



UNIVERSIDADE DO ESTADO DA BAHIA
DEPARTAMENTO DE CIÊNCIAS EXATAS E DA TERRA
CURSO DE GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

AUGUSTO LIMA DOS SANTOS

PREDIÇÃO DE TENDÊNCIAS EM SÉRIES TEMPORAIS DO MERCADO *FOREX*
COM MÚLTIPLAS REDES NEURAS ARTIFICIAIS: PROJETO CÉRBERO.

SALVADOR

2018

AUGUSTO LIMA DOS SANTOS

PREDIÇÃO DE TENDÊNCIAS EM SÉRIES TEMPORAIS DO MERCADO *FOREX* COM
MÚLTIPLAS REDES NEURAS ARTIFICIAIS: PROJETO CÉRBERO.

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Sistemas de Informação do Departamento de Ciências Exatas e da Terra da Universidade do Estado da Bahia, como requisito parcial à obtenção do grau de bacharel em Sistemas de Informação.

Orientador: Leandro Santos Coelho de Souza

SALVADOR

2018

FICHA CATALOGRÁFICA
Sistema de Bibliotecas da UNEB
Dados fornecidos pelo autor

d999

dos Santos, Augusto Lima

PREDIÇÃO DE TENDÊNCIAS EM SÉRIES TEMPORAIS DO
MERCADO FOREX COM MÚLTIPLAS REDES NEURAIAS ARTIFICIAIS:
PROJETO CÉRBERO / Augusto Lima dos Santos.-- Salvador, 2018.
72 fls : il.

Orientador(a): Leandro Santos Coelho de Souza.

Inclui Referências

TCC (Graduação - Sistemas de Informação) - Universidade do
Estado da Bahia. Departamento de Ciências Exatas e da Terra. Câmpus
I. 2018.

1.Previsão de Séries Temporais. 2.Forex. 3.Múltiplas Redes Neurais
Artificiais. 4.Análise Técnica.

CDD: 004

AUGUSTO LIMA DOS SANTOS

PREDIÇÃO DE TENDÊNCIAS EM SÉRIES TEMPORAIS DO MERCADO *FOREX* COM
MÚLTIPLAS REDES NEURAIAS ARTIFICIAIS: PROJETO CÉRBERO.

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Sistemas de Informação
do Departamento de Ciências Exatas e da Terra
da Universidade do Estado da Bahia, como
requisito parcial à obtenção do grau de bacharel
em Sistemas de Informação.

Aprovada em:

BANCA EXAMINADORA

Leandro Santos Coelho de Souza (Orientador)
Departamento de Ciências Exatas e da Terra - DCET
Universidade do Estado da Bahia – UNEB

Diego Gervasio Frías Suárez
Departamento de Ciências Exatas e da Terra - DCET
Universidade do Estado da Bahia – UNEB

Marcelo Duarte Dantas de Ávila
Departamento de Ciências Exatas e da Terra - DCET
Universidade do Estado da Bahia – UNEB

A todos os que me acompanharam nessa jornada longa, cheia de incertezas, mas sobretudo feliz e emocionante. Especialmente à minha família e amigos.

AGRADECIMENTOS


Talvez eu seja um mosaico, de conhecimentos, de ideias e de valores, mas certamente sou um mosaico de vida, das vidas que cada um dedicou a mim, com seus amores, alegrias, atenções e até mesmo dores. Não posso negar a exuberância com que o universo se apresenta para mim e nem que um dia eu fiquei sem sorrir. Fui criado na base do "muito bem", "parabéns", "continue assim" e isso só me fez bem. Talvez o segredo seja não esperar um compromisso obrigatório das pessoas, mas se admirar toda vez que alguém faz um hiato para ajudar.

Agradeço aos meus pais por toda a dedicação e amor, além da incrível habilidade de ensinar o que nem sabiam que sabiam. Agradeço também as famílias, que compõem minha história e são fonte inesgotável de alegrias e curiosidades.

Agradeço aos amigos que já eram amigos e aos colegas que viraram amigos, só nós sabemos encarar o desespero e rir, morrer de rir na cara dele. Sigamos todos em frente, na certeza de que já não há desafios que não possamos vencer e *secrets* que não possamos descobrir.

Agradeço aos professores que, cada um ao seu jeito peculiar, me ensinou algo novo, do bit até a vida. Em especial, agradeço aos professores que se tornaram grandes amigos e exemplos de coragem e dedicação.

Ao Senhor peço que "faça-me instrumento de vossa paz", pois "já sei olhar o rio por onde a vida passa, sem me precipitar e nem perder a hora, escuto no silêncio o que há em mim e basta, outro tempo começou para mim agora". A todos o meu muito obrigado!



“Deus quer, o homem sonha, a obra nasce.”

(Fernando Pessoa)

RESUMO

As séries temporais fascinam por sua capacidade de condensar informações e a vasta gama de áreas do conhecimento que podem se valer das mesmas. O estudo do comportamento destas séries serve para compreender o passado, mas principalmente para tentar prever o futuro. Um ambiente em que o processo de previsão de séries temporais apresenta grande apelo é o mercado financeiro, dos quais se destaca o mercado de câmbio de par de divisas, o Foreign Exchange (*Forex*). O *Forex* chega a movimentar trilhões de dólares diariamente, pelos mais diversos investidores. Apesar de as séries do *Forex* não apresentarem padrões claros, ou que se sustentem por muito tempo, os investidores ainda conseguem obter uma taxa de acerto suficiente para se sustentarem apenas com as operações que realizam. Um dos conjuntos de técnicas utilizadas é a conhecida análise técnica. Os padrões de análise técnica não são precisos o suficiente para que sejam automatizados de forma simples, no entanto, é possível encontrar diversos exemplos reais de operações com base nesses padrões. A utilização de redes neurais artificiais, portanto, surge como uma solução viável para o aprendizado de padrões de análise técnica, haja vista que o processo de aprendizagem se dá através de exemplos. Muitos trabalhos têm sido desenvolvidos no contexto do mercado financeiro utilizando redes neurais artificiais para prever séries temporais, no entanto, estes trabalhos não costumam levar em conta métricas financeiras, como o lucro. Sendo assim, o presente projeto busca desenvolver uma estratégia de negociação baseada em inteligência artificial, utilizando padrões de análise técnica com foco em métricas de retorno financeiro. Além disso, partindo do princípio de que quanto maior for o número de padrões de análise técnica que indiquem um mesmo movimento futuro, maiores são as chances de que este ocorra, este projeto inova por apresentar múltiplas redes neurais, especializadas em padrões de análise técnica, compondo um modelo denominado de Projeto Cérbero.

Palavras-chave: Séries Temporais. *Forex*. Análise Técnica. Múltiplas Redes Neurais.

ABSTRACT

Time series fascinate by their ability to condense information and the wide range of areas of knowledge that can avail themselves of them. The study of the behavior of these series could be used to understand the past, but mainly to try to predict the future. One environment in which the time series forecasting process presents great appeal is the financial market, of which the currency pair exchange market, the Foreign Exchange (Forex), stands out. Forex trades trillions of dollars daily, by the most diverse investors. Although the Forex series do not show clear standards or hold for a long time, investors are still able to obtain a sufficient rate of return to sustain themselves only with the operations they perform. One of the sets of techniques used is known technical analysis. Technical analysis standards are not accurate enough to be automated in a simple way, however, you can find several real examples of operations based on these standards. The use of artificial neural networks, therefore, appears as a viable solution for the learning of standards of technical analysis, since the learning process is given through examples. Many works have been developed in the context of the financial market using artificial neural networks to predict time series, however, these works do not usually take into account financial metrics such as profit. Therefore, the present project seeks to develop a negotiation strategy based on artificial intelligence, using technical analysis standards focused on financial return metrics. Furthermore, assuming that the greater the number of technical analysis patterns that indicate the same future movement, the greater the chances of this occurring, this project innovates by presenting multiple neural networks, specialized in technical analysis standards, composing a model called the Cerberus Project.

Keywords: Time Series. Forex. Technical analysis. Multiple neural networks.

LISTA DE ILUSTRAÇÕES

Figura 1 – Processo simplificado de compra no <i>Foreing Exchange Market (Forex)</i>	19
Figura 2 – Exemplo de série temporal.	21
Figura 3 – Mercados abertos e fechados pelo mundo.	24
Figura 4 – Exemplo de Suporte e Resistência.	28
Figura 5 – Confirmação de Alta.	29
Figura 6 – Exemplo da aplicação da retração de <i>fibonacci</i>	30
Figura 7 – Modelo de Neurônio Artificial (Adaptado de: Haykin (2001, p. 36))	32
Figura 8 – Arquitetura básica de uma RNN e seu <i>loop</i>	35
Figura 9 – Representação da arquitetura RNN com seu loop expandido.	35
Figura 10 – Representação interna de um módulo que compõe a arquitetura LSTM.	36
Figura 11 – Modelo de elementos e fluxos do Projeto Cérbero.	37
Figura 12 – Modelo de elementos e fluxos do Projeto Cérbero ampliado 01 e 02.	38
Figura 13 – Modelo de elementos e fluxos do Projeto Cérbero ampliado 03 e 04.	40
Figura 14 – Exemplo de funcionamento das SEQs, contabilizando três SEQs positivas e três SEQs negativas.	42
Figura 15 – Exemplo da formação de Picos e Vales utilizando a técnica derivada de Bortoli (2015).	42
Figura 16 – Recorte de uma janela de matriz de vértices.	45
Figura 17 – Modelo de elementos e fluxos do Projeto Cérbero ampliado 06 e 07.	46
Figura 18 – Identificação de suporte e resistência utilizando o <i>Expert Advisors (EA)</i> desenvolvido.	47
Figura 19 – Identificação de triângulos utilizando <i>EA</i> desenvolvido.	48
Figura 20 – Rede com <i>Overfitting</i>	56
Figura 21 – Rede com uma camada de <i>Dropout</i>	57
Figura 22 – Acurácia atingida nas redes com saída 1 - Resistência.	57
Figura 23 – Erro atingida nas redes com saída 1 - Resistência.	57
Figura 24 – Acurácia atingida nas redes com saída 2 - Resistência.	59
Figura 25 – Erro atingida nas redes com saída 2 - Resistência.	59
Figura 26 – Acurácia atingida nas redes com saída 2 corrigida - Resistência.	60
Figura 27 – Erro atingida nas redes com saída 2 corrigida - Resistência.	60
Figura 28 – Acurácia atingida nas redes com saída 1 - Suporte.	61

Figura 29 – Erro atingida nas redes com saída 1 - Suporte.	62
Figura 30 – Acurácia atingida nas redes - Triângulo.	62
Figura 31 – Erro atingida nas redes - Triângulo.	62
Figura 32 – Acurácia atingida nas redes - Retração de Fibonacci.	64
Figura 33 – Erro atingida nas redes - Retração de Fibonacci.	64
Figura 34 – Recorte do <i>Strategy Test Report</i> semana 1.	67

LISTA DE TABELAS

Tabela 2 – Configurações Utilizadas na definição e treinamento das redes neurais. . . .	50
Tabela 3 – Dados Estatísticos das Janelas Produzidas.	53
Tabela 4 – Ocorrências das Amplitudes das Janelas Produzidas.	54
Tabela 5 – Ocorrência dos elementos de análise técnica do mês de Fevereiro de 2014. .	55
Tabela 6 – Macrotendências que alcançam um suporte ou resistência.	55
Tabela 7 – Percentuais de acerto com a predição das redes para saída 1 - Resistência. .	58
Tabela 8 – Percentuais de acerto com a predição das redes para a saída 2 - Resistência.	60
Tabela 9 – Percentuais de acerto com a predição das redes para a saída 1 - Suporte. . .	62
Tabela 10 – Percentuais de acerto com a predição das redes - Triângulo.	63
Tabela 11 – Percentuais de acerto com a predição das redes - Fibonacci.	64
Tabela 12 – Contabilização da diferença entre a saída esperada e predito das redes no teste - Fibonacci.	65
Tabela 13 – Simulação no mercado do Cérbero das 8 semanas.	68

LISTA DE ABREVIATURAS E SIGLAS

<i>Ask</i>	Preço de Venda
<i>Bid</i>	Preço de Compra
<i>EA</i>	<i>Expert Advisors</i>
<i>Forex</i>	<i>Foreing Exchange Market</i>
<i>PIP</i>	<i>Point In Percentage</i>
Demo	Demonstrativa
ELU	Unidade Linear Exponencial
ReLU	Unidade Linear Retificada
RNA	Rede Neural Artificial
RNR	Rede Neural Recorrente
TanH	Tangente Hiperbólica

SUMÁRIO

1	INTRODUÇÃO	15
2	MERCADO <i>FOREX</i>	19
2.1	AS SÉRIES TEMPORAIS EM SUAS ESPECIFICIDADES	21
2.1.1	Séries Temporais	21
2.1.2	As séries do <i>Forex</i>	23
2.2	TERMINAIS DE NEGOCIAÇÃO	24
2.2.1	<i>Expert Advisors</i>	25
2.2.2	Variáveis do relatório de negociação	25
2.3	PADRÕES DE ANÁLISE TÉCNICA	26
2.3.1	Suporte e Resistência	27
2.3.2	Triângulos	28
2.3.3	Retrações de <i>Fibonacci</i>	29
3	REDES NEURAS ARTIFICIAIS	32
3.1	FUNÇÃO DE ATIVAÇÃO	33
3.2	REDE NEURAL RECORRENTE	34
4	CÉRBERO	37
4.1	<i>FOREX</i> E O ARMAZENAMENTO DE DADOS	38
4.2	BASE DE DADOS E A SELEÇÃO DE DADOS	40
4.3	INDICADOR SUAVIZADOR	41
4.3.1	Vértices Originais	43
4.3.2	Vértices Intercalados	43
4.3.3	Vértices em Macrotendência	43
4.3.4	Matriz de Vértices	44
4.4	REDES NEURAS E TOMADA DE DECISÃO	45
4.4.1	Rede Neural Artificial Padrão I e II	47
4.4.2	Rede Neural Artificial Consolidadora e a Tomada de Decisão	49
4.4.3	Parametrização	50
4.4.4	Processo de Treinamento	51
4.5	TESTES DAS REDES	51
4.6	TERMINAL DE NEGOCIAÇÃO, RESULTADOS E ANÁLISE	52

5	RESULTADOS	53
5.1	RESULTADOS ESTATÍSTICOS	53
5.2	RESULTADOS DE PROCESSAMENTO	56
5.3	RESULTADOS DE EXECUÇÃO	65
6	CONCLUSÕES E TRABALHOS FUTUROS	69
	REFERÊNCIAS	70
	GLOSSÁRIO	71

1 INTRODUÇÃO

O Todo é uma síntese única das partes que o fundamentam ao mesmo tempo que este justifica a existência das mesmas, (UHLMANN, 2002). De forma análoga, um conjunto de eventos relacionados entre si, formando uma série, podem ser entendidos como as partes desta série, cuja união singular determina o comportamento geral. Sendo assim, compreender as partes de uma série significa prover as ferramentas para classifica-la, compreendê-la e até mesmo prevê-la.

O processo de predição, apesar de intrigar a humanidade desde sua existência, acredita-se que se justifica pela necessidade humana de preparação para os eventos em virtude da escassez de recursos. Ao longo da história várias foram as técnicas ou abordagens utilizadas para se prever. Esta previsão, por sua vez, estava necessariamente atrelada aos elementos de grande desejo e difícil manipulação. Na atualidade, um objeto de grande desejo e difícil manipulação, cujo processo de previsão é totalmente cabível são as séries temporais.

As séries temporais são formas de representação de eventos ocorridos com um determinado objeto, avaliando um ou vários aspectos, como se fosse um histórico de algo. Apesar da simplicidade apresentada, estas séries são um recurso poderoso, pois intrinsecamente comportam diversas informações sobre a evolução de um determinado objeto de estudo. São aplicáveis em praticamente todas as áreas em que o tempo é essencial para o desenvolvimento ou transformação do objeto analisado. Nesse sentido, desde o surgimento do universo até uma corrida de carros, pode ser analisado sob a ótica das séries temporais.

Apesar da presença das séries temporais em quase todas as áreas de ação antrópica, é notória a existência de séries de maior e menor complexidade. Mesmo que hajam interessados nas de menor complexidade, acredita-se que quanto maior a complexidade de uma série maior relevância e impacto científico há nos resultados de seus estudos.

Um ambiente que oferece séries temporais de alta complexidade e que apresenta apelo para estudos de previsão é o mercado financeiro. Dado o desafio de prever os ativos dos mercados financeiros quanto mais complexo o mercado mais importante se torna o trabalho, pois pressupõe-se que é possível generalizar o método de previsão do mais complexo para os mais simples. Nesse sentido, um mercado que apresenta um desafio considerável é o *Forex*.

O *Forex* é o mercado global de câmbio de par de divisas ou simplesmente câmbio de moedas. Nele é possível negociar diversas moedas, sempre uma em relação ao seu par, como por exemplo a negociação do dólar americano em relação ao euro. Diariamente são

movimentados trilhões de dólares americanos, com uma altíssima taxa de geração de dados, comumente conhecida como volatilidade dos preços, de modo que os preços podem atingir centenas de valores diferentes em apenas um minuto.

As restrições para se realizar operações no mercado *Forex* vêm sendo reduzidas sistematicamente, de modo que atualmente, com apenas 100 dólares americanos é possível investir e competir, dadas as devidas proporções, com os maiores bancos do mundo. As negociações ocorrem através de corretoras que disponibilizam para seus clientes terminais de negociação, permitindo, dentre outras coisas, a negociação automatizada através de robôs.

