu e Wang [Liu e Wang 2012] propuseram o uso da rede neural de Legendre para prever índices de estoque. Nessa abordagem, os dados históricos têm um impacto diferente na previsão dos valores. Uma função de atendimento e uma função aleatória de volatilidade browniana foram aplicadas para descrever o comportamento da força do tempo nas previsões. Resultados experimentais mostraram que a rede Legendre em combinação com essas funções apresentou precisão superior quando comparada com redes neurais simples de Legendre.

Em Nametala et al. [Nametala et al. 2016] foi proposto um sistema de negociação automática que combina previsores baseados em redes neurais com previsores econômicos como entrada de uma segunda rede neural. Esta segunda rede neural funciona como um comitê de decisão. O resultado do sistema de negociação foi favorável, com 114% de retorno em um ano, mesmo com os previsores variando entre 48 e 56% de acerto nas previsões.

Neste trabalho foi proposto um sistema automático de negociação que utiliza redes neurais para prever a tendência do mercado no dia seguinte utilizando duas formas de treinamento dos previsores: a inclinação da regressão linear (como uma nova forma de prever a tendência do mercado) e o preço de fechamento do dia seguinte, em ambos os casos, treinando as redes periodicamente. Além disso, foi adotado um mecanismo

de *traling stop* não utilizado por nenhum dos trabalhos relacionados supracitados. A tabela 2.1 resume as principais características dos trabalhos relacionados.

Tabela 2.1: Resumo dos Trabalhos Relacionados

Trabalho	Investimento	Variáveis de Entrada	Técnica	Sistema de Negociação	<i>Trailing Stop</i>
[Macedo et al. 2013]	Ações	Técnicas	MLP e Regressão Linear	Sim	Não
[Chiang et al. 2016]	Ações	Técnicas	Rede Neural Recorrente	Sim	Não
[Lin et al. 2011]	Ações	Técnicas	AG e Rede ESN	Sim	Não
[Huang et al. 2005]	Índice	Técnicas	SVM/Redes Neurais de Elman	Sim	Não
[Thenmozhi e Sarath Chand 2016]	Ações	Técnicas	SVM	Sim	Não
[Qiu e Song 2016]	Índice	Técnicas	Redes Neurais/Fuzzy	Não	-
[Ticknor 2013]	Ações	Técnicas	Rede Neural Bayesiana	Não	-
[Martinez et al. 2009]	Ações	Técnica	MLP	Sim	Não
[de Oliveira et al. 2013]	Ações	Técnica/Fundamentalista	Redes Neurais	Não	-
[Dhar et al. 2010]	Índices	Técnicas	MLP	Não	-
[de Oliveira et al. 2011]	Ações	Técnica	MLP	Não	-
[Jasemi et al. 2011]	Ações	Técnicas	Redes Neurais	Não	-
[Kayal 2010]	FOREX	Técnicas	MLP	Não	-
[Chen e Du 2009]	Falência de Empresas	Fundamentalista	Redes Neurais	Não	-
[Vanstone et al. 2012]	Ações	Fundamentalista	MLP	Sim	Não
[Lasfer et al. 2013]	Índice	Técnicas	MLP	Não	-
[Majhi et al. 2009]	FOREX	Técnicas	FLANN e CFLANN	Não	-
[Mahdi et al. 2009]	FOREX	Técnica	SOMLP, FLANN e MLP	Sim	Não
[Ghazali et al. 2009]	FOREX	Técnicas	DRPNN	Não	-
[Shahpazov et al. 2013]	Índices	Técnicas	MLP,RBF,GRNN	Não	-
[Rodríguez-González et al. 2011]	Índices	Técnicas	GFNN	Sim	Não
[Liu e Wang 2012]	Índices	Técnicas	Rede Neural Legendre	Não	-
[Nametala et al. 2016]	Índices e Ações	Técnicas	MLP e Ind. Econométricos	Sim	Não

Capítulo 3

Metodologia

Como visto anteriormente, a utilização de sistemas de *trading* automáticos está cada vez mais comum entre os investidores. Um sistema de *trading* deve ser projetado para que seja possível identificar ou até mesmo se antecipar à tendência do mercado financeiro com a finalidade de obter lucros.

Neste trabalho o sistema construído baseou-se nas previsões de redes neurais para realizar as negociações. As redes neurais foram treinadas para prever a tendência do mercado de duas formas distintas, baseando-se no indicador técnico *Linear Regression Slope* e no fechamento dos preços do dia seguinte. Nos experimentos realizados, foram utilizados dados diários de cotações do fundo de índice BOVA11. Neste capítulo será descrita a construção e o funcionamento do sistema de negociação construído.

O sistema proposto seguiu a arquitetura descrita por Vanstone et al. [Vanstone et al. 2012], por apresentar uma proposta mais completa das partes essenciais do sistema, contendo regras de entrada e saída das negociações bem definidas e os módulos de gerenciamento de riscos e gerenciamento de dinheiro. A seleção das redes neurais não levou em consideração apenas as taxas de erro dos previsores (como na maioria dos trabalhos realizados), mas também o retorno financeiro obtido no período de testes, assim como em Chiang et al. [Chiang et al. 2016]. O uso de *stop loss* e *take profit* é bastante comum nos sistemas de negociação estudados no referencial teórico, mas a adoção de um mecanismo de *trailing stop* não é muito praticada entre os sistemas de negociação automático com redes neurais estudados durante levantamento bibliográfico deste trabalho. A vantagem do uso do *trailing stop* é que, caso a tendência da ordem de negociação se confirme, o valor do *stop loss* é ajustado para que, caso haja uma reversão de tendência, a saída da posição pelo valor de *stop loss* reduza os prejuízos ou até mesmo possa gerar lucro. A utilização do indicador estatístico *Linear Regression Slope* para a previsão de tendências e utilização no sistema de negociação ao invés de um indicador da análise técnica também é um diferencial deste trabalho.

3.1 Ferramentas Utilizadas

Para o desenvolvimento deste trabalho, foi utilizado o Metatrader 5, uma plataforma de desenvolvimento de sistemas automáticos de negociação que utiliza a linguagem MQL 5. Os dados utilizados nos experimentos do trabalho são provenientes de uma conta demo da corretora XP Investimentos, que permite a negociação através de sistemas desenvolvidos no Metatrader 5 ¹. O Metatrader 5, além de obter os dados de cotações de contas de uma corretora, possui diversos indicadores técnicos já implementados e a possibilidade que o usuário implemente os seus próprios indicadores.

A Scikit Learn [Pedregosa et al. 2011] é uma biblioteca de aprendizado de máquina de código aberto para a linguagem de programação Python. Esta biblioteca inclui vários algoritmos de classificação, regressão e agrupamento, incluindo SVMs, *Random Forests* e Redes Neurais Artificiais (utilizadas neste trabalho). A Scikit Learn oferece toda a estrutura para implementação das redes e funções associadas ao treinamento/validação e utilização das redes neurais para previsão. Para isso, são utilizadas funções da própria biblioteca, e passados os parâmetros de configuração da rede, algoritmo utilizado no treinamento, quantidades de épocas, dentre outras informações.

Um banco de dados MySQL foi utilizado para armazenar os dados de treinamento das redes neurais, que posteriormente são utilizados na seleção.

Para os experimentos foram utilizados dois computadores com 8 GB de memória RAM, processador Intel Core i5 3,40 GHz.

3.2 Visão Geral

O sistema de *trading* proposto neste trabalho tem como objetivo operar no mercado de renda variável a fim de obter lucros de forma consistente, implementando mecanismos para diminuir os riscos no investimento. As operações de compra e venda são realizadas, utilizando como base, dados históricos de cotações diárias da BOVA11, que simulam o comportamento do índice BOVESPA. O sistema de negociação sempre está posicionado no decorrer da simulação, comprado ou vendido, e apenas sai ou entra em uma posição caso obedeça às regras estabelecidas, que serão descritas mais adiante.

O sistema foi executado utilizando duas estratégias diferentes para previsão: Na previsão do indicador *Linear Regression Slope* do dia seguinte e no preço de fechamento do dia seguinte.

A figura 3.1 mostra a visão geral do sistema. Os detalhes de cada etapa serão descritos a seguir.

