

**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
CAMPUS TIMÓTEO**

Lucas Henrique Silva

**ESTUDO DE CASO: APLICANDO RNAS NA COTAÇÃO DO
CONTRATO FUTURO DE DÓLAR COMERCIAL NA BOLSA DE
VALORES BRASILEIRA**

Timóteo

2021

Lucas Henrique Silva

**ESTUDO DE CASO: APLICANDO RNAS NA COTAÇÃO DO
CONTRATO FUTURO DE DÓLAR COMERCIAL NA BOLSA DE
VALORES BRASILEIRA**

Monografia apresentada à Coordenação de Engenharia de Computação do Campus Timóteo do Centro Federal de Educação Tecnológica de Minas Gerais para obtenção do grau de Bacharel em Engenharia de Computação.

Orientador: Douglas Nunes de Oliveira

Timóteo

2021

Lucas Henrique Silva

**ESTUDO DE CASO: APLICANDO RNAs NA COTAÇÃO DO CONTRATO FUTURO DE
DÓLAR COMERCIAL NA BOLSA DE VALORES BRASILEIRA**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Computação do Centro Federal de Educação
Tecnológica de Minas Gerais, campus Timóteo,
como requisito parcial para obtenção do título de
Engenheiro de Computação.

Trabalho aprovado. Timóteo, 04 de junho de 2021:

Prof. Douglas Nunes de Oliveira
Orientador

Prof. Dr. Bruno Rodrigues Silva
Professor Convidado

Prof. Dr. Rodrigo Gaiba De Oliveira
Professor Convidado

Timóteo
2021



MINISTÉRIO DA EDUCAÇÃO
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE
MINAS GERAIS
SISTEMA INTEGRADO DE PATRIMÔNIO,
ADMINISTRAÇÃO E CONTRATOS

FOLHA DE ASSINATURAS

Emitido em 04/06/2021

ATA N° 20210604/2021 - DCCTM (11.63.05)
(N° do Documento: 45)

(N° do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 07/07/2021 18:04)

BRUNO RODRIGUES SILVA

PROFESSOR ENS BASICO TECN TECNOLOGICO

DCCTM (11.63.05)

Matrícula: 1675935

(Assinado digitalmente em 17/06/2021 08:41)

DOUGLAS NUNES DE OLIVEIRA

PROFESSOR ENS BASICO TECN TECNOLOGICO

DCCTM (11.63.05)

Matrícula: 2921288

(Assinado digitalmente em 17/06/2021 12:10)

RODRIGO GAIBA DE OLIVEIRA

PROFESSOR ENS BASICO TECN TECNOLOGICO

CTINFMT (11.50.40)

Matrícula: 2492493

Para verificar a autenticidade deste documento entre em <https://sig.cefetmg.br/documentos/> informando seu número:
45, ano: 2021, tipo: ATA, data de emissão: 17/06/2021 e o código de verificação: f2442520ae

Agradecimentos

Agradeço aos meus pais por todo suporte em toda a minha caminhada acadêmica, a minha esposa por todo o apoio, a instituição CEFET-MG e todos os seus professores os quais foram imprescindíveis para minha formação. Todos estes de uma maneira especial fizeram parte da minha trajetória e contribuíram para a minha caminhada acadêmica.

*“Os grandes navegadores
devem sua reputação aos temporais e tempestades”.*
Epicuro

Resumo

Mercados financeiros movimentam grandes volumes monetários diariamente. Diversas são as opções de bolsas de valores com inúmeros produtos disponíveis para negociações ao redor do mundo. Entretanto, obter lucros com as negociações não é uma tarefa fácil, principalmente para aqueles que buscam prever o mercado. Trata-se de algo desafiador devido a sua natureza volátil, não paramétrica e não linear. Desta maneira foi realizado um estudo de caso utilizando o mini dólar como objeto de análise e aplicando redes neurais artificiais para definir pontos de entrada ou saída das operações. Para a realização das devidas comparações 5 variações de *Multilayer Perceptrons* com diferentes topologias foram propostas. Como entradas para os modelos foram aplicados os indicadores Média Móvel Simples, Média Móvel Exponencial, ADX, Estocástico e o *Hilo Activator*. O *HiLo Activator* foi utilizado como principal sinal de operação indicando os momentos de compra e venda do ativo. Cada variação proposta foi implementada, treinada e utilizada para a realização de negociações pelo período de 1 semana. Em seguida, foi analisado o mesmo período, operando com os mesmos parâmetros operacionais, porém sem a utilização das redes neurais para a confirmação de compra ou venda. Ao final do período, relatórios foram extraídos e analisados evidenciando que alguns modelos de MLP foram ineficientes no período analisado, entretanto, outros modelos apresentaram valores animadores. Desta maneira, no resultado agregado, foi verificado que a utilização das redes neurais gerou lucros maiores do que a não utilização durante o período analisado. Além disto, muitos pontos de melhorias foram identificados podendo ser importantes oportunidades para a otimização da ferramenta desenvolvida.