A utilização de robôs de negociação é uma realidade nos mercados financeiros. Além de representar um ambiente promissor para trabalho dos profissionais de Tecnologia da Informação, o desenvolvimento desses robôs apresenta um desafio, haja vista que a lucratividade depende diretamente da eficiência da estratégia utilizada. No mercado *Forex* o desafio da construção de robôs eficazes se funde ao desafio da previsão de séries temporais estocásticas não-estacionárias. Fornecendo assim, o ambiente e objeto de estudo adequado para técnicas computacionais arrojadas como as técnicas de inteligência artificial.

A inteligência artificial é a área do conhecimento que busca conhecer e simular a capacidade de raciocínio humana para tomadas de decisões e resoluções de problemas. Uma das correntes da inteligência artificial inspirou-se na biologia, ou mais especificamente neurociência, para o desenvolvimento de técnicas de inteligência de estrutura próxima a de elementos do organismo humano, como visto em RUSSELL e NORVIG (2013). Uma dessas técnicas que apresenta confluência com o estudo e previsão de séries temporais é a Rede Neural Artificial (RNA).

As redes neurais artificiais, ou simplesmente redes neurais, como apresentadas por Carvalho (2017), apresentam capacidade de aprendizagem e generalização de forma adaptativa e não-linear a partir de um processo de treinamento baseado em entradas condizentes com o problema que se espera resolver através da rede.

Não há consenso sobre a arquitetura ou parametrização de rede neural mais adequada para cada problema. Por outro, lado a importância do conjunto de entradas para determinação do aprendizado da rede é clara. Acredita-se que uma possível solução para as entradas da rede é a utilização de padrões de análise técnica.

A análise técnica permite a utilização de padrões, encontrados previamente na literatura, muitos dos quais são utilizados diariamente por investidores, que dado um determinado

tipo de configuração do mercado sugere uma específica tendência futura.

Apesar da categorização das séries do *Forex* como estocásticas, estudos Putra et al. (2016) Yong et al. (2015) Bulkowski (2011) Hansun (2017), bem como a experiência de investidores, têm apontado para a realidade da existência de estados, alguns dos quais bem definidos e de constante ocorrência no mercado. Esses estados correspondem a elementos de análise técnica. Identificar esses estados ou padrões permitem, por tanto, prever o futuro. Um investidor, porém, não leva em conta um único padrão, quanto maior quantidade de indícios de uma tendência maior a probabilidade de que esta ocorra, torna-se necessário, portanto, identificar múltiplos padrões, conforme identificou Putra et al. (2016), que utiliza múltiplos indicadores para dar maior confiabilidade à previsão.

O Problema de pesquisa proposto parte do pressuposto de que é possível prever valores de tendências futuras no mercado financeiro *Forex*, hipótese reforçada por estudos já apresentados. Não obstante, algumas variáveis importantes do mercado financeiro, como por exemplo a lucratividade, não são consideradas para fins de análise dos resultados, o que os torna insatisfatórios ou inseguros para investidores. Assim, o objetivo do presente trabalho concentra-se na utilização de uma arquitetura com Múltiplas Redes Neurais Artificiais, para predição de tendências no *Forex*, tendo em consideração as variáveis pertinentes para predição lucrativa. Para tanto, supõe-se que utilizando uma arquitetura com múltiplas redes neurais artificiais, em conjunto com elementos de análise técnica extraídos do mercado, seja possível prever valores de tendências com resultados mais assertivos que a aleatoriedade.

Espera-se por tanto, contribuir para o desenvolvimento de uma técnica de previsão eficiente, capaz de apresentar ganhos financeiros, auxiliando investidores relacionados ao mercado *Forex*, traduzindo-se em um sistema de negociação para um nicho do mercado financeiro. A realização do trabalho, ainda que focado no mercado *Forex*, colabora com os estudos a respeito de séries temporais, que se mostram como um problema transversal a diversas áreas do conhecimento, gerando um modelo para predição de valores em séries temporais, bem como uma base de conhecimento para o modelo proposto. Além disso, busca-se explorar uma abordagem de pesquisa em redes neurais artificiais, até então não encontrada na revisão da literatura realizada, proporcionando uma nova forma de enxergar a interação entre redes neurais artificiais e uma base de conhecimento para a inteligência artificial. Dessa forma destaca-se o caráter restrito e universal da pesquisa, bem como sua importância para a comunidade.

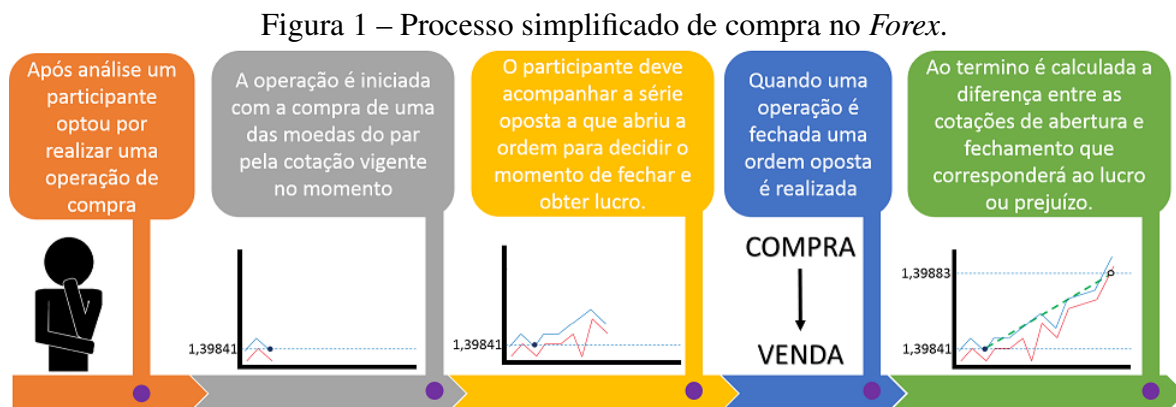
Os próximos capítulos buscam explorar os elementos essenciais para a realização

deste projeto. Desse modo o Capítulo 2 apresenta os elementos pertinentes ao mercado como o processo de negociação, as séries temporais que sintetizam e configuram o *Forex*, o terminal de negociação e os padrões de análise técnica que servem como base teórica para as técnicas de previsão. O Capítulo 3 trata das redes neurais artificiais, permitindo entender seu funcionamento e esclarecendo o modelo utilizado. O Capítulo 4 corresponde ao projeto realizado e busca deixar claro todos os detalhes de seu funcionamento. Os capítulos 5 e 6, são o fechamento do presente trabalho em que os resultados obtidos são destrinchados e comentados.

2 MERCADO FOREX

O *Forex*, corresponde ao mercado internacional de câmbio de par de divisas. Chega movimentar mais de 5 trilhões de dólares americanos por dia, segundo Roledene et al. (2016). Dentre os mercados financeiros é o que apresenta maior liquidez e é classificado como um mercado de derivativos¹, tendo especificamente um mercado de opções² como principal destaque.

As operações ou ordens no *Forex* ocorrem com base na lógica do mercado de derivativos. Há dois tipos de operações que podem ser realizadas, as de compra e as de venda. Toda vez que um participante do mercado resolve negociar um ativo, ele deve adotar uma posição de compra ou de venda. A Figura 1 apresenta um processo simplificado de operação no mercado *Forex*.



Como demonstrado na Figura 1, a primeira etapa no processo de negociação é a tomada de decisão, etapa a qual esse trabalho se propõe a realizar através do uso de inteligência artificial e análise técnica.

Uma vez feita a opção pela operação de compra a segunda etapa consiste em enviar a ordem ao mercado que a fará com base na cotação vigente. O histórico das cotações até o momento presente formam duas séries temporais cujo comportamento não é completamente descrito por nenhuma função matemática, que são o Preço de Venda (*Ask*) e Preço de Compra (*Bid*). Uma operação sempre é iniciada em uma série e finalizada na outra. Nos caso das operações de compra se inicia no *Ask* e se fecha no *Bid*, já na operação de venda se inicia no *Bid* e se fecha no *Ask*. É interessante notar que, com exceção das situações em que ambas as séries apresentam o mesmo valor de cotação, sempre uma operação é iniciada com perda

¹ Derivativos são aqui entendidos como "instrumentos financeiros cujos preços estão ligados a outro instrumento que lhes serve de referência"BM&F (2007).

² Deve-se entender mercado de opções como ambiente em que "negocia-se o direito de comprar ou de vender um bem (mercadoria ou ativo financeiro) por um preço fixo numa data futura"BM&F (2007).

financeira. Isto deixa claro que, para os participantes do mercado, não basta saber a tendência futura imediata que o mercado seguirá, mas também se essa tendência se sustenta o suficiente para superar a perda e gerar algum lucro.

É fundamental acompanhar ambas as séries, como apresentado na terceira etapa, para decidir o momento de finalizar a operação. Uma vez iniciada uma ordem, a volatilidade do *Forex* pode levá-lo a atingir os valores desejados imediatamente ou com longo prazo de tempo, sendo que por vezes pode aproximar-se ou afastar-se sem atingi-lo.

No momento em que é enviado o comando para fechamento da ordem, seguindo a lógica do mercado de derivativos, é realizada uma ordem inversa a inicial, como apresentado por BM&F (2007). Esta ordem inversa não é realizada pelo investidor, mas pela corretora. Podemos verificar que em uma operação de compra, um volume do ativo, ou mais especificamente a moeda, foi comprada em um valor de cotação. Quando a ordem é finalizada, esse mesmo volume precisa ser vendido para que a diferença entre o valor de compra e o de venda gere lucro para o investidor. O mesmo ocorre em uma operação de venda, que ao final tem uma ordem de compra realizada pela corretora cuja diferença de valores representa o lucro da operação. Dessa forma fica clara a necessidade da ordem inversa.

Uma vez finalizada a operação, como representado na quinta etapa da Figura 1, temos o lucro ou prejuízo da operação. Além do lucro e prejuízo, os participantes assíduos do mercado tem preocupação com outros fatores ligados ao seu desempenho, por tanto várias análises e informações são extraídas de cada operação.

Os participantes ou investidores desse mercado variam de pequenos investidores, cuja ação está diretamente ligada com a possibilidade de alavancagem por parte das corretoras, até bancos de grande porte e fundos de pensão, ou mesmo governos. Os investidores podem realizar operações de compra ou venda de uma moeda em relação a outra em lotes completos ou fracionados.

Toda a lógica de investimento no *Forex* baseia-se na verificação das cotações assumidas pelas séries temporais *Ask* e *Bid*. Sendo assim compreender as séries temporais torna-se fundamental para o entendimento do presente trabalho, o que será melhor explorado na próxima seção. Há ainda as seções que apresentam os terminais de negociação, em que é possível realizar a interação com o mercado, e a seção que trata da análise técnica e as suas colaborações para este projeto.


2.1 AS SÉRIES TEMPORAIS EM SUAS ESPECIFICIDADES

A percepção da evolução em relação ao tempo ocorre mesmo antes de haver uma classificação e estudo desse fenômeno. No entanto, apenas com o estudo essa percepção deixa de ser uma mera curiosidade e passa a ser elemento de compreensão e guia para transformações da realidade, sob o título de séries temporais.

2.1.1 Séries Temporais

Uma série temporal, tal qual apresentado por Averkin e Yarushev (2017), corresponde a uma sequência cronológica de dados cuja ocorrência está, necessariamente, em função de intervalos regulares de tempo. A representação mais usual destas séries é através de um gráfico em um plano cartesiano, como pode ser visto na Figura 2 em que o eixo das abscissas representa o intervalo regular de tempo e o eixo das ordenas apresenta o valor numérico de cada dado em determinado instante de tempo.

Figura 2 – Exemplo de série temporal.



Na prática, uma série temporal é um vasto conjunto de observações de um mesmo objeto dispostas na ordem em que ocorreram. Em cima destas observações é possível realizar vários estudos estatísticos e projeções, capazes de revelar informações sobre o objeto que outros estudos poderiam não revelar. O tema séries temporais têm grande relevância em algumas áreas do conhecimento, como a economia, de modo que já há classificações específicas e componentes elucidados.

Uma das classificações das séries temporais diz respeito a forma como são feitas as

observações dos dados, dividindo-se em contínuas e discretas. Uma série contínua tem medições em todos os instantes de tempo, enquanto que a discreta apresenta medições em pontos discretos de tempo, Adhikari e Agrawal (2013). Os autores ainda exemplificam como série contínua a variação de temperatura ou vazão de um rio. Já como série discreta, são exemplos, a população de uma cidade e as cotações do mercado financeiro.

Outra classificação é quanto a quantidade de tipos de registros especificados na série, podendo ser univariada ou multivariada. De acordo com Adhikari e Agrawal (2013) são consideradas séries temporais univariadas aquelas que apresentam registros de uma única variável, como por exemplo o volume de chuvas durante o ano em determinada região. Por outro lado, se a série além de apresentar o volume de chuvas contiver as médias de temperatura no mesmo período no mesmo local, então passa a ser multivariada, pois registra mais de uma variável a respeito do mesmo objeto.

As séries temporais ainda podem ser categorizadas como determinísticas e estocásticas. As séries determinísticas são as que podem ser definidas por uma equação matemática que indica todo o seu comportamento. Já as séries estocásticas, como explanado por Nicolau (2000), podem ser entendidas como apresentando valores aleatórios dentro de um conjunto probabilístico, intervaladas por um valor constante. As séries estocásticas podem ser definidas como estacionárias, que diz respeito à semelhança de propriedades estatísticas, como média e variâncias, em um intervalo finito, ou ainda podem ser definidas como não estacionárias, que corresponde justamente ao oposto, quando as propriedades estatísticas são dessemelhantes, como apresentado por Silveira et al. (2017).

O estudo das séries temporais elucidada alguns componentes, trazidos por Lamounier (2007) e por Adhikari e Agrawal (2013):

- A **tendência** é um dos componentes mais importantes do estudo de séries temporais, corresponde à análise do nível médio de uma série durante um intervalo de tempo, indicando uma elevação, declínio ou estagnação do valor médio.
- O **ciclo** corresponde a movimentos recorrentes de elevação e declínio, ou seja, movimento recorrentes de tendências, periódicos ou aproximadamente periódicos.
- A **sazonalidade** também corresponde a um comportamento recorrente de tendências, porém em um intervalo de tempo definido que deve voltar a se repetir
- As **irregularidades** que são causadas por influências imprevisíveis, normalmente externas ao ambiente imediato em que a série se forma, causam perturbações nas séries que não se

enquadram em padrões específicos ou seguem regularidades.

As séries temporais no presente projeto têm o propósito de atuarem como sintetizador do objeto de estudo, que seria o mercado *Forex*, podendo assim haver a consideração de que as séries temporais do *Forex* são o objeto de estudo. Seguindo a caracterização abordada anteriormente, temos então que as séries produzidas neste mercado são, por tanto, discretas, multivariadas, estocásticas e não estacionárias, tendo a tendência como principal elemento de análise.

2.1.2 As séries do *Forex*

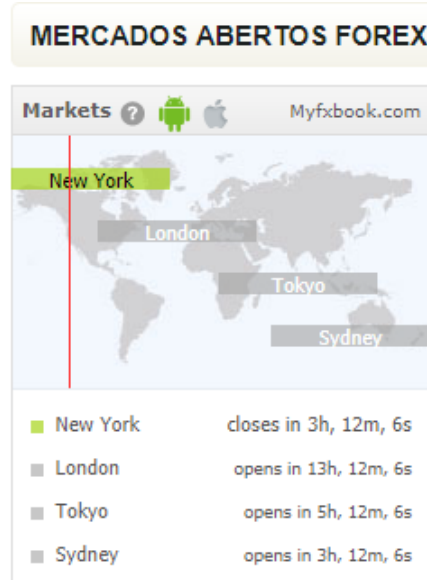
As séries temporais do mercado *Forex* são categorizadas como estocásticas, já que dado um intervalo de tempo representativo da movimentação do mercado, dificilmente apresentará comportamento matematicamente definido pelas funções conhecidas na atualidade. É possível ainda classificá-las como não estacionárias já que valores como média e variância não se mantêm constantes dada uma amostra definida, em concordância com a maioria das séries econômicas como explanado em Bressan (2004). A aleatoriedade destas séries se justifica pela diversidade de agentes e interesses que interagem com as mesmas.

O valor de *Ask*, como apresentado em Bortoli (2015), corresponde ao “valor que o mercado está disposto a vender uma moeda”, enquanto que o *Bid* diz respeito à operação oposta, ou seja, quanto o “mercado está disposto a comprar uma moeda”. O valor de *Ask* é sempre igual ou superior ao *Bid*, isto porém, não significa um espelhamento de uma das séries, pelo contrário, a observação do comportamento das séries deixa claro a diferenciação na movimentação destas. A diferença entre as cotações no mesmo instante de tempo nas duas séries é denominado *Spread*. Novas cotações são adicionadas a série a qualquer momento, no que é conhecido como *Tick*, cuja ocorrência pode se dar em intervalos menores que os segundos. Cada cotação pertence ao conjunto dos reais positivos e tem como última casa decimal da cotação, como pode ser visto em Roledene et al. (2016), o *Point In Percentage (PIP)*, valor arredondado na cotação das moedas.