¹<https://www.metatrader5.com>

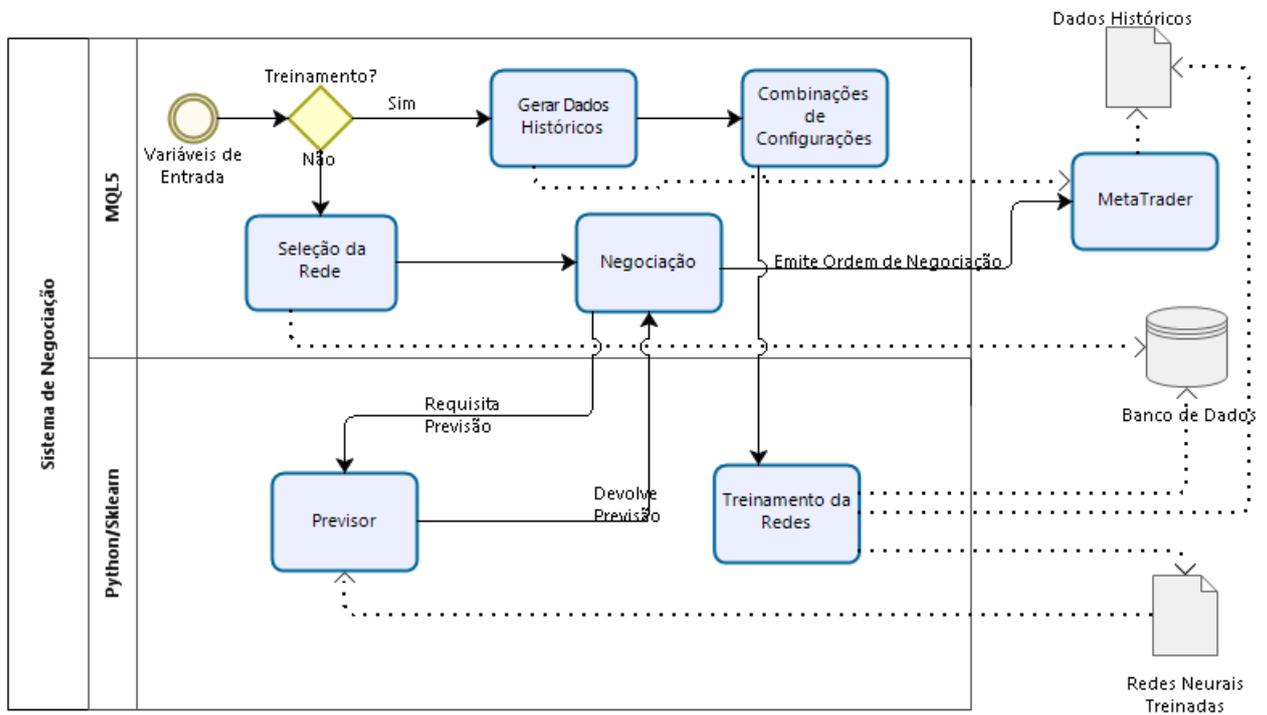


Figura 3.1: Visão Geral do Sistema de Negociação

O sistema de negociação desenvolvido em MQL5 é quem irá ditar os passos a serem seguidos.

Inicialmente, o sistema precisa ser executado em modo treinamento. Nesse modo, o sistema não irá negociar. São obtidos dados históricos através da plataforma Metatrader 5 e os dados do período de treinamento são armazenados em arquivos formato CSV. Em seguida, o sistema gera combinações de atributos de entradas para serem utilizados como entradas da rede. Cada combinação será associada ao número de neurônios na camada escondida, que pode variar na quantidade a depender do previsor que estiver sendo treinado.

Cada combinação de atributos com número de neurônios gerará uma chamada ao módulo de treinamento implementado em Python com a API Scikit Learn. O módulo de treinamento utilizará o arquivo gerado com os dados históricos, a informação da combinação de número de neurônios na camada escondida e os atributos que serão utilizados.

O módulo de treinamento é o responsável pela normalização dos dados e por iniciar o treinamento das redes. Uma vez treinadas, as redes são armazenadas em arquivo e os dados e métricas do treinamento são armazenados no banco de dados.

Com o treinamento das redes concluído, o sistema selecionará, em duas etapas,

as redes que serão utilizadas na negociação através dos dados de desempenho do treinamento das redes registrados no banco de dados. A maneira que as redes são selecionadas será descrita mais adiante. Após a seleção da rede, o sistema de negociação utiliza o previsor selecionado para prever o comportamento futuro do mercado no período de negociação.

O sistema de negociação informa os dados atuais das cotações e indicadores técnicos para o previsor e o previsor informa a tendência do mercado para o dia seguinte. Com base nessa previsão, o sistema dispara a ordem de negociação: Caso a tendência seja de alta para o próximo dia o sistema emite uma ordem de compra; Caso a previsão seja de queda, o sistema emitirá uma ordem de venda. As ordens podem ser de entrada, caso o sistema não esteja posicionado ou de saída, caso já esteja em uma posição inversa ao apontado pelo previsor.

Como diferencial, neste trabalho foram incluídos o uso do LRS no treinamento das redes na tentativa de prever a tendência do mercado. Além disso, foi adotado o uso de um mecanismo de *Trailing Stop*, não utilizado nos sistemas automáticos de negociação dos trabalhos estudados na revisão bibliográfica.

3.3 Treinamentos Periódicos

O mercado financeiro é um ambiente instável e pode mudar os seus padrões com o passar do tempo. Com a mudança de padrões, muitas estratégias de investimentos aplicadas pelos investidores ou até mesmo sistemas automáticos de negociação podem ficar ultrapassadas no decorrer do tempo por não acompanharem essas mudanças de comportamento. Para lidar com esse problema, no sistema desenvolvido neste trabalho, periodicamente é feito o treinamento de redes neurais e uma nova rede é selecionada para negociar como uma forma do sistema se adaptar às condições mais recentes do mercado.

A figura 3.2 ilustra a separação dos períodos de treinamento/validação, teste e de negociação e como periodicamente uma nova é treinada.



Figura 3.2: Treinamentos Periódicos - Divisão do tempo

Para cada conjunto de períodos, é feito o processo de treinamento e seleção das redes descrito anteriormente: as redes são treinadas com os dados do período de

treinamento, são avaliadas no período de teste, e a rede selecionada opera no sistema até o final do período de negociação, quando o processo recomeçará e uma nova rede será selecionada.

Esse método de deslocamento de períodos é baseado no *Walk-Forward*, proposto por Pardo [Pardo 1992, Pardo 2015] e utilizado por trabalhos como Kaastra e Boyd [Kaastra e Boyd 1996], Cao e Tay [Cao e Tay 2003] e Zbikowski [Zbikowski 2015] em séries temporais financeiras.

Períodos

Os períodos utilizados neste trabalho foram entre 01/01/2011 a 30/06/2018, inclusos os períodos de treinamento, validação, teste e negociação. Conforme mencionado anteriormente, cada previsor atua no sistema de negociação por um período pré-determinado, até que outro previsor seja treinado com dados mais recentes e utilizado pelo sistema de negociação.

Os períodos de treinamento são de 3 anos (sendo 10% destes dados utilizados para validação *holdout*) e são utilizados seis meses para testes do previsor e seis meses para o sistema de negociação utilizar o melhor previsor selecionado no período de testes. A cada treino e seleção de previsores o período é deslocado em seis meses para a frente.

A tabela 3.1 mostra como foram divididos os períodos baseados nos treinamentos periódicos do sistema.

3.3.1 Variáveis de Entrada

Como variáveis de entrada do sistema, foram utilizados indicadores da análise técnica e informações das cotações, como volume de negociações e preços de abertura e fechamento como entrada do sistema. Esses dados servem para realizar o treinamento das redes neurais. A rede com melhor desempenho, segundo os critérios de seleção do sistema de negociação, é escolhida para a etapa de negociação.

As redes neurais foram treinadas utilizando os dados mostrados na tabela 3.2, para o previsor baseado no preço de fechamento do dia seguinte e na tabela 3.3 para o previsor baseado no indicador *Linear Regression Slope*. Foram excluídas as entradas referentes ao volume de preços e ATR nos previsores baseados no preço de fechamento do dia seguinte por não se mostrarem relevantes no treinamento destes previsores nos treinamentos realizados. Os índices dos atributos serão utilizados para determinar quais variáveis serviram de entrada para uma rede neural.