Palavras-chave: mercado financeiro, mini dólar, previsão de séries temporais, redes neurais artificiais, previsão da movimentação de ativos financeiros.

Abstract

Financial markets handle large amounts of money on a daily basis. There are several stock exchange options with numerous products available for trading around the world. However, making profits from trading is not an easy task, especially for those who seek to forecast the market. It is challenging due to its volatile, non-parametric and non-linear nature. In this way, a case study was carried out using the mini dollar index as the object of analysis and applying artificial neural networks to define entry or out points for operations. In order to make the appropriate comparisons, 5 variations of Multilayer Perceptrons with different topologies were proposed. As inputs for the models, Simple Moving Average, Exponential Moving Average, ADX, Stochastic and Hilo Activator indicators were applied. HiLo Activator was used as the main trading signal indicating the moments of purchase and sale of the asset. Each proposed variation was implemented, trained and used to carry out negotiations for a period of 1 week. Then, the same period was analyzed, operating with the same operational parameters, but without the use of neural networks for confirmation of purchase or sale. At the end of the period, reports were extracted and analyzed showing that some MLP models were inefficient in the period analyzed, however, other models showed encouraging values. Thus, in the aggregate result, it was found that the use of neural networks generated greater profits than the non-use during the analyzed period. In addition, many points of improvement were identified, which can be important opportunities for the optimization of the developed tool.

Keywords: financial market, mini dollar index, time series forecast, artificial neural networks, stock market movement forecast.

Lista de ilustrações

Figura 1 – Gráfico exemplificando a curva da função ReLU.	17
Figura 2 – Gráfico exemplificando a curva da função Sigmoidal.	18
Figura 3 – Gráfico exemplificando a curva da função Tangente Hiperbólica.	18
Figura 4 – Histórico de preços do mini dólar.	22
Figura 5 – Representação gráfica de um <i>candle</i> de alta e de baixa.	23
Figura 6 – Exemplo de gráfico <i>Candlestick</i>	23
Figura 7 – Média móvel simples calculada para 21 períodos.	24
Figura 8 – Média móvel exponencial calculada para 21 períodos.	25
Figura 9 – Índice de Direção do Movimento.	26
Figura 10 – Estocástico calculado considerando %K igual a 5 períodos e %D igual a 3.	27
Figura 11 – Exemplo de um gráfico aplicando um HiLo Activator.	27
Figura 12 – Exemplo de um gráfico com stop loss.	28
Figura 13 – Exemplo de um gráfico com <i>stop gain</i> e <i>stop loss</i>	29
Figura 14 – Exemplo de aplicação de um mecanismo de Trailing stop.	30
Figura 15 – Exemplo de aplicação de um mecanismo de Trailing stop.	30
Figura 16 – Profit Pro.	31
Figura 17 – Home Broker da corretora Clear.	31
Figura 18 – Metatrader 5.	32
Figura 19 – Procedimentos metodológicos.	34
Figura 20 – HiLo: exemplo de um sinal de compra.	38
Figura 21 – HiLo: exemplo de um sinal de venda.	38
Figura 22 – Fluxograma evidenciando a integração entre a API e o Metatrader.	39
Figura 23 – Fluxo de operações para realização das negociações.	41
Figura 24 – Exemplo visual da extração de dados através do Metatrader.	44
Figura 25 – Exemplo visual da extração de dados através do Metatrader.	44
Figura 26 – Saída de um teste de previsibilidade.	49
Figura 27 – Exemplo gráfico durante uma negociação.	55
Figura 28 – Exemplo dos <i>logs</i> extraídos do Metatrader.	56
Figura 29 – Exemplo visual da integração entre a API e o Metatrader.	56
Figura 30 – Movimentação do mini dólar durante o período de 08/03/2021 à 12/03/2021.	57
Figura 31 – Resultados das negociações sem IA.	57
Figura 32 – Resultados das negociações utilizando a variação 1.	58
Figura 33 – Movimentação do mini dólar durante o período de 15/03/2021 à 19/03/2021.	58
Figura 34 – Resultados das negociações sem IA.	59
Figura 35 – Resultados das negociações utilizando a variação 2.	59
Figura 36 – Movimentação do mini dólar durante o período de 21/03/2021 à 26/03/2021.	60
Figura 37 – Resultados das negociações sem IA.	61
Figura 38 – Resultados das negociações utilizando a variação 3.	61
Figura 39 – Movimentação do mini dólar durante o período de 29/03/2021 à 02/04/2021.	62