A geração de dados destas séries é ininterrupta, pois a operação do mercado ocorre 24 horas durante a semana, até as 19h (local, em GMT seria 22h) do sábado e a partir das 19h (local, em GMT seria 22h) do domingo. Isso ocorre, como explica Bortoli (2015), devido ao fato de que as “transações feitas no mercado também são descentralizadas”, o que permite que o mercado funcione desde a abertura da primeira bolsa de valores do mundo até a última, como fica evidente na Figura 3. Na mesma Figura é notório que mesmo sendo a de *New York* a única

bolsa aberta, a de *Sydney* abrirá exatamente no mesmo momento em que a de *New York* fechar. O fato de ser descentralizado também é curioso pela margem de eventos externos ao mercado que podem influenciá-lo como medidas políticas, acidentes, lançamento de produtos, dentre outros.

Figura 3 – Mercados abertos e fechados pelo mundo.



Fonte: Traders (2017)

Como apresentado na Figura 1 a realização de uma operação leva em conta as duas séries. Uma operação de venda é iniciada no *Bid* e concretizada no *Ask*, para se obter lucro esperasse que o valor de *Ask* realize um movimento de descida para um valor inferior ao valor de abertura. No caso da operação de compra, inicia-se no *Ask* e concretiza-se no *Bid*, o lucro é obtido quando o valor de *Bid* consegue superar o valor inicial da operação.

Há no mercado um ciclo em que os investidores verificam as séries de cotações e com base nelas realizam ordens de negociação, ordens estas que serão somadas as demais compondo o novo valor de cotação. As operações realizadas neste mercado, se valem de uma plataforma própria que recebe os dados das cotações e enviam ordens de negociação, conhecidos como Terminais de Negociação.

2.2 TERMINAIS DE NEGOCIAÇÃO

As transações no *Forex* são comumente realizadas em terminais de negociação fornecido pelas corretoras. Dentre os terminais, o mais comum é o *MetaTrader* que é disponibilizado pelos portais online das corretoras e permite a negociação tanto com uma conta real, quanto com uma conta Demonstrativa (Demo).

Esses terminais exibem em modo gráfico e em tempo real as cotações dos pares de moeda do mercado. É possível adicionar indicadores nos gráficos, pesquisar por pares de moeda, modificar os tempos gráficos e os tipos de gráficos, o terminal ainda armazena cotações formando uma base de dados históricos dos ativos visualizados e há até mesmo suporte para chat. Tudo isso para facilitar o processo de negociação dos investidores no mercado.

Um dos principais recursos que as plataformas de negociação apresentam são os *Expert Advisors* que permitem a execução de estratégia automatizadas, bem como os relatórios de negociação do qual serão apresentadas algumas variáveis.

2.2.1 *Expert Advisors*

Os *Expert Advisors* ou robôs de negociação são desenvolvidos na linguagem *MQL*, no caso da plataforma *MetaTrader*, que tem como última versão a versão 5. A linguagem *MQL* pode ser trabalhada de modo procedural, mas também permite orientação à objetos. O desenvolvimento dos *EA* permite a utilização de bibliotecas externas ao pacote de instalação, além de indicadores do próprio terminal de negociação e de componentes gráficos. Esses robôs permitem a automatização do processo de negociação, bem como a realização de análises embasadas em mais dados e em menos tempo que o ser humano. Todas as funções necessárias para a operação constam na linguagem *MQL*, especialmente as de abertura e fechamento das ordens.

Os *Expert Advisors* são feitos exclusivamente para o terminais de negociação, cabendo utilização em negociações reais ou no sistema de simulação com dados históricos, também conhecido como examinador de estratégias. O mais adequado é que antes de aplicar um robô em negociações reais ele passe pela simulação, para verificar seu desempenho e corrigir eventuais falhas. Nesse sentido o processo de simulação se mostra muito importante.

A simulação utiliza dados históricos coletados pelo próprio terminal de negociação, enquanto ativado, ou através da base de dados das corretoras. A simulação permite ainda escolher o tempo gráfico em que o robô irá atuar, otimização de parâmetros e modo visual. Todos esses elementos colaboram para o desenvolvimento do *EA* seja qual for a destinação dada ao mesmo.

2.2.2 Variáveis do relatório de negociação

Um sistema que se propõe a operar no mercado financeiro precisa se preocupar com o lucro, principalmente, porém o aperfeiçoamento contínuo depende, também, da análise de

outras variáveis.

O relatório de negociação do examinador de estratégias apresenta variáveis bem pertinentes para a análise do desempenho do *EA*, bem como da macro estratégia adotada. Foram considerados importantes para este projeto as seguintes variáveis:

- Totais de Negociações, que corresponde ao número total de posições de compra e venda adotadas, bem como seu somatório;
- Tempo médio entre negociações, que diz respeito ao tempo médio entre cada ordem de compra ou de venda;
- Porcentagens de negociações com lucro e com perda;
- Lucro e perda, neste caso busca-se as informações do lucro e perda bruta e líquida.
- Compensação esperada, que corresponde a uma taxa de retorno considerando o lucro líquido total e o total de operações. Esse elemento é de grande importância, pois a partir dele podemos verificar se o sistema é sustentável ³ em ambiente real ou não.

Os resultados apresentados pelas variáveis do relatório de negociação estão intimamente relacionados com a estratégia de negociação aplicada no *EA*. A estratégia de negociação necessita de um método para realizar previsões dado o estado atual ou passado do mercado. A análise técnica e mais especificamente os padrões de análise técnica são uma solução viável enquanto técnica de previsão.

2.3 PADRÕES DE ANÁLISE TÉCNICA

Os relatos de pessoas que conseguem enxergar objetos, rostos ou formas animais em nuvens ou manchas, são corriqueiros. Essa capacidade humana recebe o nome de pareidolia, que como apresentado por Resende e Argimon (2010), é "um estímulo ótico pouco definido, ou vago, em que a mente percebe imagens distintas e significativas, ou imagens cinestésicas latentes". Essa seria, possivelmente, uma explicação para o fato de algumas pessoas conseguirem identificar formações imagéticas nos gráficos de cotações dos mercados financeiros. No entanto, ao contrário de muitos dos casos em que as imagens são vistas em nuvens e manchas, muitas das imagens vistas no mercado financeiro tendem a se repetir e gerar um tipo específico de consequência, configurando-se como um padrão que compõe a análise técnica.

A análise técnica, segundo Penteadó (2003), baseia-se "no estudo da evolução dos preços de mercado dos ativos ao longo do tempo". O autor ainda apresenta o entendimento

³ Entende-se como sustentável situação em que o sistema consegue se manter sem necessitar de recursos adicionais.

de outros autores dos quais se destacam as seguintes palavras chave : histórico ou passado do ativo, possibilidade de previsão, fatores racionais e irracionais, tendências e registros gráficos do ativo. Em seu trabalho Penteado (2003) deixa claro que a análise consegue identificar padrões no passado e que estes tendem a se repetir no futuro.

A origem da análise técnica, também conhecida como análise gráfica, de acordo Penteado (2003), data do século XVII no Japão, tendo sido aplicada para o preço do arroz, este método de registro dos preços ficou conhecido como *Candlestick*. Atualmente existem diversas formas de análise técnica que são comumente estudadas e aplicadas pelos investidores, especialmente os que fazem investimentos diariamente, conhecidos como *traders*.

Este trabalho não pretende esgotar o tema análise técnica, mas valer-se destas técnicas para atingir seu objetivo de previsão de tendências do mercado *Forex*. Sendo assim, foi dado foco a três técnicas que serão abordadas neste trabalho, a técnica de suporte e resistência, a de triângulos e a de retrações de *fibonacci*.

2.3.1 Suporte e Resistência


A técnica de suporte e resistência é uma técnica conhecida entre os investidores que estudam as formas de análise técnica, especialmente por sua simplicidade e por compôr outros padrões.

O suporte e a resistência são apresentados por Paula e Triches (2010), como sendo umas das principais linhas de tendência, Sendo o suporte o limite inferior atingido pelos preços do ativo durante um intervalo de tempo especificado e a resistência o limite superior. O suporte, ainda segundo os autores, representa a condição do mercado em que as forças de compra superam a pressão de venda, de modo que quando um preço atinge o suporte ele tende a retrair. Já a resistência representa a condição do mercado em que as forças de venda superam a pressão de compra. Essas tendências, porém, não são impostas por regras do mercado, são comportamentos observados e que se repetem ao longo da história, podendo haver o rompimento de um suporte ou resistência a qualquer momento.

A operação com está técnica pode se dar de duas formas. A primeira busca operar na área interna entre os limites de suporte e resistência do intervalo analisado. Nesse sentido toda vez que o preço do ativo está na região da resistência deve ser feita uma operação de venda, pois a tendência é de queda, já quando o preço encontra-se na região de suporte a operação a ser realizada é a de compra, pois a tendência é de subida. A segunda forma de operar com esta

técnica é considerar o rompimento do suporte ou da resistência. Quando o suporte é rompido espera-se que ocorra uma tendência de queda devendo ser realizada uma operação de venda, já se a resistência for rompida espera-se uma tendência de alta, logo uma operação de compra. Nos casos em que há rompimento a tendência rompida transformam-se na contrária, ou seja, o suporte vira resistência e a resistência vira suporte, como apresentado na Figura 4.

Figura 4 – Exemplo de Suporte e Resistência.



Fonte: Adaptado de Traders (2017).

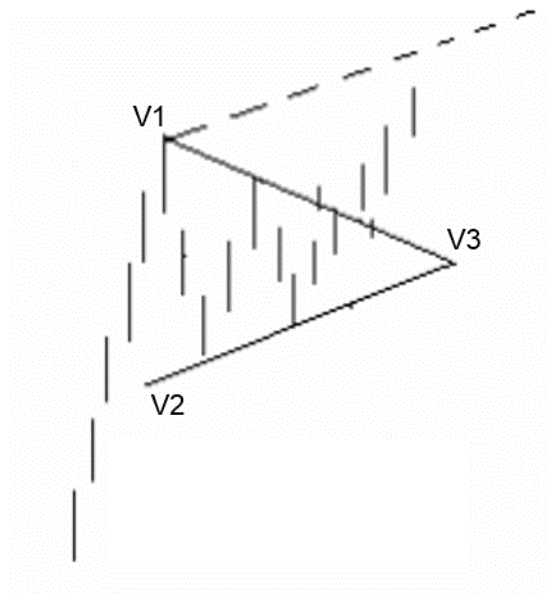
2.3.2 Triângulos

Outra técnica, não tão famosa, mas de fácil aplicação e derivada dos suportes e resistências é a técnica do triângulo. Conforme Penteadó (2003), os triângulos "podem ser interpretados como característicos de fases de hesitação do mercado".

A formação desta técnica se dá por topos descendentes compondo uma tendência de baixa e fundos ascendentes compondo uma tendência de alta. Nesta etapa da formação do padrão o volume tende a se reduzir, voltando a subir no momento do rompimento do triângulo que deve ocorrer entre 2/3 e 3/4 da distância entre o vértice do triângulo e o primeiro topo ou fundo da tendência que foi rompida, de acordo com Penteadó (2003). A Figura 5, apresenta os três vértices do triângulo, sendo que o rompimento poderia se dá entre os vértices V1 e V3 ou V2 e V3. A tendência de alta fica identificada pela formação do primeiro vértice, que no

caso é o V1, vértice esse que configura-se como um topo, esse é o primeiro topo que inicia uma tendência de topos descendentes que serão usados para formar o triângulo. A partir da formação do primeiro vértice é necessário realizar uma intercalação entre topos e fundos para se identificar os topos descendentes e os fundos ascendentes. A projeção da reta dos topos e a projeção da reta dos fundos leva a um encontro de retas produzindo o vértice V3.

Figura 5 – Confirmação de Alta.



Fonte: Adaptado de Penteadó (2003).

Segundo Rockefeller (2016), o padrão triângulo pode ser classificado como um padrão de continuação, ou seja, dada uma tendência, após a formação e rompimento do triângulo nas condições determinadas pelo padrão é maior a probabilidade de que a tendência anterior a formação do triângulo se mantenha.

2.3.3 Retrações de *Fibonacci*

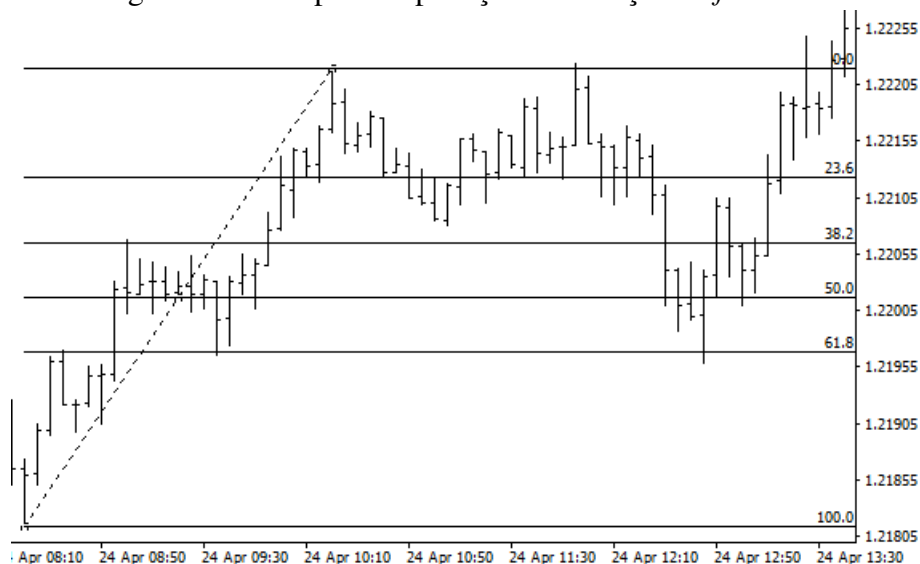
As retrações de *fibonacci* (também utilizado no singular) são uma das formas de análise técnica. Essa técnica é derivada da famosa sequência de *fibonacci*, descoberta pelo matemático italiano do século XIII, Leonardo Fibonacci. Sendo considerada uma sequência de autorreplicação, como afirmado por Rockefeller (2016), que se inicia com 1, 1, 2, 3, 5, 8, 13, etc. sem um limite final e definida pela Função 2.1.

$$F_n = F_{n-1} + F_{n-2} \quad (2.1)$$

O interessante desta sequência é que é possível extrair entre dois números seguidos uma proporção que se aproxima de 1,618, a famosa proporção áurea, ou em situação inversa 0,618. E a partir desta proporção é possível extrair outros valores de proporções.

No início do século XX, Ralph Nelson Elliott apresentou para o mundo a possibilidade de utilização das proporções da sequência de *fibonacci* no mercado financeiro (TAYLOR, 2010). Várias são as abordagens possíveis com as proporções extraídas da sequência uma das mais aplicadas é a da retração. A retração de *fibonacci* estabelece que dado a movimentação do mercado em uma tendência, uma vez que cesse a tendência, a retração que se dará tende a atingir e/ou respeitar os patamares das proporções de *fibonacci*, sendo eles 23,6%, 38,2%, 50%, 61,8%, além de 0 e 100% que corresponde a amplitude total da tendência anterior. O valor de 50% não é extraído da sequência, sua introdução se dá pela influência do padrão de Gann.

Figura 6 – Exemplo da aplicação da retração de *fibonacci*.



Na Figura 6 é possível observar um exemplo da aplicação do padrão. Há uma tendência representada pela linha tracejada que cessa seu movimento dando início a uma retração. Inicialmente as cotações tendem a se concentrar em torno do patamar de 23,6%, avançando na retração até encontrar o patamar de 61,8%, após esse patamar a tendência anterior é retomada finalizando a retração. A finalização da retração fica clara pela elevação das cotações acima do patamar de 0%. No caso da Figura analisada houve uma retração ao nível de 61,8%.


Todos os padrões descritos nesta seção são passíveis de codificação, no entanto, sua confirmação só se dá após o tempo vigente em se pode realizar uma ordem no mercado. Sendo assim, a utilização de técnicas avançadas de computação como as redes neurais artificiais podem

proporcionar uma antecipação da formação dos padrões e logo uma previsão do comportamento do mercado.

3 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais, ou simplesmente redes neurais, como apresentadas por Carvalho (2017) apresentam capacidade de aprendizagem e generalização de forma adaptativa e não-linear a partir de um processo de treinamento baseado em entradas condizentes com o problema que se espera resolver através da rede. O primeiro modelo de neurônio artificial foi criado por McCulloch e Pitts (1943) e está representado de forma adaptada por Bortoli (2015) na Figura 7.

Figura 7 – Modelo de Neurônio Artificial (Adaptado de: Haykin (2001, p. 36))



Fonte: (BORTOLI, 2015).

A figura apresenta a estrutura básica de um neurônio que é dividida em:

- Sinapses: Cada sinal x_j deve passar por uma sinapse, que possui um peso w_{kj} , onde k refere-se ao neurônio que está conectada e j ao sinal de entrada. O sinal de entrada é multiplicado por esse peso e então repassado para o próximo elemento do neurônio.
- Junção aditiva: Realiza uma soma dos sinais após passarem pelas suas respectivas sinapses.
- Função de ativação: Processa o resultado da soma para restringir o valor em um intervalo. O resultado gerado é conhecido como saída do neurônio, que pode servir como entrada para outros neurônios ou como saída da rede.