Assim, como exemplo, se uma rede neural treinada através do preço de fechamento do dia seguinte é representada com os atributos 1,2,4,5,6, significa que foram utilizados os atributos Preço de Fechamento, Preço de Abertura, Preço Máximo, MACD e

Tabela 3.1: Treinamentos Periódicos

Período	Treinamento/Validação	Teste	Negociação
Período 1	01/01/2011 a 31/12/2013	01/01/2014 a 30/06/2014	01/07/2014 a 31/12/2014
Período 2	01/07/2011 a 30/06/2014	01/07/2014 a 31/12/2014	01/01/2015 a 30/06/2015
Período 3	01/01/2012 a 31/12/2014	01/01/2015 a 30/06/2015	01/07/2015 a 31/12/2015
Período 4	01/07/2012 a 30/06/2015	01/07/2015 a 31/12/2015	01/01/2016 a 30/06/2016
Período 5	01/01/2013 a 31/12/2015	01/01/2016 a 30/06/2016	01/07/2016 a 31/12/2016
Período 6	01/07/2013 a 30/06/2016	01/07/2016 a 31/12/2016	01/01/2017 a 30/06/2017
Período 7	01/01/2014 a 31/12/2016	01/01/2017 a 30/06/2017	01/07/2017 a 31/12/2017
Período 8	01/07/2014 a 30/06/2017	01/07/2017 a 31/12/2017	01/01/2018 a 30/06/2018

Tabela 3.2: Variáveis de Entrada - Previsor por Preço de Fechamento do dia seguinte

Atributo	Índice
Preço de Fechamento	1
Preço de Abertura	2
Preço Mínimo	3
Preço Máximo	4
MACD	5
RSI	6
LLV	7
HHV	8

Índice de Força Relativa (RSI) como entrada da rede neural. A variação na entrada dependerá da seleção da rede neural a ser utilizada pelo sistema em cada treinamento periódico.

As variáveis de entrada das redes neurais foram escolhidas por frequentemente serem utilizadas em sistemas de negociações e na revisão de literatura realizada, como em Nametala et al. que utiliza os preços máximo e mínimo, de abertura e fechamento e o volume negociado, e indicadores como RSI, MACD (utilizados em [Dunis et al. 2013]) e ainda foram incluídos os indicadores HHV, LLV e ATR.

Normalização dos dados

As entradas da rede neural apresentam diferentes naturezas e grandezas, por isso, é necessário que os valores sejam normalizados, evitando assim que os neurônios da camada escondida sejam influenciados por essa diversidade de grandezas e os ajustes dos pesos possam acontecer de maneira correta.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

A equação 3.1 foi a utilizada para normalizar os valores de entrada da rede, onde x_{norm} é o valor normalizado, x é o valor original e x_{max} e x_{min} são o maior valor e o

Tabela 3.3: Variáveis de Entrada - Previsor por LSR

Atributo	Índice
Preço de fechamento	1
Preço de Abertura	2
Preço Mínimo	3
Preço Máximo	4
Volume	5
MACD	6
RSI	7
ATR	8
LLV	9
HHV	10

menor valor do conjunto de dados, respectivamente.

3.3.2 Treinamento das Redes Neurais

Neste trabalho foram utilizadas redes neurais multicamadas com propagação para frente com 3 camadas, sendo uma camada de entrada, uma camada escondida (com função de ativação sigmóide) e uma camada de saída. Durante os experimentos, foram feitos testes com redes com duas camadas escondidas, mas os resultados não se mostraram melhores que as redes com apenas uma camada.

O sistema utilizou duas formas de prever o comportamento futuro do mercado. O primeiro previsor foi treinado para que, de acordo com as variáveis de entrada, fosse previsto o comportamento do próximo dia, do indicador *Linear Regression Slope* (LRS). O indicador LRS refere-se à inclinação da regressão linear dos preços em um determinado período e assemelha-se a um oscilador, retornando valores que flutuam acima e abaixo de zero, de acordo com o coeficiente angular da regressão linear. Foi utilizada a regressão linear referente ao período de 10 dias de preços de cotações, pois, analisando os gráficos e realizando testes das redes neurais, foi observado que em um período maior, a regressão apresentava um certo atraso em sinalizar a mudança de tendência e, em períodos menores as tendências eram muito afetadas por pequenas variações e muitas vezes não capturavam a tendência geral dos dias.

Basicamente, quando o seu valor está menor que zero (inclinação descendente da reta), a tendência do mercado é de baixa. Quando está acima de zero (inclinação ascendente da reta), a tendência do mercado é de alta. Durante o treinamento das redes foi passada a tendência do mercado para o dia seguinte, baseando-se na inclinação do indicador.

A outra forma de treinamento, também para prever a tendência do próximo dia do índice BOVA11, baseou-se no preço de fechamento do dia seguinte. Se o preço de fechamento do dia seguinte for maior que o preço de fechamento do dia atual, a

tendência é de alta, caso contrário, a tendência é de queda. Assim, independente do previsor utilizado, a saída das redes neurais possuem duas classes, tendência de alta ou de queda.

Foram utilizados os dados de três anos para o treinamento e validação (10% dos dados de treinamento). As combinações de variáveis de entrada foram realizadas de modo que cada rede possuísse pelos menos 6 variáveis de entrada e no máximo todas. Na literatura, não há consenso sobre o número ideal de neurônios na camada escondida. Azoff [Azoff 1994] sugere que uma rede com uma camada oculta e $2N + 1$ neurônios ocultos são suficientes para N entradas. Em Chiang et al. [Chiang et al. 2016] foram utilizados $2N-1$ neurônios (para uma rede com N variáveis de entrada). Gately [Gately 1995] sugere que o número de neurônios na camada escondida deve ser igual ao soma dos tamanhos das camadas de entrada e saída da rede. Devido a isto, foram utilizadas as quantidades 05, 10, 15 e 20 neurônios nos experimentos no previsor com regressão linear. No experimento com o previsor baseado no preço de fechamento do dia seguinte, também foram treinadas redes com 25 e 30 neurônios na camada escondida.

A quantidade de épocas de treinamento foi fixada em 3000 épocas para o previsor baseado no indicador de regressão linear e 50000 épocas no previsor baseado no preço de fechamento do dia seguinte, sendo que o treinamento é encerrado quando atingir o número total de épocas ou quando o erro de validação não estiver diminuindo por pelo menos duas épocas consecutivas.

A ideia de treinar por 50000 épocas no segundo previsor é justamente pela maior dificuldade de realizar a previsão a partir dos preços de fechamento e que a saída do treinamento ocorra quando o erro de validação pare de diminuir. O algoritmo de treinamento utilizado foi o *backpropagation*.

3.3.3 Seleção das Redes Neurais

Após o treinamento, o sistema verifica o comportamento das redes em um período de preços desconhecido (período de testes), onde é possível avaliar o desempenho da rede quanto à acurácia e a raiz do erro médio quadrático cuja fórmula de cálculo é mostrada na equação 3.2, sendo N é o número de dias da série temporal analisada, $previsto_i$ é o valor previsto para a série no dia i e $real_i$ é o valor real da série também no dia i . Essa métrica, também chamada RMSE (Root Mean Squared Error), assemelha-se ao desvio padrão, sendo que, quanto mais próximo de zero for o erro, melhores são os resultados obtidos.

$$RMSE = \sqrt{\frac{1}{N} \sum (previsto_i - real_i)^2} \quad (3.2)$$

As redes com menores RMSE são selecionadas e passam por uma nova seleção. Dessa vez, as redes são utilizadas para negociação no período de testes para definir

as redes com melhores retornos no sistema de negociação. A intenção é verificar se o desempenho da rede na fase de testes está gerando retorno financeiro. A rede com melhor retorno é utilizada pelo sistema no período de negociação.

3.3.4 Negociação

A rede escolhida na etapa de seleção é utilizada como previsor no sistema de negociação. Para prever a tendência do dia seguinte, a rede recebe os dados do dia atual e emite uma ordem de compra ou de venda, a depender da previsão realizada para o dia seguinte (alta ou queda, respectivamente).

Neste trabalho, a quantidade de lotes a ser negociada adota a estratégia *Percent Volatility* [Tharp 1998], que utiliza o indicador ATR na sua fórmula. O indicador ATR (*Average True Range*) mede a volatilidade dos preços de determinado ativo em um determinado período.

$$Qtdlotes = (volatilidade \cdot saldoConta) / ATR \quad (3.3)$$

A fórmula 3.3 foi utilizada neste trabalho para definir a quantidade de lotes de ações a ser negociada em cada ordem. O valor da volatilidade, que é a flutuação média diária para esta compra, é escolhido pelo investidor, multiplicado pelo saldo da conta, e dividido pelo valor do indicador ATR para definir a quantidade de lotes a ser negociada.