Figura 40 – Resultados das negociações sem IA.	62
Figura 41 – Resultados das negociações utilizando a variação 4.	63
Figura 42 – Movimentação do mini dólar durante o período de 05/04/2021 à 09/04/2021.	64
Figura 43 – Resultados das negociações sem IA.	64
Figura 44 – Resultados das negociações utilizando a variação 5.	65
Figura 45 – Comparativo entre as variações, considerando lucros financeiros.	66
Figura 46 – Comparativo entre as variações, considerando taxas de acerto nas negocia- ções.	67
Figura 47 – Comparativo entre as especializações, considerando taxas de acerto nas negociações.	68
Figura 48 – Exemplo de volatilidade ocorrida durante dia 07/04/2021.	71
Figura 49 – Exemplo de perdas em virtude do <i>stop loss</i>	72

Lista de tabelas

Tabela 1 – Variação 1 - topologia da rede.	36
Tabela 2 – Variação 2 - topologia da rede.	36
Tabela 3 – Variação 3 - topologia da rede.	36
Tabela 4 – Variação 4 - topologia da rede.	37
Tabela 5 – Variação 5 - topologia da rede.	37
Tabela 6 – HiLo: configuração utilizada.	42
Tabela 7 – Estocástico: configuração utilizada.	42
Tabela 8 – ADX: configuração utilizada.	43
Tabela 9 – Médias Móveis: configuração utilizada.	43
Tabela 10 – Comparativo entre as variações - Lucros financeiros.	65
Tabela 11 – Comparativo entre as variações - número de operações.	66
Tabela 12 – Comparativo entre as variações - desempenho entre redes especializadas na compra e venda.	67

Sumário

1	INTRODUÇÃO	13
1.1	Objetivos	15
1.1.1	Objetivos específicos	15
2	REVISÃO BIBLIOGRÁFICA	16
2.1	Trabalhos correlatos	16
2.2	Redes Neurais Artificiais	16
2.2.1	Funções de ativação	17
2.2.2	Funções de otimização	19
2.2.3	RNAs aplicadas às séries temporais	20
2.3	Mercado financeiro voltado para <i>Day Trade</i>	20
2.3.1	Mini dólar	21
2.3.2	Candlesticks e tempo gráfico	22
2.3.3	Indicadores técnicos	23
2.3.4	Técnicas para negociação	27
2.3.5	Plataforma de negociações	30
2.4	Ferramentas computacionais	32
2.4.1	NodeJs	32
2.4.2	Express	33
2.4.3	Tensorflow	33
3	PROCEDIMENTOS METODOLÓGICOS	34
3.1	Classificação da pesquisa	34
3.2	Revisão bibliográfica	35
3.3	Definição dos indicadores utilizados	35
3.4	Definição da plataforma de negociação	35
3.5	Definição das estratégias de <i>Day Trade</i>	35
3.6	Definição dos modelos a serem treinados	35
3.6.1	Variação 1	36
3.6.2	Variação 2	36
3.6.3	Variação 3	36
3.6.4	Variação 4	36
3.6.5	Variação 5	37
3.7	Codificação	37
3.7.1	Obtenção dos dados	37
3.7.2	Desenvolvimento de API para treinamento	39
3.7.3	Testar a previsibilidade do modelo	40
3.7.4	Realizar negociações com a rede treinada	40
3.8	Análise e exposição dos resultados obtidos	41

4	DESENVOLVIMENTO	42
4.1	Obtenção e rotulação dos dados	42
4.2	Desenvolvimento da API	45
4.2.1	Interfaces disponíveis na API	46
4.2.1.1	Treinar	46
4.2.1.2	Predizer	46
4.2.1.3	Predizer em lote	47
4.3	Implementação de testes de previsibilidade	48
4.4	Implementação das RNAs	49
4.4.1	Variação 1	50
4.4.2	Variação 2	51
4.4.3	Variação 3	52
4.4.4	Variação 4	53
4.4.5	Variação 5	54
4.5	Negociações utilizando RNAs	55
4.5.1	Variação 1	56
4.5.2	Variação 2	58
4.5.3	Variação 3	60
4.5.4	Variação 4	61
4.5.5	Variação 5	63
4.5.6	Comparativo geral	65
5	CONCLUSÃO	69
5.1	Resultados	69
5.2	Considerações e limitações	70
5.3	Trabalhos futuros	73
	REFERÊNCIAS	75

1 Introdução

*“A resposta certa, não importa nada:
o essencial é que as perguntas estejam certas”.*
Mário Quintana