Quando agrupados em camadas, o conjunto de neurônios artificiais formam um rede neural artificial. Haykin (1998) apresenta a seguinte definição para rede neural:

“Uma rede neural é um processador massivamente paralelo e distribuído, composto de unidades de processamento simples, que tem uma propensão natural para armazenar conhecimento adquirido pela experiência, tornando-o disponível para uso.”

Uma rede neural sempre apresenta uma camada de entrada e uma camada de saída. Entre essas camadas pode ser alocado um número indeterminado de camadas intermediárias, também conhecidas como camadas ocultas.

De forma simplificada e sob a ótica da matemática uma rede neural é como uma função polinomial, cujos coeficientes são descobertos através do processo de treinamento. Uma vez treinada, todos os coeficientes já estão identificados e é possível utilizar a rede como se fosse uma função que dado um certo grupo de entradas gera uma saída específica.

O processo de treinamento, também conhecido como aprendizagem, é vital para o sucesso da rede neural. Uma das mais conhecidas técnicas computacionais para treinamento de redes neurais é o algoritmo *backpropagation*. Esse algoritmo que é classificado como de treinamento supervisionado, consiste em um processo de correção dos pesos sinápticos, a partir da camada de saída até a camada de entrada de acordo com o erro produzido entre o resultado do processamento da rede e a saída esperada.

Outro ponto fundamental para a rede neural é a configuração aplicada. Não há, até o presente momento, um método para determinação do número de neurônios em cada camada, nem mesmo o número de camadas. Dessa forma os testes e experimentações são a prática mais comum para determinação da configuração de um rede. Outros fatores, no entanto, como o tipo de função de ativação a ser utilizada, os tipos de neurônios e de redes possuem satisfatória fundamentação.

3.1 FUNÇÃO DE ATIVAÇÃO

As funções de ativação são parte integrante dos neurônios como foi apresentado na Figura 7, e como afirma Facure (2017) "as funções de ativação introduzem um componente não linear nas redes neurais, que faz com que elas possam aprender mais do que relações lineares entre as variáveis dependentes e independentes".

Várias são as possibilidades de utilização de funções de ativação, porém com o avanço dos estudos em RNAs algumas funções se destacaram. Facure (2017) apresenta um estudo comparativo do comportamento das funções Sigmoides, Tangente Hiperbólica (TanH), Unidade Linear Retificada (ReLU), Unidade Linear Retificada com Vazamento e Unidade Linear Exponencial (ELU). Nesse estudo, Facure (2017), verifica o comportamento das funções através da derivada destas, revelando a razão de algumas funções serem mais eficazes que outras.

A função Sigmóide, bem como a Tangente Hiperbólica, representadas pelas Funções

3.1 e 3.2, respectivamente, apresentam o problema de saturação, de acordo com Facure (2017), sendo que a TanH aproxima-se mais da identidade.

$$S(t) = \frac{1}{1 + e^{-t}} \quad (3.1)$$

$$\tanh(t) = \frac{e^t - e^{-t}}{e^t + e^{-t}} \quad (3.2)$$

A função ReLU consegue ser mais eficiente que as funções sigmóide e a TanH, pois a derivada desta função se mantém estável em 0 ou 1. Essa função é uma das grandes responsáveis pela popularização da *Deep Learning*, como afirma Facure (2017), havendo como defeito a "morte" de alguns neurônios que passam a produzir apenas 0 como saída.

Em virtude da falha gerada pela função ReLU, foi desenvolvida a função Unidade Linear Retificada com Vazamento, que resolve o problema dos neurônios mortos, mas cria um hiper parâmetro chamado de vazamento.

A última função do estudo foi a ELU, que também resolve o problema dos neurônios mortos, no entanto, apresenta uma saturação na região negativa, mas que na prática não é significativa. A função ELU é apontada em estudos como sendo a mais eficaz, apesar de resultados do próprio estudo indicarem que a ReLU tem desempenho praticamente igual a ELU, levando a escolha da ReLU para realização deste projeto.

Além da função de ativação outro ponto de grande importância é o tipo de rede a ser utilizada. Considerando o problema da predição de séries temporais um tipo de rede que vem recebendo grande destaque é a Rede Neural Recorrente (RNR), como visto em Carvalho (2017).


3.2 REDE NEURAL RECORRENTE

Considere um jogador de basquete arremessando uma bola de basquete na cesta. Em condições ideais seria possível calcular a trajetória da bola através de uma fórmula física, para isso seria necessário conhecer a força de arremesso, a direção, o sentido, o peso da bola e a gravidade no local. No entanto, boa parte da população que já teve a oportunidade de ver um arremesso anteriormente, não necessariamente de uma bola de basquete, consegue prever o local em que a bola irá parar, sem realizar qualquer cálculo físico de forma consciente. Essa previsão, porém, não se faz observando a bola em um único instante de tempo, é necessário observar um

conjunto de instantes de tempo da bola de modo a formar uma memória da trajetória percorrida, em que o instante anterior necessariamente influencia o instante atual.

O exemplo apresentado tem o intuito de facilitar a compreensão da Rede Neural Recorrente. Essas redes possuem especial vocação para tratar problemas relacionados com sequências e listas, apresentando resultados melhores que as redes tradicionais.


Figura 8 – Arquitetura básica de uma RNN e seu *loop*.



Fonte: (OLAH, 2015).

Para entender a RNR é necessário compreender sua estrutura interna, sendo assim a Figura 8 exibe uma unidade de uma RNR chamada A, recebendo como entrada X_t e retornando o valor de saída H_t . Há ainda um loop que transmite a informação de um ponto da rede para outro. Apesar de aparentemente mais complexa, uma RNR pode ser melhor explicada quando pensa-se de forma convencional, levando em consideração que uma RNR nada mais é que múltiplas cópias de uma mesma rede, cada uma destas passando informação para sua sucessora (OLAH, 2015), como se pode observar na Figura 9.

Figura 9 – Representação da arquitetura RNN com seu loop expandido.




Fonte: (OLAH, 2015).

É difícil citar RNRs sem mencionar uma das arquiteturas mais utilizadas e que atualmente tem dado resultados significativamente melhores quando comparados ao modelo padrão de rede neural recorrente, as redes *Long Short Term Memory*. Também conhecida como

LSTM, essa arquitetura particular de RNR foi apresentada por Hochreiter e Schmidhuber (1997) visando resolver principalmente o problema das dependências de longo prazo.

Figura 10 – Representação interna de um módulo que compõe a arquitetura LSTM.



Fonte: (OLAH, 2015).

De forma simplificada, pode-se ver na figura 10 um bloco LSTM. Esse tipo de rede tem a capacidade de remover ou adicionar informação numa estrutura chamada *cell state*, representada pela linha horizontal que passa por toda parte superior do diagrama. Para questão de entendimento, pode-se fazer analogia a *cell state* com uma correia de transporte, onde a informação trafega passando apenas por algumas interações lineares como operações de soma e multiplicação. Essa capacidade da rede é regulada por outra estrutura, os *gates* ou portões. *Gates* oferecem uma forma opcional de tráfego da informação. Eles são compostos de uma camada de rede neural sigmóide, representada com o retângulo amarelo com o símbolo sigma, e uma operação de multiplicação. Um bloco LSTM tem três desses *gates*, para proteger e controlar a *cell state*.

Um dos principais motivos que torna as redes neurais recorrentes tão amplamente utilizadas é a possibilidade de operação baseando-se em sequências de vetores. Essas sequências podem ser utilizadas como forma de entrada, saída ou em casos mais gerais entradas e saídas, viabilizando a previsão de fragmentos de séries temporais do mercado *Forex*.

A partir deste ponto, todo o referencial teórico necessário foi abordado. As séries temporais, o ambiente de extração, que é o *Forex*, a abordagem de previsão, que são os padrões de análise técnica e a técnica computacional, que são as redes neurais recorrentes, no presente trabalho, interagem de forma a gerar um agente de previsão de tendências.

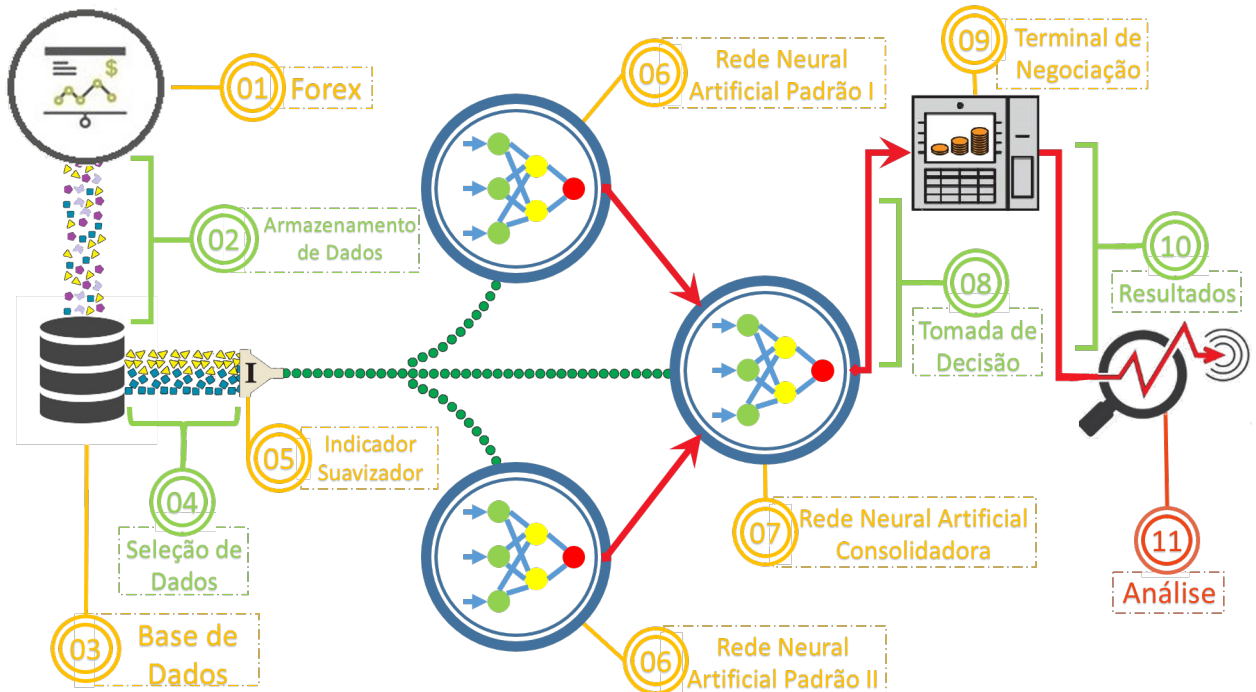
4 CÉRBERO

A proposta metodológica que buscou responder ao questionamento norteador deste trabalho de pesquisa foi denominada de Projeto Cérbero ou simplesmente Cérbero.

Cérbero é o famoso cão tricéfalo da mitologia grega. Sendo conhecido, também, como *Cerberus* ou *Kerburs*, essa criatura guardava os portões do *Hades*, buscando evitar a saída dos mortos e a entrada dos vivos. A associação da criatura com este trabalho de pesquisa se deu exclusivamente pelo coincidente número de cabeças, por parte do Cérbero, e de redes neurais artificiais por parte do projeto, ainda que o padrão suporte e resistência tenha sido dividido em duas redes por questões técnicas.

Para atingir o objetivo proposto foi idealizado um modelo que contemplou desde o processo de aquisição dos dados do mercado *Forex*, até a análise do resultados simulados, com base nas métricas definidas. A Figura 11 apresenta de forma simplificada e objetiva o modelo implementado. Buscou-se estabelecer uma relação sutil com um grafo, em que é possível notar elementos na função de nós e fluxos na função de arestas.

Figura 11 – Modelo de elementos e fluxos do Projeto Cérbero.



O modelo apresentado na Figura 11 buscou representar os softwares e processos que compõem o Cérbero. Atribuiu-se aos softwares a categoria de elementos, havendo sido

representados pelas numerações de cor laranja amarelado, que são por tanto 01, 03, 05, 06, 07 e 09. Já os processos, foram categorizados como fluxos, obtiveram a cor verde e correspondem as numerações 02, 04, 08 e 10. Por fim, é apresentado um elemento identificado como análise, na cor vermelha e de numeração 11. Ainda que seja um processo, optou-se por dar especial destaque a análise, devido à sua importância para a validação do Cérbero enquanto estratégia para previsão de séries temporais no mercado financeiro.

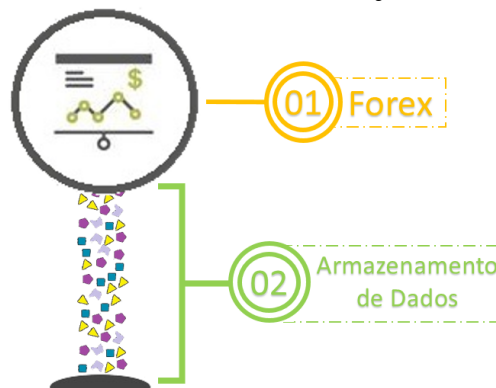
É importante salientar que o modelo da Figura 11 apresenta um estado específico do Cérbero, em que o processo de treinamento e validação das redes neurais artificiais já foi realizado. Buscou-se gerar a perspectiva de transferência contínua de dados, tal qual deveria ocorrer em condições reais de análise de séries temporárias do mercado *Forex*.

Uma vez esclarecido o funcionamento geral do modelo, faz-se necessário explorar os elementos e fluxos apresentados. Para tanto foram elaboradas as seções 4.1 *Forex* e o Armazenamento de Dados, 4.2 Base de dados e a Seleção de Dados, 4.3 Indicador Suavizador, 4.4 Redes Neurais e Tomada de Decisão, 4.6 Terminal de Negociação, Resultados e Análise.

4.1 FOREX E O ARMAZENAMENTO DE DADOS

No contexto do projeto Cérbero, o *Forex* apresenta-se como ambiente de extração das séries temporais. Apesar de o *Forex* ser um mercado de negociação de par de divisas, e por tanto, mais que um software, neste modelo ele foi representado como um elemento, como pode ser visto na Figura 12. Optou-se por este tipo de representação devido ao fato de a intermediação dos demais componentes do Cérbero com o mercado se dá através da plataforma *MetaTrader*®, já apresentada no Capítulo 2.

Figura 12 – Modelo de elementos e fluxos do Projeto Cérbero ampliado 01 e 02.



O processo de armazenamento de dados consiste na captura das cotações *tick by tick*.

Para tanto, podem ser aplicados dois procedimentos: *Expert Advisor* para captura dos *ticks* do mercado em tempo real ou consulta à base de dados disponibilizada por corretoras do mercado *Forex* através de seus portais online.

Considerando a existência de dois estados para o Cérbero, estado de treinamento de redes neurais e estado de pleno funcionamento do projeto, há uma adequação maior para cada procedimento de armazenamento mencionado.

No estado de treinamento de redes neurais o mais adequado é resgatar as cotações das bases de dados das corretoras. A viabilidade do processo de treinamento exige um número limitado de dados que serão aprendidos pela RNA. Sendo assim capturar os dados das próprias corretoras gera economia de tempo e permite a seleção do período desejado, de modo a garantir uma base de dados satisfatória para o treinamento.

Já no estado de pleno funcionamento do projeto, o mais adequado é utilizar um *Expert Advisor*. Isso se justifica pela garantia de dados reais, uma vez que as cotações estão sendo capturadas em tempo real e de forma contínua.

Os dados utilizados para as redes neurais foram coletados da base de dados históricos fornecidos pela corretora *Dukascopy* disponível na seção *Historical Data Feed* do portal online da corretora. O procedimento de coleta de dados se deu através dos seguintes passos: Escolha do par de moedas *Euro vs US Dollar*, conhecido pela sigla EURUSD; Escolha da série temporal cujos dados seriam apresentados, havendo sido escolhida a série *Bid*, pois essa é a série representada pelo *MetaTrader®* (ferramenta de negociação) em modo *default*; Escolha da unidade e contagem base de representação dos dados, havendo sido escolhido minuto como unidade e 1 como contagem, isso significa que o arquivo de dados gerado apresentaria barras de dados a cada um minuto; Escolha do filtro a ser aplicado, neste caso foi aplicado o filtro de finais de semana, uma vez que mesmo havendo operação durante os finais de semana, os pequenos investidores não tem acesso a negociação nestes períodos, de modo que eles apresentam cotação constante e volume zero, não sendo necessário para este projeto; Escolha do horário de início do dia, podendo optar por UTC (do inglês *Universal Time Coordinated*) referência para calcular as zonas horárias do mundo ou EET (do inglês *Eastern European Time*) que tem como referência as capitais dos países da Europa Oriental como Istambul ou Moscou, optou-se pelo UTC; Escolha GMT (do inglês *Greenwich Mean Time*) como zona de referência; Por fim foi definido o período de tempo que se deseja fazer o download e dados, neste caso foi feito o processo para cada mês desde de Janeiro de 2014 a Dezembro de 2017, especificando a data de início e fim de cada mês.

Uma vez definidos os parâmetros para a seleção dos dados da base histórica fornecida pela corretora foi possível realizar o download dos arquivos em formato csv e armazená-los para posterior seleção como especificado pela seção seguinte.