Definida a ordem e a quantidade de dinheiro a ser investida, o sistema realiza a negociação.

Todas as ordens de negociação realizadas pelo sistema possuem os valores de *stop loss* e *take profit*. Esses valores garantem a saída da posição atual no mercado para reduzir perdas ou resgatar os lucros já obtidos, respectivamente. Os valores de *stop loss* e *take profit* representam 2% do valor do preço na negociação do ativo para mais ou para menos.

Foi implementado no sistema um mecanismo de *Trailing Stop* que ajusta o valor de *stop loss* de acordo com a tendência do mercado. Para isso foi utilizado o indicador *Parabolic SAR*. O *Parabolic SAR* acompanha a tendência de preços da seguinte forma:

- Quando o preço do indicador está abaixo dos preços, significa que se trata de uma tendência de alta;
- Quando está acima dos preços, é uma tendência de baixa.

Dessa forma, o *Parabolic SAR* mostra-se um bom indicador para se configurar o *stop loss*, pois ele sempre está a uma margem segura da tendência e uma pequena variação de preços não ativará o *stop loss*. O *Trailing Stop* monitora a ordem de

negociação aberta e atualiza o valor do *stop loss* com o preço do parabolic SAR sempre no sentido da tendência. Se o indicador confirmar a tendência, o valor do *stop loss* é ajustado para que as perdas sejam reduzidas. A figura 3.3 mostra como é realizado o ajuste do stop loss com a variação dos preços dos ativos.



Figura 3.3: *Trailing Stop* com indicador *Parabolic SAR*

Fonte: Adaptado de [Online Trading Concepts 2007]

No sistema proposto há três formas de saída de uma negociação: Se os preços atingirem o valor de *stop loss*, se os preços atingirem o valor de *take profit* ou se o previsor acusar para o sistema de negociação uma mudança na tendência do mercado para o dia seguinte. Já as entradas no mercado são sempre definidas pela previsão de tendência do previsor.

Neste trabalho foi adotado o desconto da corretagem no valor de R\$ 10,00 por operação.

Para comparar os resultados do sistema de negociação proposto com a estratégia *buy and hold* também foi desenvolvido no Metatrader um robô que emite uma ordem de compra com o maior número de lotes que seja possível comprar com o capital inicial no início da negociação e só sai da posição no final do período de negociação. Os dados da estratégia *buy and hold* utilizados neste trabalho foram produzidos por este robô.

Capítulo 4

Discussão dos Resultados

A escolha da rede neural para o período de negociação do sistema de *trading* foi realizada em duas etapas para cada uma dos treinamentos periódicos realizados. Como descrito no capítulo 3, na primeira etapa são selecionadas redes neurais com base na menor RMSE do período de testes e que possuam acurácia acima de um determinado valor, escolhido a depender do tipo de treinamento, como será explicado mais adiante. Os previsores baseados no indicador LRS tiveram uma acurácia maior no geral comparado com os previsores baseados nos preços de fechamento. Os melhores previsores baseados no preço do fechamento do dia seguinte tiveram acurácia variando de 60 a 66%, já os previsores baseados no LRS tiveram acurácia acima de 70% no período de testes. Devido a isto, o ponto de corte na seleção do previsor será diferente, adotando 60% para os previsores baseados em preço de fechamento e 70% para os previsores baseados no LRS.

Na segunda etapa, as redes pré-selecionadas são aplicadas no sistema de negociação para verificar os retornos alcançados no período de testes.

O capital inicial na simulação foi de R\$ 100.000,00. Os lucros/prejuízos obtidos são repassados para o próximo período na negociação.

Serão detalhados a seguir os experimentos realizados com o sistema de negociação proposto.

4.1 Experimentos

Foram utilizados dados diários de cotações do fundo de índice BOVA11, provenientes de uma conta demo da corretora XP Investimentos ¹ através do Metatrader 5 (plataforma de desenvolvimento de sistemas de negociação para bolsa de valores). Com os dados de cotações, o Metatrader fornece o cálculo de diversos indicadores utilizados como entrada para as redes neurais utilizadas neste trabalho.

¹<https://www.xpi.com.br/>

Os dados foram extraídos do período de 01/01/2011 a 30/06/2018, inclusos os dados utilizados no treinamento, validação, testes e negociação. O período de negociação total, juntando todos os treinamentos periódicos foi de 01/07/2014 a 30/06/2018, totalizando quatro anos de operação. Esta janela de tempo foi escolhida por considerar os dados mais recentes do mercado.

Para cada seis meses de negociação, foi escolhida uma rede neural treinada (e validada) com os dados dos últimos três anos, para que o sistema se adapte aos dados mais recentes do índice. Foram utilizados 10% dos dados de treinamento para a validação. Para o treinamento da rede, foram utilizadas duas estratégias: o indicador técnico *Linear Regression Slope* para prever a tendência do mercado e a previsão de tendência baseada no fechamento do preço do dia seguinte. A quantidade de lotes a ser comprada em cada negociação seguiu a estratégia *Percent Volatility*, descrita anteriormente, adotando a volatilidade de 1% (valor considerado conservador). O capital inicial de investimento é de R\$ 100.000,00 e os ganhos obtidos poderão ser aplicados no decorrer dos testes. Foi aplicada a taxa de corretagem no valor de R\$ 10,00 por operação nos experimentos.

4.1.1 Seleção das Redes Neurais

As redes foram selecionadas segundo o critério definido de utilizar as redes com menores RMSE no período de testes e que atinjam um nível de acurácia pré-definido (60% para o previsor baseado em fechamento de preços e 70% para os previsores baseados no indicador LRS). As redes que atingiram esses critérios foram utilizadas pelo sistema para negociação no período de testes, aplicando a mesma metodologia aplicada no sistema em modo de negociação, com o gerenciamento de dinheiro e regras de *stop loss* e *take profit*.

Durante o processo de seleção foi perceptível a diferença de resultado entre a quantidade de redes que atingiam as restrições impostas nas duas formas de treinar. A quantidade de redes selecionadas (que atingiam 70% de acurácia) nas redes que utilizavam o indicador LRS foi muito maior que a quantidade de redes que atingiam os critérios de seleção das redes treinadas com o preço de fechamento, mesmo com o ponto de corte da acurácia menor (60%). Resultados iguais ou inferiores a 50% não são satisfatórios, pois seriam como uma tentativa aleatória de prever um problema com apenas duas classes (tendência de alta ou de baixa).

Trabalhos como os de Giacomel [Giacomel 2016] e Gambogi [Gambogi 2013] obtiveram como resultado de alguns previsores acurácias na faixa 60% ou um pouco menos e mesmo assim com lucro nas negociações. Esse fato pode ocorrer porque algumas redes com maior taxa de acerto podem acertar mais as previsões com a tendência já estabelecida (no meio e fim da tendência), enquanto outras redes, mesmo com uma acurácia menor, podem prever melhor as reversões de tendência, gerando um lucro maior. Além disso, alguns erros podem ser tolerados pelo previsor, pois uma escolha equivocada de investimento pode ser revertida através dos mecanismos de

Tabela 4.1: Redes Seleccionadas - Preço de Fechamento

Período	Atributos	<i>H. layer</i>	RMSE	Acurácia	Capital
Período 1	1,2,3,4,5,6,7	20	0,6324	60%	R\$ 105.131,00
Período 2	1,2,3,5,6,7,8	15	0,6311	60,16%	R\$ 112.718,00
Período 3	1,2,3,5,6,7,8	15	0,6220	61,29%	R\$ 101.927,00
Período 4	1,2,4,5,6,7,8	10	0,6363	61,74%	R\$ 102.297,00
Período 5	1,2,3,5,7,8	10	0,6324	60%	R\$ 98.530,00
Período 6	1,4,5,6,7,8	20	0,6048	63,41%	R\$ 108.768,00
Período 7	1,2,4,5,7,8	20	0,6123	62,50%	R\$ 104.502,00
Período 8	1,2,3,4,5,7	10	0,6054	63,33%	R\$ 104.637,00

gerenciamento de riscos (no caso deste trabalho, *stop loss*) do sistema de negociação, evitando grandes perdas e valorizando os acertos com a continuidade no investimento quando uma tendência é prevista corretamente.