Um dos meios mais clássicos para se realizar negociações financeiras é através de bolsa de valores. Até hoje não é possível definir com exatidão a sua origem. Alguns escritores a localizam “nos emporium dos gregos, outros nos collegium mercatorum dos romanos, ou nos funduks(bazares) dos palestinos” (RUDGE; CAVALCANTE, 1996). Segundo Gomes (1997), “as primeiras bolsas com características modernas surgiram com o desenvolvimento do comércio, em meados do século XV, e sua expansão no século XVI”. A definição dos preços de ativos sempre tiveram como base a Lei da Oferta e Procura. Em um mundo cada vez mais globalizado, tem-se centenas de opções de bolsas de valores espalhadas pelo mundo, com milhares de ativos disponíveis para negociações a todos os interessados no assunto. Tal situação é algo benéfico para a sociedade, uma vez que cada pessoa pode definir o que é melhor ou não para si, entretanto, ao mesmo tempo trás sempre o questionamento sobre o que comprar/vender e quando se deve comprar/vender diante deste cenário (EDWARDS; MAGEE; BASSETTI, 2018).

No âmbito nacional, a Bolsa de Valores Brasileira B3 “é uma das principais empresas de infraestrutura de mercado financeiro no mundo, com atuação em ambiente de bolsa e de balcão” (B3, 2020b). É a única entidade com estas características atuante em território nacional. De acordo com o noticiado recentemente, “em meio à epidemia do coronavírus, a Bolsa de Valores movimentou R\$ 25,9 bilhões por dia em 2020 no primeiro semestre, no maior valor diário da história do mercado acionário brasileiro”(ANDRADE, 2020, p.1). Analisando os números mencionados, a porcentagem da população a qual participa deste mercado e o seu potencial de crescimento a médio-longo prazo, percebe-se um nicho de mercado promissor no qual a aplicação de técnicas as quais consigam prever qual o melhor momento para se comprar/vender de forma a maximizar ganhos financeiros são de grande valia para qualquer investidor ou até mesmo interessados no assunto.

Um dos principais ativos negociados nacionalmente é o mini-dólar, conhecido também como Contrato Futuro de Dólar Comercial. Trata-se do segundo contrato derivativo mais negociado no mercado brasileiro, apresentando diversas utilizações tais como proteção para investidores que, por exemplo, tenham recebíveis em dólares americanos, ou exposição para pagamentos de passivos na moeda em datas futuras, em valores nominais¹ inferiores aos do contrato padrão, ou até mesmo negociar sobre a tendência da moeda no futuro e assim auferir lucro (B3, 2020a). Estas características colocam-o como um promissor ativo a ser utilizado como objeto de estudo a fim de aferir o comportamento do mercado ao longo do tempo.

¹ Valor nominal é o valor total dos ativos de uma posição alavancada

Com a evolução dos mercados financeiros, houve também uma evolução na maneira de investir. Estudiosos do tema sempre buscaram formas de tornar suas operações mais rentáveis. Com isso, desenvolveu-se técnicas para realizar análises dos ativos disponíveis. Existem duas abordagens principais para a tomada de decisão: modelo fundamentalista e o modelo técnico. Segundo Aires, Dametto e Crepaldi (2018), “o modelo fundamentalista analisa aspectos da empresa em questão e aspectos macroeconômicos. Já o modelo técnico se fundamenta em dados históricos a respeito da empresa, tentando, assim, inferir o futuro a partir de comportamentos passados.” Cada investidor decide a melhor forma de analisar de acordo com o seu perfil. Investidores os quais possuem perfis de investimento a longo prazo tendem a ser mais minuciosos durante a análise fundamentalista. Entretanto, profissionais os quais desejam obter lucros a curto e/ou curtíssimo prazo realizando compras e vendas em um mesmo dia, conhecidos como *traders*, comumente utilizam-se das análises técnicas como referencial para a tomada de decisão.

Durante o processo de análise técnica, investidores analisam o histórico de negociação do ativo contemplando informações sobre os preços de abertura, fechamento, máximos, mínimos, entre outros, os quais produzem uma série temporal não-linear, “cuja previsão de comportamento é de fundamental importância para negociações futuras” (AIRES; DAMETTO; CREPALDI, 2018). O mercado futuro tende a repetir os movimentos do mercado passado. Desta forma, analisar o passado de maneira a extrair informações relevantes para a tomada de decisão no futuro é uma tarefa crucial a qual pode definir sucesso ou fracasso dos profissionais.

As principais ferramentas utilizadas para o auxiliar na análise técnica são os gráficos e indicadores. Profissionais experientes são extremamente cuidadosos ao utilizar tais ferramentas. Cada indicador tem como função evidenciar informações relevantes para a tomada de decisão a partir de cálculos matemáticos feitos utilizando histórico de preço da abertura, fechamento, maior e menor preço negociado durante um determinado intervalo de tempo, entre outros. Exemplos são: médias móveis exponenciais e simples, índice de força relativa, estocástico, volume de negociações e bandas de Bollinger. Profissionais comumente utilizam tais informações em conjunto de forma a gerar sinais os quais referem-se a momentos oportunos para se comprar ou vender um ativo de forma a se antecipar a uma movimentação do mercado, objetivando lucros financeiros.