4.2 BASE DE DADOS E A SELEÇÃO DE DADOS

A formação de uma base de dados se faz necessária para reaproveitamento dos dados para os diferentes treinamentos, bem como para manter uma rastreabilidade entre os movimentos que de fato se deram no mercado e o resultado do processamento das RNAs. Os dados armazenados, por tanto, devem seguir para o *MetaTrader®* para que seja aplicado o indicador suavizador. É possível, no entanto, que alguns dados não estejam adequados para serem utilizados pela ferramenta de negociação, mesmo com os filtros aplicados pelo próprio portal da corretora, fazendo necessário uma nova seleção. A Figura 12 apresenta a chegada dos dados do *Forex* para a base de dados, a Figura 13, porém apresenta os dados processados e organizados seguindo para a próxima etapa, processamento este fruto da seleção de dados realizada nesta etapa.

Figura 13 – Modelo de elementos e fluxos do Projeto Cérbero ampliado 03 e 04.



Na etapa de seleção dos dados foi utilizado um software proprietário que formata dados dos arquivos recuperados do site da corretora de modo adequado para a leitura da ferramenta de negociação além de retirar os período em que o volume está zerado. Neste caso a seleção de dados se dá dentro dos arquivos, retirando alguns dados, normalmente o horário das 21h após os finais de semana haja visto que o mercado ainda não voltou a operar nesse horário e o volume é zero.

Há ainda uma seleção entre os arquivos de meses. Alguns meses apresentaram

volume de negociação muito acima do normal de modo que a própria ferramenta de negociação não consegue executar fazendo uso destes dados. Neste caso os meses de Janeiro de 2014 e Dezembro de 2017 não foram utilizados no projeto, ainda que tenham sido armazenados.

Após esta etapa, com os dados devidamente tratados e selecionados foi possível seguir para a etapa do indicador suavizador, fundamental para o funcionamento do projeto.

4.3 INDICADOR SUAVIZADOR

Os dados selecionados seguem para o indicador suavizador. O volume de dados em um minuto do *Forex* pode conter centenas de valores, o que torna inviável fornecer os dados direto do mercado, dado o número de neurônios necessários para o processamento. Sendo assim o processo de suavização busca condensar a informação em um determinado período de tempo trazendo a tona a tendência predominante naquele período. Além disso a suavização consegue promover uma padronização das entradas da rede que servem tanto para facilitar o processo de previsão, quanto para compreender o que ocorre no mercado e assim fazer correções no Cérbero.

O indicador proposto neste trabalho baseia-se no indicador baseado em diferenças de primeira ordem proposto por Bortoli (2015), com modificações. O indicador proposto por Bortoli (2015) trabalhava com *ticks*, neste projeto foi utilizado o tempo gráfico de um minuto. Além disso utilizou-se os valores de *high* e *low* de cada barra do tempo gráfico de um minuto para formar os picos e vales.

Em seu indicador, Bortoli (2015) apresenta sequências de variações que ele denomina de SEQ e define como "observação de variações consecutivas em um mesmo sentido (apenas positivas ou negativas)". Cada SEQ é constituída pelo somatório das diferenças de primeira ordem de suas observações, como apresentado na Figura 14, sendo ainda classificadas como expressivas ou inexpressivas segundo um dos parâmetros de retorno financeiro utilizados. O valor zero não provoca a geração de uma nova SEQ, ficando por tanto incluído na SEQ vigente no momento de sua ocorrência.

Para além de ser um método para entendimento da evolução das séries temporais do *Forex*, o conjunto das diferenças de primeira ordem que correspondem as SEQs acabam por definir as tendências assumidas pela série em cada momento. Desse modo, as mudanças do tipo de SEQ (positivas ou negativas), acabam por definir pontos de reversão, que podem ser interpretados como máximos e mínimos locais.

Santos (2009), apresenta máximos e mínimos locais como sendo:

Figura 14 – Exemplo de funcionamento das SEQs, contabilizando três SEQs positivas e três SEQs negativas.




Fonte: (BORTOLI, 2015)

Definição 1 Dada uma função f , seja $c \in D(f)$, temos que:

1. f possui um máximo local em c se existe um intervalo aberto I contendo c , tal que $f(c) \geq f(x)$ para todo x em $I \cap D(f)$.
2. f possui um mínimo local em c se existe um intervalo aberto I contendo c , tal que $f(c) \leq f(x)$ para todo x em $I \cap D(f)$.

Considerando intervalos que correspondem a região formada por duas SEQs seguidas de tipos diferentes, positiva e negativa ou negativa e positiva, temos como máximo e mínimo locais o ponto de reversão entre as SEQs. Havendo ainda a especificidade de que para o máximo o ponto de reversão está entre uma SEQ positiva e uma negativa, nessa ordem, enquanto que para o mínimo está entre uma SEQ negativa e uma positiva, também nessa ordem unicamente.

Figura 15 – Exemplo da formação de Picos e Vales utilizando a técnica derivada de Bortoli (2015).



A Figura 15 apresenta o resultado gráfico de uma implementação realizada na linguagem MQL4 utilizando a plataforma de negociação *MetaTrader*. A imagem apresenta uma janela de sessenta barras, delimitada pelo retângulo vermelho. Dadas essas barras são identificadas as SEQs positivas e negativas utilizando os valores de *high* e *low*, de modo independente, a partir da barra mais recente completamente formada, ou seja, a barra um, até a barra sessenta. Para melhor visualização foram traçadas retas em tendência representando as SEQs formadas, sendo as azuis

positivas e as vermelhas as negativas. Considerando apenas os pontos de reversão produzidos pelas análises dos valores de *high* são formados o que nesse projeto foi denominado de picos, por outro lado, considerando apenas os pontos de reversão produzidos pela análise dos valores de *low* são gerados os vales. Por fim, cada pico ou vale recebeu uma etiqueta indicando a ordem de ocorrência, seguido de *underline* e a ordem da barra que corresponde ao ponto de reversão.

Os picos e vales identificados serão sempre os mesmos para as mesmas janelas, o que garante estabilidade dos dados. Nesse ponto é necessário uma variação do tratamento dos picos e vales, também denominados de vértices, em três abordagens para seguir para a etapa de treinamento das redes.

4.3.1 Vértices Originais

A simples identificação dos picos e vales resulta na formação dos vértices originais. Esses vértices são importantes pois são a base para a identificação do padrão de suporte e resistência. Neste caso poderiam ser formadas sequências exclusivas de picos e sequências exclusivas de vales independentes umas das outras.

4.3.2 Vértices Intercalados

A formação dos vértices intercalados se dá pela intercalação de picos e vales a partir da ocorrência mais antiga entre eles. Para tanto, os vértices são posicionados em dois vetores, de mesmo tamanho da janela de barras, um destinado aos picos e outro aos vales, de acordo com a posição em que ocorreram na janela. Verifica-se qual a primeira ocorrência entre os vetores e a partir desta se constrói um vetor único sempre alternando as posições, ou seja, se começou com um pico a próxima posição necessariamente será o vale imediatamente seguinte ao pico e em seguida o pico imediatamente seguinte ao vale e assim por diante. Desta forma, mesmo que antes do vale imediatamente seguinte haja mais de um pico, estes serão ignorados pois o que se busca neste momento é o vale imediatamente seguinte.

4.3.3 Vértices em Macrotendência

A formação dos vértices em macrotendência se dá por um processo que combina os vértices originais e os intercalados. Neste caso partindo da ocorrência mais antiga entre picos e vales dentro da janela verifica-se duas condições: Se for iniciado com um pico verifica-se se o

próximo pico é superior ou inferior ao pico atual, se for superior verifica-se o próximo pico, se for inferior busca-se o vale imediatamente seguinte; No caso dos vales verifica-se o se o vale seguinte é superior ou inferior, se for inferior verifica-se o próximo vale, se for superior busca-se o pico imediatamente seguinte. Desta forma encontra-se a intercalação entre os máximos dos máximos e os mínimos dos mínimos locais, formando as macrotendências.

4.3.4 Matriz de Vértices

Definidas as possíveis configurações em que os vértices podem ser apresentados é necessário padronizar o formato de saída dos dados do indicador suavizador. Nesse sentido optou-se pela configuração de matrizes de vértices, que corresponde a apresentação dos vértices em uma matriz cujas posições não ocupadas são representadas por zero.

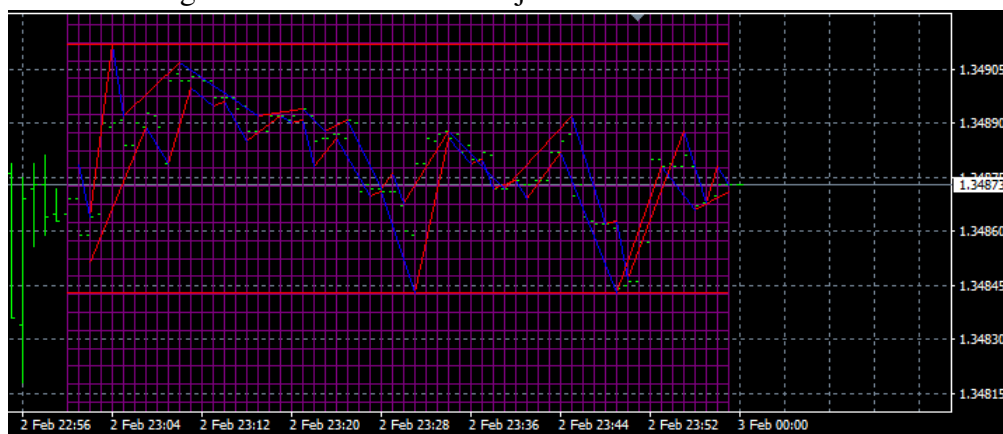
A matriz de vértices acompanha a janela de barras e portanto é deslizante, no entanto, enquanto a janela de barras apresenta amplitudes variadas de acordo com o máximo e mínimo de cada janela, a amplitude da matriz de vértices se mantém constante ao longo de toda a execução. A determinação da amplitude dessa matriz se deu através de um estudo de todos os períodos analisados para este projeto.

Devido a impossibilidade de se analisar o período completo de quatro anos juntos, uma vez que quando o *MetaTrader*® atinge determinada quantidade de dados históricos os mais antigos são descartados, foram feitas análises por mês de todo o período. Foi desenvolvido um programa em linguagem MQL4 cuja função era recriar as janelas de barras de modo a verificar a amplitude dessas janelas e armazenar cada uma das observações de cada mês em um arquivo csv. Uma vez que o armazenamento de dados havia sido feito foram identificados alguns elementos estatísticos para cada mês: Cotações máxima e mínima do mês, maior e menor amplitude dentre as janelas do mês, média de amplitude, moda de amplitude, desvio padrão de amplitude, mediana de amplitude e número de ocorrências de cada amplitude. Em posse destes elementos estatísticos foi possível descobrir qual a porcentagem de janelas que eram cobertas por alguns valores de amplitude, sendo eles as ocorrências até a moda, as ocorrências até a mediana, ocorrências até a mediana somada ao desvio padrão, além dos valores de 300 e 500 de amplitude, que neste caso corresponde ao mesmo valor em pips.

Buscando abarcar o maior número de janelas possível optou-se pelo valor de amplitude que tivesse o maior valor de porcentagem, que no caso foi o de 500 pips, responsável por no mínimo 90% das janelas analisadas. A matriz de vértices se inicia 250 pips acima da metade

da primeira janela do mês e vai até 250 pips abaixo da metade da primeira janela do mês. Os limites da matriz só são alterados quando os valores ultrapassam as fronteiras superior ou inferior estabelecidas anteriormente, nestes casos a mudança se dá apenas no valor da diferença em que a matriz foi ultrapassada. A Figura 16 apresenta um recorte de uma janela de matriz de vértices, sendo a matriz representada pelas linhas de cor roxa, sessenta verticais e 100 horizontais, sendo as horizontais espaçadas por 5 PIPs que é justamente o limite máximo para a formação de um suporte ou resistência. O surgimento de um pico ou um vale em dos quadrantes da matriz é que faz com que esse quadrante receba um valor diferente de zero.

Figura 16 – Recorte de uma janela de matriz de vértices.



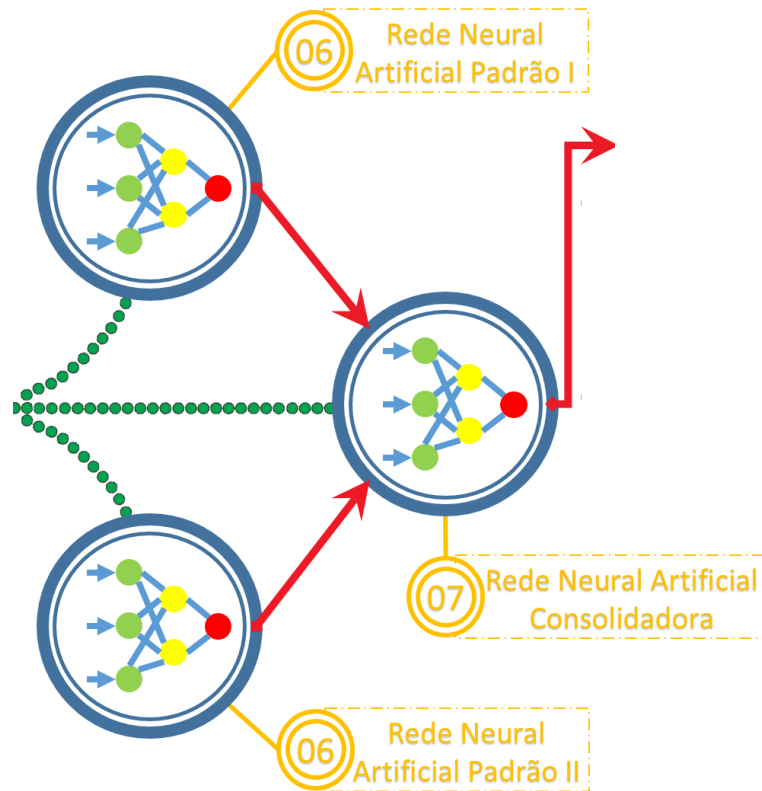
4.4 REDES NEURAI E TOMADA DE DECISÃO

O cerne do projeto Cérbero são suas redes neurais artificiais. O grande diferencial aqui descrito é a utilização de três RNAs especializadas em atividades diferentes que se unem em determinado ponto para definir qual ação deve ser tomada. Todas as redes são responsáveis pela identificação de um padrão de análise técnica já apresentado no Capítulo 2, na seção 2.3.

Para melhor entendimento da proposta uma analogia válida é com a música. Cada nova música configura-se como uma composição única de notas musicais tocadas por diferentes instrumentos, em ordens diferentes, podendo ainda haver a adição de canto ou declamações. Dadas as múltiplas possibilidades, identificar a qual estilo musical, ou a mensagem pretendida ou ainda as possíveis sensações que a música transmite não é uma tarefa trivial. Pode-se supor, portanto, que um indivíduo que precise realizar uma das atividades anteriores iria buscar entender a melodia, em seguida a letra e por fim a composição destas duas. Ou seja, dado um mesmo sinal de entrada este sinal seria analisado sob aspectos diferentes, ignorando o que fosse necessário a

dependendo do aspecto analisado. Neste trabalho realizou-se algo semelhante, em que dado um mesmo sinal de entrada cada uma das redes o analisou sob a luz de um aspecto complementar, adquirido pelo treinamento.

Figura 17 – Modelo de elementos e fluxos do Projeto Cérbero ampliado 06 e 07.



Como sugerido na Figura 17 o resultado do indicador suavizador, segue para as três redes da arquitetura, deixando para cada rede a função de identificar a existência de um padrão. Para tanto, no processo de treinamento das redes Padrão I e II foram identificados, com o uso de *Expert Advisors* especialmente desenvolvidos para tal finalidade, os padrões de análise técnica de suporte e resistência e o de triângulo respectivamente. Com base nesses padrões os conjuntos de treinamento foram estruturados e passados como *inputs* ou entradas para as RNAs, sendo cada entrada associada a uma saída esperada, que varia de acordo com o padrão. No caso da rede Padrão I foram gerados dois tipos de saída, a primeira que podia assumir os valores 0 ou 1, indicando se o padrão de suporte ou resistência vigente no momento será respeitado ou não, já o outro tipo de saída informava qual o valor dentro da matriz de vértices em que estava se dando o suporte ou a resistência, variando de 0 a 100 em valores inteiros. Para a rede Padrão II a saída esperada seria o sentido da macrotendência ocorrida após a formação do triângulo, com os valores -1 para tendências de baixa, 0 para estagnação e 1 para tendências de alta.

Apesar de cada rede ficar responsável por identificar um padrão de análise técnica, é possível identificar ao menos um subgrupo que é o das redes neurais artificiais Padrão I e II, cuja saída serve de entrada para a rede consolidadora, adicionando informações ao processamento que apenas a rede consolidadora poderia não obter.

4.4.1 Rede Neural Artificial Padrão I e II

As redes Padrão I e II se distinguem pelos padrões adotados por cada uma. Sendo o padrão de suporte e resistência para a rede I e o padrão triângulo para a rede II. A Figura 18 apresenta a identificação de suportes, como as regiões inferiores que servem de base para a série, e resistências que são as regiões superiores, que limitam a série.

Figura 18 – Identificação de suporte e resistência utilizando o *EA* desenvolvido.



O algoritmo desenvolvido para a identificação do suporte e resistência utilizou os picos e vales fornecidos pelo indicador suavizador. Neste caso os valores foram ordenados do maior para o menor, no caso dos picos, e do menor para o maior, no caso dos vales. Após a ordenação foi verificado quais valores apresentavam a menor diferença em módulo, dos mais antigos até os mais recentes na janela de sessenta barras. Para o que apresentasse a menor diferença, havendo uma limitação máxima de cinco *PIPs*, se verificava a possibilidade de realizar uma projeção até o início da janela, ou seja até o valor mais recentemente adicionado à série dentro da janela. Validado todos os requisitos considerava-se identificado um suporte ou uma resistência, que só seria rompido se os valores ultrapassassem a região identificada, ou se os valores que formaram a região de suporte ou resistência já não estivessem contidos na janela.