Também foi observado que nem sempre a rede com maior acurácia trouxe maiores retornos financeiros. A acurácia, apesar de ser uma medida importante, não demonstra a qualidade do previsor, principalmente em casos que a base de dados apresentada está com desbalanceamento, em que uma classe é muito mais frequente que a outra. Para estas situações, a análise da matriz de confusão e da precisão e *recall*, tornam-se mais importantes. Com a amostra desbalanceada, o previsor pode tender a gerar todos os resultados como sendo da maior classe, aumentando a acurácia, mas sendo incapaz de prever situações em que a classe em menor número ocorra.

Nos experimentos deste trabalho as amostras não foram balanceadas para treinamento. Os períodos, no geral, apresentaram amostras bem equilibradas das duas classes. As redes neurais com menor RMSE foram seleccionadas e utilizadas no sistema de negociação para serem escolhidas pelo retorno financeiro realizado no período de testes.

As tabelas 4.1 e 4.2 mostram as redes seleccionadas em cada período, com os seus atributos, número de neurônios na camada escondida, as suas acurácias, RMSE e retorno financeiro no período de teste (critério final de seleção).

Pode-se observar, que dentre as redes seleccionadas, apenas uma em cada previsor teve retorno financeiro negativo dentre as redes que obtiveram melhor desempenho. As acurácias do previsor baseado no LRS são visivelmente superiores comparando-as com os resultados do previsor baseado no preço de fechamento. Devido a este melhor resultado, mais redes LRS foram pré-seleccionadas (com acurácia superior a 70%), para negociação no período de testes (seleção final), devido a isto, a seleção dessas redes demandaram um tempo maior.

Entre as redes seleccionadas foram mais comuns redes com 10, 15 e 20 neurônios na camada escondida. Nenhuma rede com mais de 20 neurônios foi escolhida para o

Tabela 4.2: Redes Selecionadas - LRS

Período	Atributos	<i>H. layer</i>	RMSE	Acurácia	Saldo
Período 1	1,2,4,5,6,8,9,10	15	0,5332	71,55%	R\$ 115.434,00
Período 2	2,3,5,6,7,8,9,10	20	0,5039	74,59%	R\$ 106.546,00
Período 3	1,3,4,5,6,8,9,10	20	0,4528	79,48%	R\$ 103.033,00
Período 4	1,2,3,4,5,6,8,9	10	0,4098	83,19%	R\$100.792,00
Período 5	1,3,4,5,6,7,9	5	0,4693	83,19%	R\$ 98.855,00
Período 6	1,3,4,5,6,7,9	10	0,4453	80,17%	R\$ 101.114,00
Período 7	1,3,4,5,6,7,8,9	15	0,4895	76,03%	R\$ 103.909,00
Período 8	3,4,5,6,7,8,9	15	0,4978	75,20%	R\$ 112.049,00

Tabela 4.3: Evolução do Capital por Período

-	<i>Buy and Hold</i>	Regressão Linear	Preço Fechamento
Período 1	R\$ 93.046,00	R\$ 109.125,00	R\$ 103.870,00
Período 2	R\$ 99.468,00	R\$ 108.422,00	R\$ 110.070,00
Período 3	R\$ 81.418,00	R\$ 108,422,00	R\$ 121.910,00
Período 4	R\$ 97.587,00	R\$ 90.076,00	R\$ 129.468,00
Período 5	R\$ 113.072,00	R\$ 86.226,00	R\$ 143.008,00
Período 6	R\$ 117.043,00	R\$ 82.971,00	R\$ 155.549,00
Período 7	R\$ 140.831,00	R\$ 76.211,00	R\$ 148.147,00
Período 8	R\$ 134.485,00	R\$ 74.506,00	R\$ 147.455,00

previsor baseado no preço de fechamento (apenas este previsor tinha essa possibilidade).

4.1.2 Resultados das Negociações

Após a seleção das redes neurais, o sistema de negociação as utilizou como previsor de tendência no período de negociação. A tabela 4.3 e a figura 4.1 mostram o capital acumulado do sistema de negociação utilizando os previsores baseados no LRS e no preço de fechamento do dia seguinte comparado com a estratégia *buy and hold* em cada um dos períodos.

Pode-se perceber que no primeiro período, o previsor baseado no LRS obtém o melhor desempenho. Porém, nos períodos posteriores, o previsor baseado no preço de fechamento se mostra melhor e apresenta uma maior consistência nos resultados, apesar do prejuízo e pequeno ganho nos dois últimos períodos.

A estratégia *buy and hold* possui uma maior oscilação, tanto para alcançar prejuízos, quanto para recuperar-se pois todo o capital está investido. Devido a isso, a tendência é que o máximo *drawdown* na estratégia *buy and hold* seja maior. As outras estratégias aplicam apenas parte do capital disponível (aplicando o *Percent Volatility*).

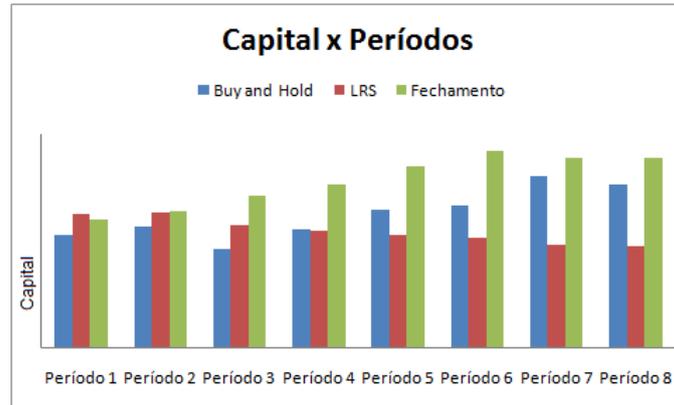


Figura 4.1: Capital x Períodos

Tabela 4.4: Resumo do Desempenho das Estratégias de Negociação

-	Preço de Fechamento	LRS	Buy and Hold
Capital Inicial	R\$ 100.000,00	R\$ 100.000,00	R\$ 100.000,00
Maior Capital	R\$ 161.555,00	R\$ 112.739,00	R\$ 160.765,00
Menor Capital	R\$ 93.289,00	R\$ 74.064,00	R\$ 69.234,00
Lucro	R\$ 47.455,00	R\$ -25.494,00	R\$ 34.485,00
Capital Final	R\$ 147.455,00	R\$ 74.506,00	R\$ 134.485,00
Máximo de lotes	3100	1400	1900
Número de negociações	415	461	1
Negociações vencedoras	229 (55,18%)	231 (50,10%)	1 (100%)
Negociações perdedoras	186 (44,82%)	230 (49,90%)	0 (0%)
Max. drawdown	16,37%	34,30%	40,38%
CAR	10,21%	-7,09%	7,65%
CAR/MDD	0,6237	-0,4331	0,1894

Previsor por Preço de Fechamento do Dia Seguinte

A tabela 4.4 mostra o desempenho geral dos previsores. Analisando o previsor baseado no preço de fechamento do dia seguinte, o menor capital durante as negociações foi de R\$ 93.289,00. O capital final obtido foi de R\$ 147.455,00, tendo chegado a acumular durante o período de negociações o capital de R\$ 167.971,00. Durante o período total foram realizadas 415 negociações, sendo que 229 foram vencedoras (geraram lucro) e 186 perdedoras (geraram prejuízo).

As tabelas 4.5 e 4.6 trazem dados anuais consolidados. É possível perceber o acúmulo de capital crescente no decorrer dos anos, e uma desaceleração nos lucros nas negociações nos períodos mais recentes. O maior *drawdown* aconteceu em 2017 (14,64%), correspondendo ao pior desempenho do sistema. O segundo período de 2017 (período 7) foi o período em que o sistema de negociação, usando este previsor, obteve o maior prejuízo. No ano de 2018, houve um pequeno prejuízo de R\$ 692,00.

Tabela 4.5: Informações Anuais I- Previsor por Preço de Fechamento

ANO	Retorno(R\$)	Capital Final(R\$)	Retorno(%)	Drawdown(%)
2018	-692,00	147.455,00	-0,46	8,80
2017	5.139,00	148.147,00	3,59	14,64
2016	21.098,00	143.008,00	17,31	4,53
2015	18.040,00	121.910,00	17,37	5,64
2014	3.870,00	103.870,00	3,87	6,71
Total	47.455,00	147.455,00	47,45	16,37

Tabela 4.6: Informações Anuais II- Previsor por Preço de Fechamento

Ano	Trades	Trades Venc. (%)	Profit Factor
2018	41	53,66	0,98
2017	80	48,75	1,09
2016	124	57,26	1,42
2015	103	55,34	1,44
2014	67	59,70	1,23
Total	415	229 (55,18%)	1,237

A tabela 4.6 traz mais informações do desempenho anual do sistema de negociações utilizando os previsores treinados com preço de fechamento. A tabela mostra o número de negociações por ano (lembrando que em 2014 e 2018 os períodos negociados foram de apenas seis meses) e a porcentagem das negociações vencedoras. Apenas em 2017, ano em que o sistema obteve o seu pior desempenho, a porcentagem de negociações vencedoras ficou abaixo da taxa de perdedoras.