Entretanto, mesmo com todos os estudos atuais, realizar previsões adequadas é um problema ainda não solucionado de uma maneira totalmente satisfatória para os investidores, principalmente devido ao comportamento não linear dos ativos. Milhares de *trades* operam diariamente, mas até mesmo os mais experientes estão suscetíveis a perdas financeiras consideráveis durante o processo. Logo, tal campo de pesquisa tem se tornado cada vez mais relevante a fim de superar dificuldades, tais como determinar combinações ótimas de indicadores ou ajustar seus parâmetros (SHYNKEVICH et al., 2017).

a previsão do mercado de ações é uma tarefa altamente exigente e desafiadora para investidores, analistas profissionais e pesquisadores do mercado financeiro devido à natureza altamente barulhenta, não paramétrica, volátil, complexa, não linear, dinâmica e caótica das séries temporais de preços de ações.

Investir no mercado de ações envolve maior risco, logo, trata-se de uma tarefa crucial e área de pesquisa proeminente no domínio financeiro (KUMAR; JAIN; SINGH, 2020).

Com os avanços tecnológicos, a Inteligência Artificial têm se tornado cada vez mais presente na sociedade. Devido sua eficiência, tem sido aplicada nos mais diversos cenários desde em aplicações WEB até Sistemas Operacionais sempre objetivando melhorar a experiência dos usuários de alguma maneira ou evidenciar informações relevantes ainda desconhecidas. Dentro do campo da IA, Redes Neurais Artificiais têm sido utilizadas para vários propósitos. Devido a sua capacidade de lidar com informações abrangentes, desordenadas, sem exigir fortes suposições do modelo e também apresentar uma boa capacidade de aproximação não linear, altas taxas de aprendizagem e habilidades auto-adaptativas, elas têm sido introduzidas para treinar e prever as flutuações do mercado de ações. (LIU; WANG, 2012)

1.1 Objetivos

Considerando a relação entre o problema enfrentado e abordagens atuais para tentativas de resolução, este trabalho tem como objetivo realizar um estudo de caso referente a aplicação de redes neurais artificiais para realizar a previsão da movimentação do mini índice do dólar negociado na B3 avaliando sua performance no âmbito de lucros monetários, utilizando indicadores da análise técnica que atuarão como entradas para o modelo.

1.1.1 Objetivos específicos

- Levantar o indicadores financeiros de entrada do modelo.
- Definir o modelo de rede neural artificial a ser utilizada.

2 Revisão bibliográfica

*“O período de maior ganho em conhecimento e experiência
é o período mais difícil da vida”.*
Dalai Lama

Este capítulo têm como objetivo explanar de forma mais detalhada os principais conceitos relacionados ao presente trabalho e trabalhos correlatos. As fontes de informação utilizadas foram Google Scholar, Portal de Periódico da Capes e sites conceituados relacionados ao mercado financeiro e técnicas de operação, além de sites oficiais de instituições.

2.1 Trabalhos correlatos

Kumar, Jain e Singh (2020) realizaram uma importante pesquisa compilando vários estudos relacionados a previsão de preços de mercados de ativos utilizando inteligência computacional. Vários modelos foram revisados, tais como Algoritmos Genéticos, Redes Neurais Artificiais, modelos híbridos, entre outros, sendo uma valiosa fonte de pesquisa para o assunto.

Guresen, Kayakutlu e Daim (2011) estudaram 3 diferentes modelos para realizar a predição do preço: Perceptron Multicamadas (MLP), rede neural artificial dinâmica (DAN2) e as redes neurais híbridas que usam heterocedasticidade condicional autorregressiva generalizada (GARCH) para extrair variáveis de entrada. Ao final os autores concluem que o MLP foi o modelo o qual obteve os melhores resultados, embora a diferença entre eles tenha sido pequena, reforçando assim a aplicabilidade deste modelo ao problema.

Vanstone, Finnie e Hahn (2012) desenvolveu um trabalho similar analisando o mercado financeiro australiano. Para tal, ele implementou um MLP utilizando 4 variáveis da análise fundamentalista como entrada, tais como retorno sobre o patrimônio líquido (ROE), valor contábil, índice de distribuição de dividendos e índice preço / lucro (P / L). Eles concluíram que as variáveis escolhidas não obtiveram os resultados totalmente satisfatórios e sugerem a utilização de outros indicadores, como a média móvel do índice o qual descreveria melhor o mercado como um todo.