No caso do padrão de suporte e resistência optou-se por analisar dois tipos de saídas esperadas. O primeiro seria verificar se o padrão de suporte e resistência está ativo ou não na janela analisada, nesse caso as saídas esperadas são 1 para ativo e 0 para inativo. A abordagem do padrão ativo ou inativo pressupõe que durante a operação no mercado, encontrar a região de suporte e resistência não necessita dos recursos da inteligência artificial, no entanto, descobrir se

o padrão ainda pode ser considerado válido para aquela janela não é algo trivial e que necessita dos recursos de inteligência artificial. Já a segunda abordagem busca identificar qual o patamar em que está ocorrendo o padrão de suporte e o de resistência, mantendo, dessa forma, toda a estratégia de negociação atrelada à rede neural.

Cabe o esclarecimento de que o conceito de suporte e resistência não está vinculado a escala micro como trabalhado no algoritmo, de modo que seria mais apropriado tratar como micro suporte e micro resistência os elementos identificados pelo algoritmo. Porém, para evitar confusão de conceitos e termos, continuou-se tratando como suporte e resistência.

Figura 19 – Identificação de triângulos utilizando *EA* desenvolvido.



Já o padrão triângulo é apresentado pela Figura 19. O algoritmo de identificação do padrão triângulo baseia-se em uma intercalação dos picos e vales gerados pelo indicador suavizador, de modo que um pico seja sucedido apenas por um vale e vice versa. Uma vez realizada a intercalação é realizada uma busca por picos descendentes e por vales ascendentes pareados. Os picos descendentes formam então retas descendentes e os vales ascendentes formam retas ascendentes. Havendo a identificação do pareamento são identificados os primeiro e último pontos das retas descendentes e ascendentes, que são fundamentais para o cálculo do coeficiente linear dessas retas. Com base nos coeficientes é possível calcular um ponto de encontro da projeção das retas, que constitui o terceiro ponto do triângulo. Dessa forma o padrão triângulo é identificado.

No caso do padrão triângulo o esperado é a indicação de uma tendência de alta ou de baixa, dessa forma, as saídas esperadas seriam 1 para tendência de alta, -1 para tendência de baixa e 0 para quando não houver tendência. Essas saídas correspondem ao esperado pelo último triângulo formado na janela.

Em essência os Padrões I e II são formas de suporte e resistência, sendo que no Padrão II o suporte e a resistência estão em tendência e convergindo. As informações fornecidas por cada padrão são de grande valia para a previsão do mercado financeiro, pois enquanto o primeiro informa uma alta probabilidade de retração, o segundo informa uma alta probabilidade

de continuidade. A decisão de como utilizar essas informações é justamente uma tarefa que fica para a rede neural artificial consolidadora.

4.4.2 Rede Neural Artificial Consolidadora e a Tomada de Decisão

Uma das hipóteses que fundamentam este trabalho é que se uma tendência do mercado for realmente expressiva, poderá ser identificada por mais de um método, incluindo padrões de análise técnica diferenciados. Outra hipótese é que RNAs especializadas tendem a ser mais eficazes do que uma única rede que identifica múltiplas características. Dessa forma, a rede artificial consolidadora apresenta-se com a função de, com base no resultado do processamento das outras redes e da sua própria, definir qual ação tomar.

A rede consolidadora apresenta o padrão de análise técnica da retração de *fibonacci*. O algoritmo de identificação das retrações se vale dos dois padrões anteriores e das macrotendências. Considerando a formação de um triângulo, a macrotendência que finaliza imediatamente após o vértice do triângulo será considerada para análise da retração de *fibonacci* se sofrer uma retração ao atingir a região de um suporte ou resistência. Se a macrotendência referida atingir esses requisitos, então a amplitude da macrotendência imediatamente seguinte será analisada em termos de porcentagem em relação a macrotendência anterior para se determinar qual patamar de retração de *fibonacci* ocorreu.

No caso desse padrão as saídas esperadas correspondem as numerações atribuídas aos patamares da retração de *fibonacci* que são 0 para os casos sem retração, 1 quando o valor está entre 0 e 23,6%, 2 quando o valor está entre 23,6 e 38,2%, 3 quando o valor está entre 38,2 e 50%, 4 quando o valor está entre 50 e 61,8%, 5 quando o valor está entre 61,8 e 100% e 6 quando estiver acima de 100%.

O processo de treinamento da rede consolidadora só se deu após o treinamento das duas outras redes. Neste treinamento a rede consolidadora recebia as saídas esperadas associadas do treinamento das duas outras redes, bem como os *inputs* provenientes do indicador suavizador para que no treinamento da rede consolidadora conseguisse identificar a importância de cada padrão em cada situação.

Neste ponto é importante chamar a atenção para as entradas das redes neurais. No caso das de padrão I e II são apenas as provenientes da matriz de vértices, porém para a rede consolidadora, além da entrada proveniente pela matriz de vértices há ainda as saídas das outras duas redes que servirão de entrada para a consolidadora. Ocorre que a inserção das saídas

das outras redes na entrada da última acaba provocando um efeito de análise combinatória no treinamento e consequente processamento da última rede.

A tomada de decisão se dá logo após o processamento da rede consolidadora. Em posse do patamar de retração indicado pela rede, a tomada de decisão indicará para o *Expert Advisor* em qual cotação ele deve iniciar a ordem e em qual deve fechar. A cotação de início será o valor de suporte ou de resistência que se mantém ativo, de acordo com a tendência do triângulo, já o valor de fechamento será o início do patamar de retração indicado pela rede consolidadora.

Uma vez definida as redes, suas saídas esperadas e formas de interação é necessário criar a rede neural no que tange a sua programação e estruturação lógica, para tanto foi utilizado a biblioteca Keras do Python, bem como um conjunto de parâmetros específicos.

4.4.3 Parametrização

Os estudos de redes neurais ainda não conseguiram definir um método para parametrização das redes de acordo com o problema que estas terão que solucionar. Dessa forma é necessário aplicar a tentativa e erro, no entanto, é possível partir de condições já testadas em outros trabalhos. Para este trabalho partiu-se dos parâmetros apresentados por Carvalho (2017), demonstrados na tabela 2.

Tabela 2 – Configurações Utilizadas na definição e treinamento das redes neurais.

Parâmetro	Utilizado
Tipo de rede utilizada	LSTM
Taxa de aprendizagem do algoritmo	0.001
Tamanho do <i>batch</i> de treinamento	6
Número de camadas escondidas	1
Quantidade de unidades LSTM	64
Número de épocas	50
Função de ativação	Tangente Hiperbólica
Estratégia de Treinamento	Validação cruzada
Algoritmo de treinamento	Backpropagation
Função de Custo	Erro quadrático médio (MSE)

Dos parâmetros citados alguns são de grande relevância e mudam do trabalho desenvolvido por Carvalho (2017) e o desenvolvido no projeto Cérbero. O primeiro dos parâmetros apresentados é a taxa de aprendizagem que diz respeito a uma constante no intervalo de 0 a 1, essa taxa diz respeito à velocidade em que rede é capaz de aprender, logo um valor mais alto leva a um aumento da velocidade de aprendizagem, no entanto, valores altos tendem a causar

oscilação na mudança dos pesos sinápticos, de modo que o melhor valor é o mais alto que não gere oscilações. O segundo é o tamanho do *batch* de treinamento que diz respeito a quantos padrões de treinamento serão apresentados à rede antes que esta possa atualizar os pesos. O terceiro é o número de camadas escondidas, também conhecido como camadas ocultas, esse número diz respeito à quantidade de camadas existentes entre a camada de entrada e a de saída, camadas obrigatórias em todas as redes neurais. Por fim, o quarto é o número de épocas, que diz respeito a quantidade de vezes que todos os padrões de entrada serão apresentados à rede.

Apesar de partir da parametrização de Carvalho (2017), o processo de construção demonstrou a necessidade de mudança de alguns parâmetros. A começar pelo *batch* de treinamento, que ficou definido como 1, haja visto que cada entrada correspondia a um vetor de seis mil posições, aumentar o número de *batch* iria elevar consideravelmente o tempo de processamento, especialmente na fase de treinamento. Outro parâmetro modificado foi o número de camadas escondidas, que foi iniciado com pelo menos 2 camadas, haja visto que estudos posteriores indicaram que o aumento do número de camadas produziram resultados melhores. A quantidade de unidades LSTM foi iniciado com 4, variando para 8, 16 e 32. O número de épocas foi aumentado para 100 buscando uma melhoria nos resultados. Por fim, a função de ativação adotada foi a ReLU (do inglês *Rectified Linear Unit*).

4.4.4 Processo de Treinamento

Considerando o conjunto de dados gerado por cada algoritmo dos padrões foram divididos dois grupos, um de treinamento e outro de teste. O grupo que é destinado ao treinamento sofre uma nova divisão, que são os dados para o treinamento propriamente, que corresponde a 85%, e os dados para validação, que corresponde a 15%, já que o Keras utiliza o método da validação cruzada. Dessa forma, considerando que 70% do conjunto de dados seja destinado ao treinamento, temos que 59,5% é destinado ao treinamento propriamente, 10,5% é para validação e 30% para teste.

4.5 TESTES DAS REDES

Uma vez que a rede foi treinada é possível fazer previsões dos valores com base nos pesos estabelecidos. Foram feitos dois tipos de previsão, por tanto, a primeira utilizando-se do conjunto de dados usados para o treinamento, gerando assim as previsões do treinamento. A

segunda previsão foi feita com a parte do arquivo que não foi destinada ao treinamento, logo dados inéditos para a rede, gerando a previsão do teste. Nos dois casos é calculado o Mínimo Erro Quadrático, conhecido pela sigla do inglês MSE. Considerando que os dados da previsão de treinamento foram vistos pela rede estes apresentam um erro menor que os dados de teste, já que nunca foram vistos pela rede.

4.6 TERMINAL DE NEGOCIAÇÃO, RESULTADOS E ANÁLISE

As decisões tomadas pela arquitetura de múltiplas redes neurais serão encaminhadas para o terminal de negociação. Neste caso o processo ocorre da seguinte forma: Os dados são encaminhados para o terminal de negociação que através de um *Expert Advisor* gera um arquivo de dados correspondente à janela em vigor com dados trabalhados pelo indicador suavizador. Esse arquivo é lido pela arquitetura de redes que utiliza os dados como entradas. O resultado do processamento das redes é colocado em um arquivo que deve ser lido pelo *EA* para que com base no conteúdo do arquivo seja ou não tomada uma decisão.

Espera-se com o terminal, obter uma avaliação do desempenho do projeto, o mais próximo da realidade possível. Os resultados obtidos pelo terminal são os mesmos apresentados nas variáveis do relatório de negociação do Capítulo 2, que são totais de negociações, tempo médio entre negociações, porcentagens de negociações com lucro e com perda, lucro e perda, além da compensação esperada.

Por fim, os resultados obtidos do terminal foram analisados, tendo como objetivo responder ao seguinte questionamento: A utilização de um sistema com múltiplas redes neurais artificiais com a aprendizagem de padrões de análise técnica permite uma previsão lucrativa do mercado *Forex* mais assertiva do que a aleatoriedade?

Além do lucro ou prejuízo buscou-se avaliar a qualidade das previsões com as demais métricas, para verificar a viabilidade de aplicação do sistema em negociações reais.

5 RESULTADOS

A elaboração deste projeto exigiu vários recursos de software, não apenas as redes neurais artificiais, há ainda os códigos desenvolvidos para discretização dos dados do *Forex*, os códigos desenvolvidos para identificar os padrões de análise técnica, os códigos desenvolvidos para combinar as entradas com as saídas esperadas e os códigos para testar as respostas do Cérbero no mercado.

Em virtude do grande número de recursos envolvidos o projeto forneceu vários resultados que foram categorizados nas classes Resultados Estatísticos, Resultados de Processamento e Resultados de Execução.

5.1 RESULTADOS ESTATÍSTICOS

Os resultados estatísticos aqui apresentados pertencem a fase de pré-processamento, fornecendo informações para a tomada de decisões sobre a estruturação das entradas para as redes e as saídas esperadas.

O conjunto de dados históricos que foram armazenados para utilização no terminal de negociação totalizou 76,5 MB de arquivo texto. Esse corpo de dados produziu cerca de 1.430.440 janelas de dados, cada janela contendo 60 barras de um minuto e amplitude variável. A partir dos dados de amplitude, máximo e mínimo de cada uma das mais de um milhão de janelas foram obtidos os primeiros resultados estatísticos.

Tabela 3 – Dados Estatísticos das Janelas Produzidas.

Dado	Valor
Volume de Dados Históricos Armazenados	76,5MB
Total de Janelas Produzidas	1.430.440
Valor Máximo de Cotação	1,39933
Valor Mínimo de Cotação	1,03403
Maior Amplitude	3205
Menor Amplitude	7
Média de Amplitude	163
Moda	62
Mediana	127
Desvio Padrão	139

Para as entradas da rede optou-se pela formação de uma matriz apresentando apenas os picos e os vales. Essa matriz seria formada por 60 colunas, em função do tamanho definido da janela de dados, e por um número a ser definido de linhas. A definição desse número de linhas

depende do estudo estatístico apresentado pela Tabela 3.

O ideal seria que a matriz englobasse a maior amplitude encontrada para evitar valores que ultrapassassem essa matriz. Entretanto, considerando a maior amplitude apresentada no estudo fica claro que não é possível adotar esse valor por ser consideravelmente grande, gerando entradas com mais de 30 mil posições, sendo mais de 99% dessas posições são zeradas, pois não constituem picos e vales.

Considerando a Tabela 3 é possível optar pela Moda que é um valor muito menor que a maior amplitude, no entanto, a Mediana que corresponde ao valor que divide o conjunto em partes iguais, logo próximo dos 50% de ocorrências, acaba por descartar a Moda haja visto que a moda não abarcaria nem 50% das janelas formadas. Faz-se necessário, por tanto, um estudo para identificar a porcentagem de ocorrências de algumas amplitudes em todo o conjunto de janelas.

Tabela 4 – Ocorrências das Amplitudes das Janelas Produzidas.

Dado	Ocorrências
Até a Moda	14,7%
Até a Mediana	50,1%
Até a Média	64,5%
Até a Mediana + Desvio Padrão	86%
Até a Média + Desvio Padrão	89,6%
Até 300	89,4%
Até 500	97,3%

A Tabela 4 apresenta as porcentagens das ocorrências das amplitudes das janelas considerando as propriedades estatísticas apresentadas na Tabela 3, além de dos valores de 300 e 500 *PIPs*, que foram colocados a fim de se verificar o comportamento. As porcentagens a partir da Mediana acrescida do Desvio Padrão, abarcam número considerável de janelas, no entanto apenas com 500 *PIPs* de amplitude se consegue atingir a faixa dos 90% sendo que a amplitude de 500 só não contempla cerca de 2,8% das janelas, tornando esta amplitude a mais adequada para a produção da matriz.

Considerando o volume de dados dos quatro anos e em virtude do tempo de treinamento de cada rede neural que está em função, também, da quantidade de dados de entrada fornecidos, optou-se por um estratégia de treinamento que utilizaria o primeiro mês válido, por tanto fevereiro de 2014, deixando os demais meses para treinamentos ou testes futuros. Uma vez definido o mês a ser trabalhado mais resultados estatísticos foram produzidos.

Os primeiros resultados específicos do mês de fevereiro de 2014 dizem respeito aos elementos de análise técnica identificados, como apresentados na Tabela 5. Em relação

aos padrões de Resistência e Suporte é interessante identificar a proximidade dos valores das ocorrências, indicando que apesar de independentes é comum que as cotações respeitem esses limites superiores e inferiores em proporções próximas. Já no que diz respeito aos triângulos e macrotendências o que chama a atenção são os valores superiores que alcançam, o que se justifica pelo fato de que na formação de um único suporte ou resistência é possível formar até 3 triângulos e várias macrotendências, ao mesmo tempo.

Tabela 5 – Ocorrência dos elementos de análise técnica do mês de Fevereiro de 2014.

Padrão	Ocorrências
Resistência	797
Suporte	748
Triângulo	1040
MacroTendência	3781

Outros resultados estatísticos importantes relacionados aos padrões dizem respeito a relação entre eles. Verificou-se qual a porcentagem de macrotendências que a partir de sua formação alcançavam um suporte ou uma resistência. Posteriormente verificou-se qual a porcentagem de macrotendências que se davam após formação de triângulos e que alcançavam um suporte ou uma resistência. Essas porcentagens são apresentadas na Tabela 6.

Tabela 6 – Macrotendências que alcançam um suporte ou resistência.

Condição	Resistência	Suporte	Total
Origem não especificada	20,8%	20,3%	41,1%
Originária de Triângulos	7,0%	6,9%	13,9%

Os dados da Tabela 6 apresentam que 41,1% das macrotendências alcançam o suporte ou resistência, o que pode ser considerado um valor expressivo, mesmo não tendo alcançado os 50%, haja vista que não foi considerado nem 1 *PIP* a mais para incluir macrotendências. No entanto, quando se busca as macrotendências originadas de triângulos e que constituem a estratégia do Cérbero, a porcentagem cai para 13,9% das macrotendências, deixando claro que mesmo que todos os padrões sejam identificados corretamente, a combinação não passa de 15% das possibilidades de ação com as macrotendências.