A tabela também traz os índices de *profit factor*. O fator de lucro pode ser simplesmente definido como lucros brutos divididos por perdas brutas. Os anos de 2015 e 2016 tiveram melhor *profit factor*.

Previsor por *LRS*

A tabela 4.7 mostra os retornos anuais do sistema negociando com os previsores treinados para prever a tendência do mercado com o indicador *LRS*.

Operando com estes previsores o sistema só conseguiu obter lucro no ano de 2014, principalmente no primeiro período de seis meses de negociação, em que superou todas as outras estratégias (ver figura 4.1 e tabela 4.3). A tabela 4.8 mostra o *profit factor* sempre menor que 1 (com exceção de 2014), sinalizando que os prejuízos superaram os lucros. Analisando o número de *trades* vencedores, no ano de 2018, 78,79% das negociações foram vitoriosas, ou seja, geraram algum tipo de lucro, mas mesmo assim houve uma queda no capital de R\$ 1.705,00 nesse mesmo período. É

Tabela 4.7: Informações Anuais I- Previsor por LRS

Ano	Retorno (R\$)	Saldo Final (R\$)	Retorno(%)	Drawdown(%)
2018	R\$ -1.705,00	\$74.506,00	-2,23	10,76
2017	R\$ -10.015,00	\$76.211,00	-11,61	12,06
2016	R\$ -5.331,00	\$86.226,00	-5,82	7,54
2015	R\$ -17.568,00	\$ 91.557,00	-16,10	18,40
2014	R\$ 9.125,00	\$ 109.125,00	9,125	5,179
Total	R\$-25.494,00	\$74.506,00	-25,49	34,30

Tabela 4.8: Informações Anuais II - Previsor por LRS

Ano	Trades	Trades Venc. (%)	Profit Factor
2018	33	78,79	0,8770
2017	109	44,04	0,7188
2016	65	49,23	0,7389
2015	187	47,06	0,7717
2014	67	55,22	1,541
Total	461	231 (50,10%)	0,8443

provável que o previsor tenha oscilado entre as tendências, gerando pequenos lucros nas operações vencedoras.

Apesar do bom começo, o desempenho final do sistema de negociação baseado nas previsões do LRS não atingiu as expectativas, gerando repetidos prejuízos no decorrer dos períodos testados. A tabela 4.4 mostra o desempenho geral nos períodos de negociação, com o capital final de R\$ 74.506,00 e *drawdown* máximo de 34,30% (considerado alto).

Buy and Hold

A tabela 4.4 detalha o desempenho da estratégia *buy and hold*. O lucro obtido no final dos quatro anos de negociação foi de R\$ 34.485,00 de lucro. Como essa estratégia opera com todo o capital investido, há um maior risco de *drawdown*, que chegou a atingir 40,38% de rebaixamento do capital, representando um risco muito alto para o investidor. Por outro lado, com todo o dinheiro investido, em caso de uma alta no mercado, o poder de recuperação torna-se maior. O *buy and hold* chegou a atingir o capital de R\$ 160.765,00, mas voltou a cair chegando ao valor final de capital de 134.485,00.

A figura 4.2 mostra a variação do capital de cada estratégia no decorrer do período de negociação.

A tabela 4.4 mostra os dados gerais das 3 estratégias utilizadas. A métrica CAR/MDD (relação do retorno anual composto pelo máximo drawdown) é uma

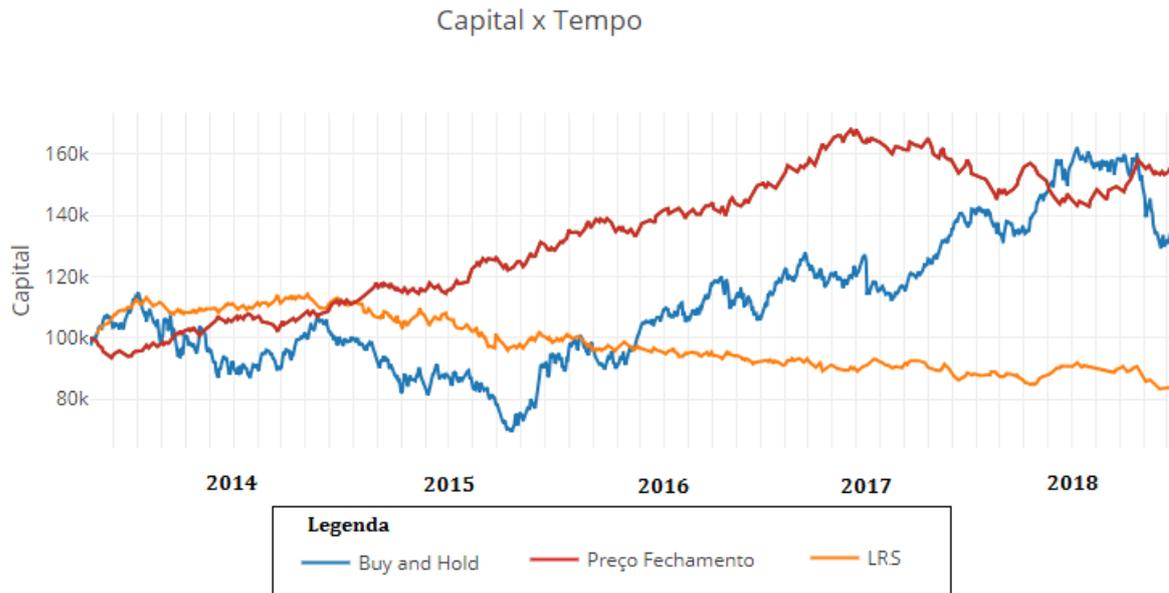


Figura 4.2: Capital x Tempo - Estratégias

métrica de qualidade do sistema. Quanto maior a taxa, melhor o sistema é avaliado. A negociação com previsor baseado no fechamento de preços do dia seguinte obteve a melhor taxa CAR/MDD (0,6237), demonstrando uma melhor relação retorno/risco que as outras estratégias.

4.1.3 Desempenho dos Previsores

As tabelas 4.9 e 4.10 mostram as taxas de acerto dos previsores no período de negociação. A taxa de acerto total do previsor baseado no fechamento de preços foi de 52,65% no período de negociação. O previsor baseador no LRS alcançou 62,80%.

O trabalho de Nametala et al. [Nametala et al. 2016] obteve resultados parecidos com relação à acurácia do previsor e o sistema, no geral, foi lucrativo. A tabela 4.11 mostra as acurácias e o retorno financeiro obtido por cada previsor do trabalho [Nametala et al. 2016] durante o período de novembro de 2012 a novembro de 2013 comparados com os resultados obtidos na melhor estratégia adotada neste trabalho (previsor por preços de fechamento do dia seguinte). Os períodos não são compatíveis para comparação dos resultados com este trabalho, mas reforça a ideia de que os previsores, mesmo com acurácia um pouco maiores que 50%, podem gerar bons resultados.