2.2 Redes Neurais Artificiais

Segundo Castro (2007), Redes Neurais Artificiais podem ser definidas como sistemas de processamento de informações projetados com inspiração tirada do sistema nervoso sistema, na maioria dos casos o cérebro humano. São utilizadas para realizar aproximação de funções a partir de conjunto de dados. Segundo Souza (2008), a principal diferença entre redes neurais e as abordagens estatísticas, tais como os modelos ARIMA, é que as redes neurais não estabelecem hipóteses ou suposições sobre a distribuição ou propriedades dos dados e, desta forma, tendem a ser mais úteis em situações práticas. As RNAs constituem também

uma abordagem inerentemente não-linear, fornecendo precisão quando modelam dados de padrões complexos, conhecidas também como aproximadores universais de funções.

Multilayer perceptrons, ou MLP, é uma das diversas classes de RNA. Seu funcionamento consiste de “um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada” (HAYKIN, 2007, p.183). Durante a fase de treinamento de uma rede, MLP é utilizado em conjunto com o Algoritmo de *Back-Propagation*. Nesta configuração, a rede neural realiza cálculos matemáticos de forma a obter o resultado para a respectiva entrada, passando informações entre as diversas camadas do modelo, iniciando na camada de entrada até a camada de saída. Ao final dos cálculos, os erros são calculados e, então propagados para as camadas anteriores na ordem inversa, servindo como parâmetros para atualizar os pesos sinápticos, resultando assim em um aprendizado, processo semelhante ao que acontece no cérebro humano (HAYKIN, 2007). Após esta fase, utiliza-se a rede com os pesos obtidos durante o treinamento para verificar a acurácia do modelo introduzindo novas entradas e verificando os resultados obtidos.

2.2.1 Funções de ativação

Funções de ativação são um passo muito importante no processo de aprendizado das redes neurais artificiais. Nesta seção, serão abordados alguns exemplos utilizados para este passo.

ReLU

ReLU, acrônimo para Rectified Linear Unit function, é uma função de ativação de uso comum para camadas escondidas em MLPs. É contínua porém não diferenciável em $x = 0$. No entanto, apresenta bons resultados na prática e ainda possui a vantagem de ser rápida para ser calculada. O fato de sua imagem não possuir um valor máximo ajuda a reduzir alguns problemas durante a fase de otimização pelo gradiente descendente (GÉRON, 2019, p.288).

Sua equação é dada por:

$$relu(x) = \max(0, x) \quad (2.1)$$

Figura 1 – Gráfico exemplificando a curva da função ReLU.



Fonte: (WIKIPEDIA, 2021a)


Sigmoidal

A função Sigmoidal, também conhecida como função Logística, é uma função de ativação com imagem compreendida entre o intervalo de $[0,1]$. É comumente utilizada para problemas de classificação binária, tais como: caso o valor de saída seja menor do que 0.5, representa-se a classe "0", caso seja maior ou igual a 0.5, representa-se a classe "1". Em exemplos reais, pode representar se um email é ou não spam, entre outros (GÉRON, 2019, p.144).

Sua equação é dada por:

$$y(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$

Figura 2 – Gráfico exemplificando a curva da função Sigmoidal.




Fonte: (WIKIPEDIA, 2021b)

Tangente Hiperbólica

Tangente hiperbólica é uma função de ativação em forma de S, muito similar a função Sigmoidal, sendo representada por:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$

Figura 3 – Gráfico exemplificando a curva da função Tangente Hiperbólica.



Fonte: (WIKIPEDIA, 2021c)

Sua imagem é compreendida no intervalo $[-1, 1]$. Devido a este comportamento tende a tornar a saída de cada camada mais próximo a 0 no início do treinamento, resultando assim em uma aceleração da convergência (GÉRON, 2019, p.288).

2.2.2 Funções de otimização

Treinar grandes conjuntos de dados pode ser algo moroso e lento. Logo, uma das formas de acelerar este processo é por meio de funções de ativação (GÉRON, 2019, p.344). Estas funções têm como objetivo minimizar os erros durante o processo e, desta maneira, permitir uma atualização mais assertiva dos pesos. Esta seção retratará alguma destas funções.

Momentum

A função de otimização Momentum utiliza os conceitos de aceleração da física para atingir o objetivo. Baseada no gradiente descendente, ela leva em consideração cada gradiente local do vetor de momentum m (multiplicado pela taxa de aprendizagem η) e atualiza os pesos adicionando esse vetor de momentum. Devido a este comportamento, ela irá acelerar o aprendizado cada vez mais até atingir o fundo, o ideal. Em redes neurais profundas que não usam a normalização em lote, as camadas superiores muitas vezes acabam tendo entradas com escalas muito diferentes, então usar a otimização de momento ajuda muito. Também pode ajudar a caminhar para além dos ótimos locais (GÉRON, 2019, p.345-346).