Os resultados estatísticos são importantes para definir a estrutura das entradas das redes neurais, além de deixar claro quais as expectativas possíveis após a fase de treinamento. A fase de treinamento de todas as redes, bem como demais resultados referentes a estas são apresentados na Seção 5.2 Resultados de Processamento.

5.2 RESULTADOS DE PROCESSAMENTO

Os resultados do processamento dizem respeito ao treinamento e aos testes. Nesta fase foi considerada a acurácia e o erro médio quadrático atingido durante cada época do processo de treinamento, além dos acertos atingidos com a previsão realizada pelas redes após o treinamento. O treinamento foi supervisionado em que são apresentadas entradas para as redes neurais bem como as respectivas saídas esperadas, o ajuste da rede é feito comparando o resultado processado com o que era esperado buscando reduzir o erro e aumentar a acurácia através do ajuste dos pesos.

Durante a execução das primeiras versões das redes descobriu-se que estava ocorrendo *overfitting*, também conhecido como sobreajuste, um problema em que a rede se mostra bem ajustada para um conjunto de dados visto anteriormente, porém ineficaz para a predição com o conjunto de dados que nunca foi apresentado. A Figura 20 apresenta um recorte de dados da predição realizada com os dados do arquivo de treinamento, justamente no limite entre o fim do subgrupo de treinamento e o início do subgrupo de validação. Fica claro que até o fim do subgrupo de treinamento, o previsto e o real se sobrepõe de forma exata, o que não seria problema se a previsão do subgrupo da validação se mantivesse com a exatidão da previsão do subgrupo de treinamento, o que não ocorre como pode ser visto na segunda metade da figura.


Figura 20 – Rede com *Overfitting*.



A solução para o *overfitting* é apresentada pelo próprio *Keras* com a adição de uma camada conhecida como *Dropout*. Essa camada desativa as entradas e saídas de uma camada temporariamente, de modo a evitar o sobreajuste e generaliza o aprendizado. A Figura 21 apresenta o mesmo recorte de dados da predição realizada com os dados do arquivo de treinamento da Figura 20, só que com a camada de *dropout*. É possível ver que os dados da predição de treinamento não se sobrepõe completamente, indicando que o sobreajuste não ocorreu completamente, ainda que a segunda metade da figura que apresenta os dados de validação

indique que o aprendizado do padrão não ocorreu.

Figura 21 – Rede com uma camada de *Dropout*.



Esclarecida a necessidade da camada de *Dropout* foi possível realizar o treinamento dos Padrões I e II. Inicialmente foi realizado o treinamento com o padrão de Suporte e Resistência e mais especificamente o padrão de Resistência, havendo sido treinadas redes com 3 camadas ocultas para 4, 8, 16 e 32 neurônios. No caso do padrão Resistência foram trabalhados dois tipos de saída esperada, a primeira buscava que a rede identificasse apenas se haveria ou não continuidade de determinado patamar de resistência, indicando 1 para continuidade e 0 para descontinuidade, havendo o resultado sido apresentado na Figura 22 para acurácia e na Figura 23 para o erro.

Figura 22 – Acurácia atingida nas redes com saída 1 - Resistência.





Figura 23 – Erro atingida nas redes com saída 1 - Resistência.



Considerando o treinamento de 100 épocas realizado e que tanto a acurácia quanto o

erro variam no range de 0 a 1, temos que a acurácia atingida neste treinamento foi consideravelmente boa, o que é confirmado pelo erro baixo, indicando aprendizado do padrão. O valor mais baixo de acurácia e mais alto de erro foram os da rede com 4 neurônios o que pode ser justificado pela menor capacidade de processamento, frente as demais redes. No entanto, seguindo esta lógica a rede com melhor desempenho deveria ser a de 32 neurônios, o que não se confirma avaliando o gráfico, pois a rede de 16 neurônios apresenta desempenho levemente superior no que diz respeito a acurácia e a ao menor erro. Outro ponto importante a ser notado é que apesar de haverem pontos específicos para cada rede, no geral, nas primeiras 40 épocas é que se dá o crescimento mais expressivo da acurácia, que a partir de então tende a crescer de forma muito mais lenta. O mesmo é válido para o erro que tende a decrescer de forma mais expressiva nas 40 primeiras épocas, diminuindo o ritmo de decrescimento a partir de então.

Uma vez realizados os treinamentos foram feitas previsões com dois tipos de arquivos o arquivo utilizado para treinamento da rede e o arquivo utilizado para teste da rede, cujos resultados são apresentados na Tabela 7. Os percentuais de acerto são menores para o arquivo de teste para todas as redes, o que já era esperado já que em nenhum momento as redes tiveram contato com os resultados esperados nesses casos. Apenas na rede de 4 neurônios com o arquivo de treinamento que identificou-se percentual abaixo de 50%, contrastando com o arquivo de teste em que apenas com 32 neurônios houve percentual acima de 50%. É interessante perceber que apesar de a rede de 16 neurônios apresentar melhor desempenho no que diz respeito a acurácia e ao erro, não apresenta o melhor percentual de acerto no processo de previsão.

Tabela 7 – Percentuais de acerto com a previsão das redes para saída 1 - Resistência.

	4 Neurônios	8 Neurônios	16 Neurônios	32 Neurônios
Treinamento	46,12%	61,69%	80,96%	88,67%
Teste	38,53%	41,87%	48,75%	61,35%

Ainda em relação ao padrão Resistência há ainda o segundo tipo de saída esperada. Nesse caso a saída seria o próprio valor em que se deu o patamar de resistência, portanto podendo assumir diversos valores entre 0 e 1, aumentando a complexidade da previsão. Assim como no primeiro tipo de saída, neste foram treinadas redes com 3 camadas ocultas para 4, 8, 16 e 32 neurônios, cujos resultados de acurácia e erro são apresentados nas Figuras 26, 27, respectivamente.

A primeira coisa que chama a atenção nas Figuras 26 e 27 é o valor contínuo para a rede de 4 neurônios. A princípio o valor contínuo poderia ser encarado como um erro do

código de treinamento, no entanto, é exatamente o mesmo código, com mesmas entradas e saídas esperadas das demais redes apresentadas no gráfico da Figura 26, o único fator que difere é o número de neurônios nas camadas, sendo assim não se trata de um erro na estrutura do código. Restou por tanto a possibilidade de a rede 4 neurônios, mediante o segundo tipo de saída esperada necessitar de uma parametrização diferenciada das demais redes, como por exemplo taxa de aprendizado. Nesse caso a taxa de aprendizado foi alterada para se averiguar a influência desta na acurácia e no erro, observou-se porém que mesmo com taxas diferentes o comportamento se manteve, apenas o valor em que se dava o comportamento contínuo é que foi modificado, aumentando ou diminuindo de acordo com a taxa aplicada.

Figura 24 – Acurácia atingida nas redes com saída 2 - Resistência.





Figura 25 – Erro atingida nas redes com saída 2 - Resistência.



Por fim, na tentativa de entender o comportamento contínuo da rede de 4 neurônios observou-se os resultados de suas previsões que apresentaram o mesmo valor para todas as entradas fornecidas no arquivo de treinamento e no arquivo de teste: o valor 0,525620996952056 aproximado para 0,52 para análise e comparação dos erros, esse valor acaba sendo muito próximo do primeiro valor apresentado como saída esperada que foi de 0,53, o que sugere uma possível "memorização" deste valor. Buscando averiguar esta hipótese foi realizado um treinamento com 40 épocas, com 3 camadas e mesma taxa de aprendizado das demais redes, no entanto foram retiradas as 1000 primeiras linhas do arquivo de entradas de modo a evitar a

possível "memorização" dos primeiros valores do arquivo. Essa modificação acabou por ter efeito retirando a rede de 4 neurônios da condição contínua em que se encontrava.

Figura 26 – Acurácia atingida nas redes com saída 2 corrigida - Resistência.





Figura 27 – Erro atingida nas redes com saída 2 corrigida - Resistência.



Apesar de alterar a condição da acurácia e do erro, a retirada de linhas do arquivo de entrada acabou diferenciando a rede, pois os valores de acurácia e erro não iniciam na mesma região que as demais e apresentam uma evolução rápida, mas pequena.

Além da questão específica da rede de 4 neurônios, chama a atenção os valores baixos de acurácia alcançados, ainda que o erro também se mantenha baixo. Diferente do processamento do primeiro tipo de saída, nessa o melhor desempenho realmente é da rede de 32 neurônios, confirmando a ideia de que maior poder de processamento leva a melhores resultados. Assim como no primeiro tipo de saída, a evolução mais expressiva da acurácia se dá nas primeiras 40 épocas.

Tabela 8 – Percentuais de acerto com a predição das redes para a saída 2 - Resistência.

	4 Neurônios	4 Neu. - Cor.	8 Neurônios	16 Neurônios	32 Neurônios
Treinamento	1,10%	1,18%	7,3%	22,49%	26,31%
Teste	1,78%	0,34%	3,47%	6,46%	9,48%


A Tabela 8 apresenta as porcentagens de acerto de previsões para os arquivos de

treinamento e de teste com a saída do tipo 2. Os valores apresentados nesta tabela deixam bem claro que a saída 2 apresenta um nível de dificuldade elevado para as redes treinadas, pois mesmo com o arquivo de treinamento cujas entradas já foram vistos pelas redes não se alcança mais que 30% de acerto e no arquivo de teste não se chega a 10% de acerto. No entanto, considerado que a saída do tipo 2 apresenta até 100 possíveis valores a serem preditos, a rede ainda consegue ter algum nível de aprendizado e o aumento das porcentagens de acertos indica a possibilidade de melhora dos resultados na medida que aumenta o número de neurônios, apesar de que o aumento no arquivo de teste entre 8 e 16 neurônios não se mantém entre 16 e 32 neurônios. A rede de 4 neurônios corrigida (que utiliza um arquivo com menos entradas) não apresentou resultados satisfatórios, pois ficou abaixo de 1% de acerto nas predições do teste.

A segunda rede a ser treinada correspondeu ao padrão de Suporte. Assim como o padrão Resistência, o padrão suporte poderia ser testado quanto aos dois tipos de saídas possíveis, no entanto, mediante os resultados obtidos com a saída 2 do padrão anterior optou-se por realizar apenas os resultados com a saída 1.

As Figuras 28 e 29 apresentam os resultados de acurácia e de erro das redes treinadas para o padrão Suporte considerando apenas a saída 1, que como no caso do padrão anterior apresenta apenas os valores 0 e 1 que indicam a continuidade ou não do suporte nas janelas analisadas.

Figura 28 – Acurácia atingida nas redes com saída 1 - Suporte.



O comportamento das redes que se assemelha ao das redes de Resistência com igual número de neurônios, corroborando a ideia de que as redes de Suporte e Resistência devem ter o mesmo comportamento.

A Tabela 9 apresenta os resultados de acertos para rede referente ao padrão Suporte.

A terceira rede a ser treinada foi a rede referente ao padrão Triângulo. No caso dessa rede a saída esperada poderia assumir três valores, sendo eles 0, 0,5 e 1. Como o

Figura 29 – Erro atingida nas redes com saída 1 - Suporte.




Tabela 9 – Percentuais de acerto com a predição das redes para a saída 1 - Suporte.

	4 Neurônios	8 Neurônios	16 Neurônios	32 Neurônios
Treinamento	63,71%	55,39%	76,00%	83,19%
Teste	41,63%	37,53%	59,06%	66,98%

padrão Triângulo indica uma tendência, os valores esperados indicam tendência de descida, sem tendência e tendência de subida, respectivamente.

As Figuras 30 e 31 apresentam a acurácia e erro alcançados, respectivamente nos treinamentos do triângulo, treinamentos esses que apresentaram acurácia baixa e erro baixo. Esses resultados em comunhão com os resultados dos padrões anteriores levam à hipótese de que quando as saídas esperadas não são binárias provavelmente a acurácia será baixa.

Figura 30 – Acurácia atingida nas redes - Triângulo.





Figura 31 – Erro atingida nas redes - Triângulo.



Ao contrário dos padrões anteriores, no padrão triângulo a evolução mais expressiva

da acurácia se dá nas 20 primeiras épocas, número válido, também, para a evolução do erro. A rede de 32 neurônios apresenta os melhores valores de acurácia e de erro, enquanto a rede de 4 neurônios apresenta os piores resultados, corroborando a hipótese de que quanto maior o processamento melhores são os resultados. Essa hipótese, no entanto, esbarra nos percentuais de acerto apresentado na Tabela 10.

A Tabela 10 apresenta os percentuais de acerto com as predições realizadas. Ainda que a acurácia seja baixa, as porcentagens de acerto se apresentam acima dos 50% para as redes de 8, 16 e 32 neurônios, mesmo na fase de testes, indicando uma maior chance de aprendizado do comportamento do padrão. Enquanto a fase de treinamento apresenta um crescimento dos percentuais de acerto, crescimento esse em acordo com a hipótese anterior, os resultados da fase de teste informam que os melhores resultados foram alcançados com as redes de 8 e 16 neurônios, contrariando a hipótese levantada. Além disso, pela primeira vez nos resultados apresentados neste projeto, uma rede se comportou melhor na fase de teste do que na fase de treinamento, como o ocorrido com a rede de 4 neurônios.

Tabela 10 – Percentuais de acerto com a predição das redes - Triângulo.

	4 Neurônios	8 Neurônios	16 Neurônios	32 Neurônios
Treinamento	27,60%	85,02%	91,04%	93,23%
Teste	31,41%	69,60%	69,00%	66,68%

A última rede a ser treinada é a relacionada ao padrão de retração de *Fibonacci*, além de ser a rede consolidadora. A saída esperada nesse caso correspondia aos números atribuídos aos patamares da retração que podiam ser 0, para os casos em que não houve retração, 1 para os casos em que a retração se deu entre 0 e 23,6%, 2 para os casos em que a retração se deu entre 23,6 e 38,2%, 3 para os casos em que a retração se deu entre 38,2 e 50%, 4 quando esteve entre 50 e 61,8%, 5 quando esteve entre 61,8 e 100% e 6 quando esteve acima de 100%. Para que esses valores se enquadrassem no range de 0 a 1, foram divididos por sete, já que entre 0 e 6 ocorrem 7 valores, ficando, por tanto, os patamares como 0 (0), 0,142857143 (1), 0,285714286 (2), 0,428571429 (3), 0,571428571 (4), 0,714285714 (5), 0,857142857 (6).

As Figuras 32 e 33 apresentam os resultados de acurácia e erro das redes treinadas. Nesse último padrão optou-se por não realizar o treinamento das 4 redes, haja vista que os melhores desempenhos normalmente se davam com as rede de 16 e 32 neurônios, apesar de no padrão triângulo a rede de 8 neurônios ter apresentado melhor desempenho. Ao contrário dos padrões anteriores, em que se observava uma evolução positiva da acurácia, neste padrão

involução do valor, havendo uma oscilação constante dentro de uma faixa de 0,825 a 0,807, sendo que os melhores valores se deram antes das 10 primeiras épocas. Esses dados podem produzir dois entendimentos, o primeiro seria de que menos treinamentos são mais eficazes nesse padrão, o segundo seria de que por ter como saída esperada valores muito específicos e com várias casas decimais, o processo de treinamento foi generalizando o aprendizado e por tanto se afastando dos valores específicos apresentados nas saídas esperadas. O erro como nas demais redes foi sendo reduzido na medida que aumentavam as épocas, no entanto, há um comportamento diferenciado na forma como o erro é reduzido entre a rede de 16 e 32 neurônios.

Figura 32 – Acurácia atingida nas redes - Retração de Fibonacci.




Figura 33 – Erro atingida nas redes - Retração de Fibonacci.




Tabela 11 – Percentuais de acerto com a predição das redes - Fibonacci.

	16 Neurônios	32 Neurônios
Treinamento	63,63%	67,66%
Teste	46,57%	47,90%

A Tabela 11 apresenta os percentuais de acerto com as predições realizadas. Apesar de na fase de treinamento ambas as redes acertarem mais de 50%, na fase de teste nenhuma das duas redes chegou a tal porcentagem, o que indica a necessidade de treinamentos com mais camadas ou mais neurônios. No entanto, considerando que o padrão fibonacci apresenta

patamares de retração, mesmo que o patamar predito não seja o da saída esperada, se houver uma indicação de retração de um patamar anterior ao esperado é possível considerar como uma forma de acerto. Mesmo não identificando todo o potencial de retração, a identificação de uma retração por parte da rede, quando de fato há, é uma forma de acerto.

A Tabela 12 apresenta a contabilização da diferença entre a saída esperada e o predito para a fase de teste. A diferença zero indica que houve um acerto por parte da rede do valor exato do patamar de retração, todos os demais foram contabilizados como erros para a porcentagem da Tabela 11. No entanto, com a Tabela 12 é possível perceber que os valores positivos correspondem a predições em que a rede informou um ou mais patamares antes do que de fato aconteceu, o que para o processo de negociação também pode ser aproveitado. A exceção fica por parte da diferença 6, pois nesse caso haveria uma retração com base na saída esperada, mas a rede não indicou essa retração.

Tabela 12 – Contabilização da diferença entre a saída esperada e predito das redes no teste - Fibonacci.