Tabela 4.9: Acurácia no Período de Negociação - Preço de Fechamento

-	Acurácia	Acertos/Total
Período 1	48,38%	58/120
Período 2	54,62%	65/119
Período 3	56,19%	68/121
Período 4	50,83%	61/120
Período 5	51,21%	63/123
Período 6	56,67%	68/120
Período 7	49,16%	59/120
Período 8	54,16%	65/120
Total	52,65%	507/963

Tabela 4.10: Acurácia no Período de Negociação - LRS

-	Acurácia	Acertos/Total
Período 1	67,5	81/120
Período 2	62,18%	74/119
Período 3	73,94%	89/121
Período 4	65,83%	79/120
Período 5	68,29%	84/123
Período 6	46,66%	56/120
Período 7	68,33%	82/120
Período 8	50%	60/120
Total	62,80%	605/963

Tabela 4.11: Comparação de Resultados Nametala et al. x Sistema Proposto

Resultados							
Trabalho	Ativo	Acurácia (%)	Retorno (%)		Ativo	Acurácia (%)	Retorno (%)
Nametala et al.	ITUB4	53	51,38	Sistema Proposto	BOVA11	52,65	47,45
	CMIG4	55	34,31				
	BOVA11	56	33,58				
	BGI	52	0,48				
	EMBR3	48	-4,78				
Total			114,01	Total			47,45

Capítulo 5

Conclusão

Neste trabalho foi proposto um sistema de *trading* que negociou ativos do fundo de índice BOVA11 na bolsa de valores. O sistema apresentado possui módulos de gerenciamento de riscos, gerenciamento do dinheiro e foi baseado em previsões de redes neurais *Multilayer Perceptron* para emitir ordens de compra e venda. Foram testadas duas formas de treinamento das redes neurais: uma baseada no indicador de inclinação da regressão linear dos preços dos ativos, no período de 10 dias e a outra foi baseada no preço do fechamento do dia seguinte do ativo.

Os resultados dos experimentos mostram que as redes neurais podem ser utilizadas para apoiar a decisão dos investidores nas operações no mercado de ações, desde que fatores como arquitetura, entradas das redes, tamanho das amostras de treinamento sejam testados em diferentes estratégias e aplicadas nos sistemas de negociação.

Além disso, é importante que o objeto da predição realmente corresponda ao que se deseja prever, como no exemplo do indicador *Linear Regression Slope*. Neste caso em específico, as redes conseguiram um bom desempenho na acurácia do indicador, mas o seu uso como previsor de tendência do mercado não se mostrou eficaz para realizar negociações. A escolha de outro indicador ou uma combinação de indicadores para prever a tendência do mercado seriam outras opções a serem testadas no sistema.

O sistema de negociação, ao utilizar os previsores baseados no preço de fechamento, apesar de apresentarem taxas de acerto menores que os outros previsores, conseguiram uma boa evolução da carteira de investimento, chegando a aumentar o capital em torno de 61%, mas nos dois últimos períodos teve uma queda no rendimento e fechou o período total em 47,45% de ganhos, superando a estratégia *buy and hold*.

Nesses casos em que os previsores possuem uma acurácia menor, torna-se importante o módulo de gerenciamento de riscos, que permite que o sistema se recupere de uma escolha errada do previsor, saindo da posição mais rapidamente (*stop loss*) e valorize as escolhas certas, permanecendo na posição até obter uma margem de lucro aceitável (*take profit*), antes que o mercado volte a reverter.

O trabalho de Nametela et al. [Nametala et al. 2016] obteve resultados parecidos com relação à acurácia dos previsores do preço de fechamento deste trabalho, com acurácia um pouco acima de 50%, mas mesmo assim obtendo lucro nas negociações. Os resultados foram comparados com relação à acurácia dos previsores, já que os períodos de negociação aplicados neste trabalho foram distintos.

Foi utilizada uma estratégia de treinamentos periódicos dos previsores para que o sistema de negociação fosse capaz de se adaptar às condições mais recentes do mercado, selecionando os que atingissem maiores retornos no períodos de testes. Os resultados mostraram que essa estratégia atingiu o retorno esperado para os previsores baseados no preço de fechamento do dia seguinte. Para os previsores baseados em regressão linear, não se pode afirmar já que a estratégia de negociação não se mostrou lucrativa.

Apesar do resultado satisfatório utilizando estes previsores, o sistema somente poderia ser avaliado de forma mais conclusiva durante um período maior de negociação e aplicando o mesmo modelo em outras ações da bolsa de valores. A depender das características dos ativos a serem aplicados, outra possibilidade é modificar as variáveis de entrada dos previsores substituindo-as por indicadores e dados de cotações que tenham mais relevância para o ativo escolhido.

Os lucros foram obtidos através de uma estratégia conservadora, aplicando 1% de volatilidade na estratégia *Percent Volatility*. Pelas taxas de *drawdown* obtidas nas negociações baseadas no predictor baseado nos preços de fechamento (abaixo de 20%), o resultado obtido é considerado satisfatório, superando os investimentos de perfil conservador, como poupança ou até mesmo a estratégia *buy and hold*.

O sistema apresentado foi implementado em uma plataforma de negociação real, já utilizada por corretoras brasileiras, em modo simulado com testes em cotações históricas, seguindo as regras definidas pela corretora e o mercado de ações brasileiro, podendo ser aplicado em uma conta real ou demo.

5.1 Pesquisas Futuras

Como sugestões de pesquisas futuras, seguem algumas lacunas observadas no decorrer da pesquisa:

- O sistema poderia ser testado em cotações com outros intervalos de tempo, principalmente os menores (60, 30 e 15 minutos), que permitissem operações *intraday* como alternativa de maximizar os lucros em um pequeno período de tempo;
- Realizar o treinamento dos previsores utilizando como critério de parada apenas o valor do erro quadrático médio, sem utilizar uma quantidade pré-definida de épocas para tentar melhor o desempenho das redes neurais;

-
- Variar o período de dias do indicador LRS para o treinamento das redes, como tentativa de que a sua previsão acompanhe com mais precisão o comportamento futuro do mercado;
 - Avaliar o uso do sistema de negociação utilizando redes neurais recorrentes;
 - As janelas de tempo dos treinamentos periódicos poderiam ser variadas para verificar o desempenho em diferentes ativos, treinando previsores em intervalos maiores para ativos que tendem a manter os padrões e treinando mais frequentemente para ativos com maior alternância de comportamento;
 - O módulo de previsão do sistema também poderia ser incrementado, seja por utilização de outros métodos de inteligência computacional, como SVMs, *Random Forests* ou combinando vários previsores que poderiam fazer parte de uma espécie de votação para decidir se uma negociação poderia ser realizada;
 - A aplicação da estratégia utilizada neste trabalho em um portfólio de ações também poderia ser explorada, já que o portfólio permite ao investidor variar os investimentos realizados.

Referências Bibliográficas

- [Appel 1985] Appel, G. (1985). *The Moving Average Convergence-divergence Trading Method: Advanced Version*. Scientific Investment Systems.
- [Assaf Neto 2000] Assaf Neto, A. (2000). *Mercado Financeiro*. Atlas, São Paulo, 3 ed. edition.
- [Atsalakis e Valavanis 2009] Atsalakis, G. S. e Valavanis, K. P. (2009). Surveying stock market forecasting techniques part ii: Soft computing methods. *Expert Systems with Applications*, 36(3, Part 2):5932 – 5941.
- [Azoff 1994] Azoff, E. M. (1994). *Neural Network Time Series Forecasting of Financial Markets*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition.
- [Cao e Tay 2003] Cao, L. J. e Tay, F. E. H. (2003). Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on Neural Networks*, 14(6):1506–1518.
- [Cavalcante et al. 2016] Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., e Oliveira, A. L. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55:194 – 211.
- [Chen e Du 2009] Chen, W.-S. e Du, Y.-K. (2009). Using neural networks and data mining techniques for the financial distress prediction model. *Expert Systems with Applications*, 36(2, Part 2):4075 – 4086.
- [Chiang et al. 2016] Chiang, W.-C., Enke, D., Wu, T., e Wang, R. (2016). An adaptive stock index trading decision support system. *Expert Systems with Applications*, 59:195 – 207.
- [de Oliveira et al. 2013] de Oliveira, F. A., Nobre, C. N., e Zarate, L. E. (2013). Applying artificial neural networks to prediction of stock price and improvement of the directional prediction index case study of petr4, petrobras, brazil. *Expert Systems with Applications*, 40(18):7596 – 7606.
- [de Oliveira et al. 2011] de Oliveira, F. A., Zárate, L. E., de Azevedo Reis, M., e Nobre, C. N. (2011). The use of artificial neural networks in the analysis and prediction of stock prices. In *2011 IEEE International Conference on Systems, Man, and Cybernetics*, pp. 2151–2155.