SGD

A função de otimização SGD, uma abreviação para *Stochastic Gradient Descent*, é baseada no Gradiente Descendente e tem como princípio escolher aleatoriamente uma instância do conjunto de dados do treinamento em cada etapa e calcula os gradientes com base apenas nessa única instância. Desta maneira, o algoritmo torna-se muito veloz, uma vez que poucos dados são utilizados para manipular cada iteração (GÉRON, 2019, p.126).

Entretanto, esta característica estocástica, ou seja, aleatória ao escolher os dados torna-o menos regular do que outros algoritmos. Com isso, a cada iteração, ao invés de diminuir suavemente até encontrar um mínimo, a função irá oscilar tanto para cima quanto para baixo, diminuindo apenas na média. Com o tempo, ele atingirá valores próximos ao mínimo, os quais serão bons, contudo não serão os ótimos (GÉRON, 2019, p.126).

AdaGrad

A função de otimização AdaGrad é uma implementação muito similar ao algoritmo SGD, podendo ser entendido até mesmo como uma variante. Seu princípio se baseia em diminuir a taxa de aprendizado adaptativamente, ou seja, será mais rápida para dimensões íngremes do que para dimensões com declives mais suaves, melhorando o direcionamento em relação ao ótimo global das atualizações resultantes (GÉRON, 2019, p.347).

AdaGrad geralmente apresenta um bom funcionamento para problemas quadráticos simples, entretanto, durante o treinamento de redes neurais a taxa de aprendizado pode ser reduzida além do esperado resultando em uma estagnação do processo antes mesmo de atingir o ótimo global (GÉRON, 2019, p.348).

Adam

A função de otimização Adam, um acrônimo para *adaptive moment estimation*, combina a ideia da otimização Momentum e RMSProp (função de otimização baseada no algoritmo AdaGrad, a qual acumula apenas os gradientes das iterações mais recentes) (GÉRON, 2019, p.349).

Seu princípio se baseia na ideia de manter o controle no decaimento de uma média exponencial dos gradientes descendentes anteriores (Momentum), e também o controle no decaimento de uma média exponencial dos gradientes quadráticos anteriores (RMSProp). De maneira geral, esta função apresenta bons resultados, convergindo rapidamente para soluções satisfatórias (GÉRON, 2019, p.349-351).

2.2.3 RNAs aplicadas às séries temporais

Segundo Nascimento et al. (2017), “uma série temporal constitui-se em qualquer conjunto de dados ou variáveis ordenadas no tempo, ou qualquer outra variável que desempenhe a função de índice”. O estudo voltados para este tipos de séries são de extrema relevância para a ciência. Acompanhar dados demográficos, cotação de ativos em bolsas de valores, dados demográficos, entre outros, são exemplos de séries temporais.

Henriques e Neves (2017), assim como (LIU; WANG, 2012), menciona avanços nos estudos relacionados a aplicação de RNA para previsão de séries temporais. Um dos principais motivos é a capacidade das RNAs de serem auto adaptativas, não sendo necessário realizar quaisquer suposições sobre o modelo, tão pouco ter um conhecimento do processo que gera a série temporal *a priori*.

2.3 Mercado financeiro voltado para *Day Trade*

O mercado financeiro é um campo de estudo extremamente vasto, com inúmeros produtos e serviços de renda fixa e renda variável, diversas formas de negociação e ativos. Existem produtos e serviços para todos os tipos de investidores, estratégias, etc.

Voltado para mercado de *Day Trade*, o mercado futuro é um dos principais ambientes onde são negociados contratos futuros, um tipo de derivativo. Contratos futuros representam um direito de compra ou venda de ativos físicos ou financeiros em uma determinada data futura e preços previamente acordados entre as partes. Este tipo de mercado pode ser utilizado para realizar proteção de carteira do investidor ou pode ser também utilizado para auferir lucro devido a diferença entre preços (INVESTIDOR, 2020). Considere o seguinte cenário:

No dia 01 de novembro de 2020, 1 dólar comercial equivale a R\$ 5,74. Neste dia, um investidor recebe uma oferta onde poderá comprar 1 dólar pelo valor de R\$ 5,76 no dia 10 do mesmo mês caso pague R\$ 0,02 por este direito. Durante este acontecimento, este investidor recebe uma informação a qual o dólar no dia 10 estará valendo R\$ 5,90 devido a variações cambiais. Logo, podemos notar que: se o investidor efetivar a compra, ele terá realizado um bom negócio, uma vez que terá comprado o ativo por um valor abaixo do valor de mercado

neste momento, podendo até mesmo realizar sua venda logo após o recebimento do ativo.

$$R\$5,76 + R\$0,02 = R\$5,78(\text{valor total pago}) < R\$5,90(\text{valor de mercado})$$

2.3.1 Mini dólar

Assim como mencionado no Capítulo 1, Mini Dólar é um contrato futuro. A data de vencimento é no 1º dia útil do mês de vencimento do contrato. O lote padrão corresponde a 1 contrato podendo ser negociado até a seção anterior a data de vencimento do contrato (B3, 2020a). Em relação a valores financeiros, um mini contrato de dólar representa um valor financeiro de US\$ 10.000. Cada ponto do dólar está associado ao valor de R\$ 10,00. Ou seja, caso o dólar suba 1 ponto, o lucro financeiro será de R\$ 10,00 para cada contrato negociado. Caso o dólar perca seu valor, o inverso é verdadeiro, resultando em um prejuízo de R\$ 10,00 por contrato para cada ponto (RICO, 2021).