Diferença	Quantidade 16 Neurônios	Quantidade 32 Neurônios
-6	578	962
-5	495	337
-4	291	440
-3	244	329
-2	241	441
-1	1305	703
0	3995	4109
1	145	166
2	177	158
3	187	180
4	202	106
5	368	288
6	350	359

Os resultados de processamento são fundamentais para o Projeto Cérbero, pois correspondem ao motor de predição produzido. É necessário após o treinamento das redes fazer a simulação desse processamento em situações reais do mercado, o que é descrito na seção 5.3.

5.3 RESULTADOS DE EXECUÇÃO

Os resultados de execução buscaram simular o processamento das redes em situações reais. Cabe deixar claro que esta fase tinha o intuito único e exclusivo de provar que é possível

desenvolver uma arquitetura de múltiplas redes neurais artificiais que de fato opera no mercado financeiro, permitindo uma análise mais profunda do funcionamento da estratégia. Dessa forma, os resultados obtidos não são de grande relevância para a análise do Cérbero.

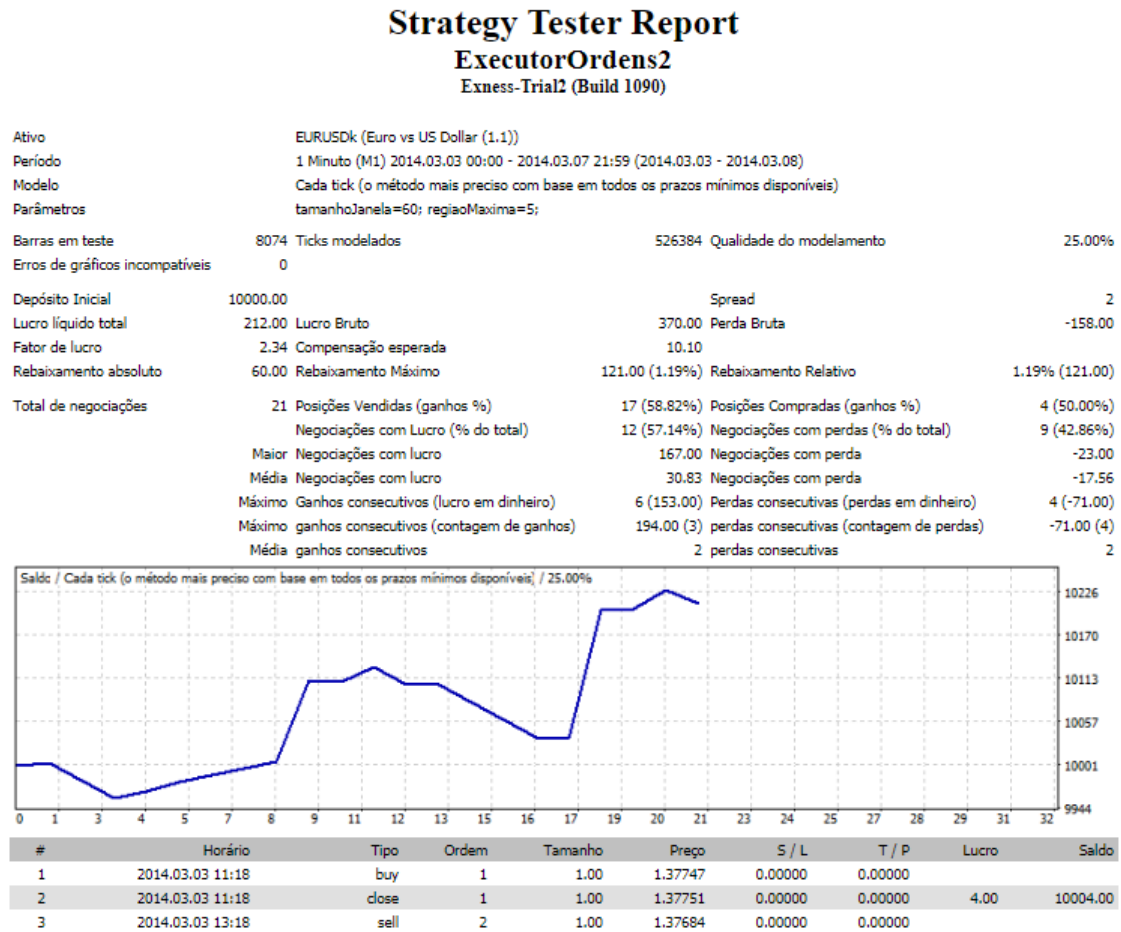
Para a simulação foram escolhidas as redes que apresentaram melhores resultados na fase de testes de cada padrão treinado. No processo de execução as redes correspondentes aos padrões Suporte, Resistência e Triângulo eram executadas primeiro e suas saídas eram encaminhadas para a rede do padrão Fibonacci.

Para essa simulação foi desenvolvido um código para comunicação entre as redes neurais e a plataforma de negociações automatizadas, fazendo uso de arquivos de extensão csv e da estratégia de semáforos de sistemas operacionais. A comunicação consistia em duas etapas, primeiro o código das redes neurais identificava a presença ou não dos arquivos de entrada, havendo esses arquivos eles eram lidos, tinham seus respectivos valores armazenados e eram apagados, as redes processavam as entradas e geravam um arquivo de saída para ser lido pelo código da plataforma de negociação; na segunda etapa, o código da plataforma lia o arquivo do resultado do processamento das redes, armazenava os valores, processava a estratégia de negociação desenvolvida, por fim gerava os arquivos com as entradas para as redes neurais e apagava o arquivo com o resultado do processamento da rede neural. Para que a comunicação fosse bem sucedida era necessário um arquivo que agia como semáforo, a presença desse arquivo indicava para o código das redes que já estavam habilitadas para ler os arquivos de entrada, já a ausência do arquivo de semáforo indicava para o código da plataforma que poderia ler o arquivo com os resultados do processamento das redes. O arquivo de semáforo por tanto era gerado pelo código da plataforma e apagado pelo código das redes.

Na plataforma de negociação foi desenvolvida uma estratégia automatizada simples para receber os resultados de processamento das redes e de acordo com os mesmos iniciar ou não uma ordem. Cabe nesse momento lembrar que o padrão triângulo e o suporte e resistência se apresentam nesse trabalho como auxiliares do padrão de retração de Fibonacci, que por tanto é o padrão aplicado na estratégia automatizada. O algoritmo do *EA* verifica se há uma tendência de baixa juntamente com a indicação de uma retração ou uma tendência de alta com a indicação de uma retração, se houver, verifica-se qual o valor identificado pelo próprio *EA* para o suporte ou resistência e uma vez que a cotação alcança o valor de suporte ou resistência identificado verifica-se se a resistência ou o suporte se mantém ou será finalizado de acordo com a resposta das redes correspondentes.

As simulações foram feitas utilizando os meses de Fevereiro de 2014 e Março de 2014, havendo sido consideradas as variáveis pertinentes para operação no mercado, apresentadas no *Strategy Test Report*. A Figura 34 apresenta o relatório produzido pela plataforma de negociação. As primeiras informações apresentadas são informações técnicas do teste realizado como o ativo, o período em que o teste foi realizado e a modelagem das cotações. Em seguida são apresentados os parâmetros criados para a estratégia e o valor que assumiram. Mais abaixo são apresentadas as informações sobre as operações realizadas como o *spread*, o lucro líquido e o bruto e a perda bruta. Há ainda o total de negociações realizadas, bem como as posições de venda e de compra, com lucro e com perda. Os dois últimos elementos importantes são o gráfico do desempenho da estratégia e o histórico das operações realizadas.

Figura 34 – Recorte do *Strategy Test Report* semana 1.



Uma vez que o ambiente estava completamente configurado foi possível executar os testes. Em virtude de questões técnicas referentes ao processo de comunicação entre o código das redes e da plataforma de negociação que poderia ocasionar em falhas se executado por longos períodos, optou-se por fazer a execução dos testes no intervalo de semanas. Dessa forma os testes

foram divididos em 8 semanas, sendo a semana 1 a primeira semana de dias úteis de Fevereiro e a semana 8 a última semana completa de Março, foram utilizados os dias de segunda a sexta das semanas selecionadas, pois como explicado anteriormente, os dados dos finais de semana não são disponibilizados para os investidores que operam via terminais de negociação.

A Tabela 13 apresenta os primeiros resultados de simulação de cada semana. A primeira coluna corresponde a semana tratada, a segunda coluna diz respeito ao total de negociações realizadas naquela semana, a terceira informa o número de negociações de venda realizadas, enquanto a quarta diz respeito ao número de negociações de compra, a quinta coluna corresponde a quantidade de operações que geraram lucro com a porcentagem correspondente, a sexta coluna corresponde a quantidade de operações que geraram perda e a porcentagem correspondente, por fim é apresentada a coluna do saldo após os lucros e perdas.

Tabela 13 – Simulação no mercado do Cérbero das 8 semanas.

Semana	Total de Negociações	Venda	Compra	Lucro	Perda	Saldo
1	21	17	4	12 (57,14%)	9 (42,86%)	212
2	6	4	2	3 (50.00%)	3 (50.00%)	29
3	10	8	2	3 (30.00%)	7 (70.00%)	-68
4	47	23	24	38 (80.85%)	9 (19.15%)	-16
5	13	12	1	9 (69.23%)	4 (30.77%)	74,75
6	54	24	30	33 (61.11%)	21 (38.89%)	-333
7	20	10	10	8 (40.00%)	12 (60.00%)	5
8	14	14	0	9 (64.29%)	5 (35.71%)	-14

6 CONCLUSÕES E TRABALHOS FUTUROS

O Projeto Cérbero é certamente um projeto grande e complexo o que fica claro por todo o arcabouço teórico necessário para compreendê-lo, bem como a quantidade de resultados produzidos. Como apresentado na introdução desta monografia o todo é uma síntese única das partes que o fundamentam ao mesmo tempo que este justifica a existência das mesmas, assim é o Projeto Cérbero, uma síntese única dos padrões de análise técnica abordados que depende diretamente do aprendizado das redes neurais artificiais envolvidas, mas que não é produto exclusivo da ação individual dessas redes e sim da interação singular que elas realizam.

A eficácia da estratégia proposta neste trabalho está diretamente relacionada a capacidade de identificação correta dos padrões de análise técnica propostos, bem como da correta interligação destes. Provou-se que havia pelo menos uma configuração de rede dentre as analisadas que conseguia uma assertividade de mais de 50% para o padrão correspondente. Indicando a viabilidade de aprendizagem dos padrões por parte das redes neurais.

Com os dados atuais não é possível concluir se o projeto é de fato eficaz para operação no mercado ou não. Se o Cérbero fosse um programa finalizado, seria dotado de uma larga parametrização que inclui os tipos de padrões utilizados, a forma de discretização dos dados do mercado, a estrutura de apresentação das entradas para as redes, as saídas esperadas para cada rede, o método para combinação e análise para a saída de cada uma das redes, dentre outros, sendo que todos esses fatores influenciam no sucesso ou não da estratégia.

Considerando a complexidade do Cérbero este trabalho foi a primeira de muitas etapas que serão realizadas. Um dos trabalhos futuros a ser desenvolvido é a utilização de mais neurônios e mais camadas para os padrões utilizados nesse projeto a fim de melhorar a assertividade dessas redes. Outra atividade a ser realizada é um trabalho mais aprofundado de ciência dos dados para identificar a melhor forma de produzir entradas que facilitem o processamento e saídas que sejam representativas dos acontecimentos. É importante também o teste com os demais meses armazenados nas fases iniciais do projeto. Há ainda a necessidade de verificar outros padrões de análise técnica e suas possíveis relações. Também é possível bifurcar a abordagem das redes neurais colocando as redes recorrentes em paralelo com as redes convolucionais, podendo inclusive uni-las em uma mesma rede. Por fim, a utilização de três padrões foi uma escolha deste projeto porém não há limites para o número de padrões e redes, o que abre margem para a criação do Projeto Hidra.

REFERÊNCIAS

- ADHIKARI, R.; AGRAWAL, R. An introductory study on time series modeling and forecasting. **arXiv preprint arXiv:1302.6613**, 2013.
- AVERKIN, A. N.; YARUSHEV, S. Hybrid approach for time series forecasting based on anfis and fuzzy cognitive maps. In: IEEE. **Soft Computing and Measurements (SCM), 2017 XX IEEE International Conference on**. [S.l.], 2017. p. 379–381.
- BM&F, B. de M. . F. **MERCADOS DERIVATIVOS**. 2007. Disponível em: <[https://edisciplinas.usp.br/pluginfile.php/1818183/mod_resource/content/1/ENS%20 – %20MF2%20BMF%202007%20 – %20BK%20Introd%20Derivativos.pdf](https://edisciplinas.usp.br/pluginfile.php/1818183/mod_resource/content/1/ENS%20-%20MF2%20BMF%202007%20-%20BK%20Introd%20Derivativos.pdf)> .Acessoem : 06dez.2017.
- BORTOLI, M. A. **Indicadores Baseados em Diferenças de Primeira Ordem para Orientar Robôs no Mercado FOREX**. 2015. UNEB (Universidade do Estado da Bahia), Salvador, Brasil.
- BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE-eletrônica**, SciELO Brasil, v. 3, n. 1, 2004.
- BULKOWSKI, T. N. **Encyclopedia of chart patterns**. [S.l.]: John Wiley & Sons, 2011. v. 225.
- CARVALHO, J. L. d. S. d. **Predição da Tendência de Séries Temporais do Mercado FOREX Utilizando Indicador Baseado em Estatística Descritiva e Redes Neurais Recorrentes**. 2017. UNEB (Universidade do Estado da Bahia), Salvador, Brasil.
- FACURE, M. **Funções de Ativação**. 2017. Disponível em: <<https://matheusfacure.github.io/2017/07/12/activ-func/>>. Acessado em: 22 abr. 2018.
- HANSUN, S. Wema versus b-wema methods in forex forecasting. In: ACM. **Proceedings of the 9th International Conference on Machine Learning and Computing**. [S.l.], 2017. p. 268–271.
- HAYKIN, S. **Neural Networks: A Comprehensive Foundation (2nd Edition)**. Prentice Hall, 1998. Hardcover. ISBN 0132733501. Disponível em: <<http://www.amazon.ca/exec/obidos/redirect?tag=citeulike09-20&path=ASIN/0132733501>>.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.
- LAMOUNIER, W. M. Tendência, ciclos e sazonalidade nos preços spot do café brasileiro na nybot. **Gestão & Produção, São Carlos**, SciELO Brasil, v. 14, n. 1, p. 13–23, 2007.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.
- NICOLAU, J. Modelação e estimação de séries financeiras através de equações diferenciais estocásticas. 2000.
- OLAH, C. **Understanding LSTM Networks**. 2015. Disponível em: <<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>>.
- PAULA, A. de; TRICHES, D. O mercado acionário e o desempenho dos ativos financeiros no brasil com emprego da análise técnica. **Perspectiva Econômica**, v. 6, n. 1, p. 37–62, 2010.

PENTEADO, M. A. d. B. **Uma avaliação estatística da análise gráfica no mercado de ações brasileiro à luz da teoria dos mercados eficientes e das finanças comportamentais**. Tese (Doutorado) — Universidade de São Paulo, 2003.

PUTRA, A. R. P.; PERMANASARI, A. E.; FAUZIATI, S. I forex trend prediction technique using multiple indicators and multiple pairs correlations dss: A software design. In: IEEE. **Information Technology and Electrical Engineering (ICITEE), 2016 8th International Conference on**. [S.l.], 2016. p. 1–5.

RESENDE, A. C.; ARGIMON, I. Perspectiva transcultural do método de rorschach. **Avanços do Rorschach no Brasil**, Casa do Psicólogo São Paulo, p. 87, 2010.

ROCKEFELLER, B. **Análise técnica para leigos**. Rio de Janeiro, RJ: Alta Books, 2016.

ROLEDENE, S.; ARIYATHILAKA, L.; LIYANAGE, N.; LAKMAL, P.; BAMUNUSINGHE, J. Genibux-event based intelligent forex trading strategy enhancer. In: IEEE. **Information and Automation for Sustainability (ICIAfS), 2016 IEEE International Conference on**. [S.l.], 2016. p. 1–6.

RUSSELL, S. J.; NORVIG, P. **Inteligência Artificial**. [S.l.]: Rio de Janeiro: Elsevier, 2013.

SANTOS, G. L. D. **ESTUDO DA VARIAÇÃO DAS FUNÇÕES**. 2009. Disponível em: <<http://www.calculo1.ufba.br/lista-ca/varfun.pdf>>. Acessado em: 02 abr. 2018.

SILVEIRA, A. G.; MATTOS, V. L. D. de; KONRATH, A. C. Avaliação da estacionariedade e teste de cointegração em séries temporais o caso da demanda de energia elétrica residencial no brasil. **RETEC-Revista de Tecnologias**, v. 9, n. 3, 2017.

TAYLOR, V. S. A relevância da análise técnica para selecionar ações. 2010.

TRADERS, F. **SUPORTE E RESISTÊNCIA NA ANÁLISE TÉCNICA**. 2017. Disponível em: <<http://www.forextraders.com.br/suporte-resistencia-analise-tecnica/>>. Acessado em: 13 dez. 2017.

UHLMANN, G. W. Teoria geral dos sistemas. 2002.

YONG, Y. L.; LEE, Y.; NGO, D. An investigation into the recurring patterns of forex time series data. In: IEEE. **Robotics and Intelligent Sensors (IRIS), 2015 IEEE International Symposium on**. [S.l.], 2015. p. 313–317.