- [Dhar et al. 2010] Dhar, S., Mukherjee, T., e Ghoshal, A. K. (2010). Performance evaluation of neural network approach in financial prediction: Evidence from indian market. In *2010 International Conference on Communication and Computational Intelligence (INCOCCI)*, pp. 597–602.
- [Dunis et al. 2013] Dunis, C., Rosillo, R., de la Fuente, D., e Pino, R. (2013). Forecasting ibex-35 moves using support vector machines. *Neural Computing and Applications*, 23(1):229–236.
- [Edwards e Magee 2009] Edwards, R. e Magee, J. (2009). *Technical Analysis of Stock Trends*. BN Publishing.
- [Elman 1990] Elman, J. L. (1990). Finding structure in time. *COGNITIVE SCIENCE*, 14(2):179–211.
- [Gambogi 2013] Gambogi, J. A. (2013). Aplicação de redes neurais na tomada de decisão no mercado de ações. Dissertação (mestrado), Universidade de São Paulo, São Paulo.
- [Gately 1995] Gately, E. (1995). *Neural Networks for Financial Forecasting*. John Wiley & Sons, Inc., New York, NY, USA.
- [Ghazali et al. 2009] Ghazali, R., Hussain, A. J., Nawi, N. M., e Mohamad, B. (2009). Non-stationary and stationary prediction of financial time series using dynamic ridge polynomial neural network. *Neurocomputing*, 72(10):2359 – 2367. Lattice Computing and Natural Computing (JCIS 2007) / Neural Networks in Intelligent Systems Designn (ISDA 2007).
- [Giacomel 2016] Giacomel, F. d. S. (2016). Um método algorítmico para operações na bolsa de valores baseado em ensembles de redes neurais para modelar e prever os movimentos do mercado de ações. Dissertação (mestrado), Universidade Federal do Rio Grande do Sul, Rio Grande do Sul.
- [Haykin 2001] Haykin, S. (2001). *Redes Neurais Princípios e Práticas*. Bookman.
- [Huang et al. 2005] Huang, W., Nakamori, Y., e Wang, S.-Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers and Operations Research*, 32(10):2513 – 2522. Applications of Neural Networks.
- [Jasemi et al. 2011] Jasemi, M., Kimiagari, A. M., e Memariani, A. (2011). A modern neural network model to do stock market timing on the basis of the ancient investment technique of japanese candlestick. *Expert Systems with Applications*, 38(4):3884 – 3890.
- [Kaastra e Boyd 1996] Kaastra, I. e Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3):215 – 236. Financial Applications, Part II.
- [Kayal 2010] Kayal, A. (2010). A neural networks filtering mechanism for foreign exchange trading signals. In *2010 IEEE International Conference on Intelligent Computing and Intelligent Systems*, volume 3, pp. 159–167.

- [Kirkpatrick e Dahlquist 2006] Kirkpatrick, C. e Dahlquist, J. (2006). *Technical Analysis: The Complete Resource for Financial Market Technicians*. FT Press, first edition.
- [Lasfer et al. 2013] Lasfer, A., El-Baz, H., e Zualkernan, I. (2013). Neural network design parameters for forecasting financial time series. In *2013 5th International Conference on Modeling, Simulation and Applied Optimization (ICMSAO)*, pp. 1–4.
- [Lin et al. 2011] Lin, X., Yang, Z., e Song, Y. (2011). Intelligent stock trading system based on improved technical analysis and echo state network. *Expert Systems with Applications*, 38(9):11347 – 11354.
- [Liu e Wang 2012] Liu, F. e Wang, J. (2012). Fluctuation prediction of stock market index by legendre neural network with random time strength function. *Neuro-computing*, 83:12 – 21.
- [Macedo et al. 2013] Macedo, J. A., Camargo, L. T. O., de Oliveira, H. C. B., da Silva, L. E., e Salgado, R. M. (2013). An intelligent decision support system to investment in the stock market. *IEEE Latin America Transactions*, 11(2):812–819.
- [Mahdi et al. 2009] Mahdi, A. A., Hussain, A. J., e Al-Jumeily, D. (2009). Adaptive neural network model using the immune system for financial time series forecasting. In *2009 International Conference on Computational Intelligence, Modelling and Simulation*, pp. 104–109.
- [Majhi et al. 2009] Majhi, R., Panda, G., e Sahoo, G. (2009). Efficient prediction of exchange rates with low complexity artificial neural network models. *Expert Systems with Applications*, 36(1):181 – 189.
- [Martinez et al. 2009] Martinez, L. C., da Hora, D. N., de M. Palotti, J. R., Meira, W., e Pappa, G. L. (2009). From an artificial neural network to a stock market day-trading system: A case study on the bm&f bovespa. In *2009 International Joint Conference on Neural Networks*, pp. 2006–2013.
- [Murphy 2003] Murphy, J. (2003). *Technical Analysis of the Financial Markets*. NYIF.
- [Nametala et al. 2016] Nametala, C. A. L., Pimenta, A., Pereira, A. C. M., e Car-rano, E. G. (2016). Uma estratégia automatizada de investimento por meio de redes neurais artificiais e preditores econométricos. In *XII Brazilian Symposium on Information Systems*, pp. 1–4.
- [Neter et al. 1996] Neter, J., Kutner, M. H., Nachtsheim, C. J., e Wasserman, W. (1996). *Applied Linear Statistical Models*. Irwin, Chicago.
- [Online Trading Concepts 2007] Online Trading Concepts (2007). Online trading concepts - using parabolic sar for stop losses. <https://www.>

- onlinetradingconcepts.com/TechnicalAnalysis/ParabolicSAR2.html. Accessed: 2018-08-01.
- [Pardo 1992] Pardo, R. (1992). *Design, Testing, and Optimization of Trading Systems*. John Wiley & Sons, Inc., New York, NY, USA.
- [Pardo 2015] Pardo, R. (2015). *Walk-Forward Analysis*, chapter 11, pp. 237–261. Wiley-Blackwell.
- [Pedregosa et al. 2011] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., e Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- [Piazza 2009] Piazza, M. C. (2009). *Bem Vindo à Bolsa de Valores*. Novo Conceito, São Paulo, 9. ed. rev. e ampl edition.
- [Qiu e Song 2016] Qiu, M. e Song, Y. (2016). Predicting the direction of stock market index movement using an optimized artificial neural network model. *PLoS ONE*, 11(5):1 – 11.
- [Rodríguez-González et al. 2011] Rodríguez-González, A., Ángel García-Crespo, Colomo-Palacios, R., Iglesias, F. G., e Gómez-Berbís, J. M. (2011). Cast: Using neural networks to improve trading systems based on technical analysis by means of the rsi financial indicator. *Expert Systems with Applications*, 38(9):11489 – 11500.
- [Shahpazov et al. 2013] Shahpazov, V. L., Velez, V. B., e Doukovska, L. A. (2013). Design and application of artificial neural networks for predicting the values of indexes on the bulgarian stock market. In *2013 Signal Processing Symposium (SPS)*, pp. 1–6.
- [Skapura 1996] Skapura, D. (1996). *Building Neural Networks*. ACM Press Series. ACM Press.
- [Sugumar e Rengarajan 2014] Sugumar, R. e Rengarajan, A. (2014). A technique to stock market prediction using fuzzy clustering and artificial neural networks. *Computing e Informatics*, 33(5):992 – 1024.
- [Teixeira 2009] Teixeira, L. A. (2009). Sistema automático para previsão de tendência de preços em bolsas de valores baseado em análise técnica e inteligência computacional. Dissertação (mestrado em engenharia da computação), Universidade de Pernambuco, Recife.
- [Tharp 1998] Tharp, V. (1998). *Trade Your Way to Financial Freedom*. McGraw-Hill Education.
- [Thenmozhi e Sarath Chand 2016] Thenmozhi, M. e Sarath Chand, G. (2016). Forecasting stock returns based on information transmission across global markets

- using support vector machines. *Neural Computing and Applications*, 27(4):805–824.
- [Ticknor 2013] Ticknor, J. L. (2013). A bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*, 40(14):5501 – 5506.
- [Vanstone et al. 2012] Vanstone, B., Finnie, G., e Hahn, T. (2012). Creating trading systems with fundamental variables and neural networks: The aby case study. *Mathematics and Computers in Simulation*, 86:78 – 91. The Seventh International Symposium on Neural Networks + The Conference on Modelling and Optimization of Structures, Processes and Systems.
- [Wilder 1978] Wilder, J. (1978). *New Concepts in Technical Trading Systems*. Trend Research.
- [Zbikowski 2015] Zbikowski, K. (2015). Using volume weighted support vector machines with walk forward testing and feature selection for the purpose of creating stock trading strategy. *Expert Systems with Applications*, 42(4):1797 – 1805.
- [Zhu e Zhou 2009] Zhu, Y. e Zhou, G. (2009). Technical analysis: An asset allocation perspective on the use of moving averages. *Journal of Financial Economics*, 92(3):519 – 544.