Durante as negociações, este ativo atende pela sigla WDO, seguidos por uma letra e dois números. Os números representam os dois últimos dígitos do ano de vencimento do contrato, enquanto que a letra corresponde ao mês, seguindo a seguinte ordem:

- Janeiro (F)
- Fevereiro (G)
- Março (H)
- Abril (J)
- Maio (K)
- Junho (M)
- Julho (N)
- Agosto (Q)
- Setembro (U)
- Outubro (V)
- Novembro (X)
- Dezembro (Z)

Um contrato com código WDON21 representa um contrato de mini dólar o qual terá como vencimento no primeiro dia útil de Julho de 2021.

Figura 4 – Histórico de preços do mini dólar.




Fonte: (TRADINGVIEW, 2021)

2.3.2 Candlesticks e tempo gráfico

Para a realização de uma análise técnica em relação a um ativo, a representação gráfica é uma ferramenta crucial. Uma das diversas abordagens na construção dos gráficos de ativos recebe o nome de *Candlestick*. Tal metodologia evidencia o preço de um ativo ao longo de um dado período. O formato adotado é chamado de *Candle* ou vela (CLEAR, 2011).

Cada *candle* compila as informações referentes ao preço de abertura, fechamento, máxima, mínima e a tendência do ativo durante o período gráfico escolhido. Este período é denominado tempo gráfico. Exemplo: para um tempo gráfico de 5 minutos (M5), cada *candle* representará a movimentação do preço do ativo neste intervalo, evidenciando a abertura, fechamento, máxima, mínima e a tendência.

A figura 5 exemplifica a construção de um *candle* de alta e um de baixa. Para *candles* de alta são comumente utilizadas as cores verde ou branco, enquanto que para os *candles* de baixa são utilizadas as cores vermelho e preto.

Figura 5 – Representação gráfica de um *candle* de alta e de baixa.

Fonte: (INVESTIDOR, 2013)

Figura 6 – Exemplo de gráfico *Candlestick*.

Fonte: (INVESTIDOR, 2013)

2.3.3 Indicadores técnicos

Indicadores técnicos são uma parte crucial do presente trabalho. Nas principais plataformas de negociação eles são calculados de maneira automática, sendo necessário apenas configurar alguns parâmetros de acordo com a necessidade do usuário. Abaixo são apresentados alguns indicadores, bem como os cálculos e parâmetros associados.

Média Móvel Simples

Média Móvel Simples é um indicador da análise técnica dado pela fórmula:

$$MMS(p) = \frac{\sum_{i=1}^p P_{i-1}}{p} \quad (2.4)$$

MMS representa o valor da média móvel

p representa o número de períodos desejado

P_t representa o preço do fechamento do ativo no instante t

Durante análises técnicas são utilizadas 2 ou mais médias móveis com períodos diferentes. O ponto de atenção neste processo é dado nos cruzamentos das diferentes médias móveis. Quando uma média móvel com período mais curto intercepta de cima pra baixo uma média móvel com período mais longo, indica uma tendência de queda no preço dos ativos. Ao mesmo tempo que, quando uma média móvel mais curta intercepta a média móvel mais longa de baixo para cima indica uma tendência de alta no preço dos ativos (SAFFI, 2003).

Figura 7 – Média móvel simples calculada para 21 períodos.



Fonte: (METAQUOTES, 2020)

Média Móvel Exponencial

Média Móvel Exponencial ou MME remete a um comportamento similar à Média Móvel Simples, entretanto, ela atribui um peso diferente para os valores de acordo com a sua proximidade. Ou seja, quanto maior o tempo entre o valor calculado no momento, menor será o peso atribuído a ele.

A equação para o cálculo da MME é dada por:

$$MME(p) = P_t \left(\frac{2}{p+1} \right) + MME(P_{t-1}) \cdot \left(1 - \left(\frac{2}{p+1} \right) \right) \quad (2.5)$$

MME representa o valor da média móvel

p representa o número de períodos desejado

P_t representa o preço do fechamento do ativo no instante t

Médias Móveis Exponenciais são mais sensíveis a eventos recentes se comparado a MMS, desta forma, ela se aproxima mais do valor real do ativo. Tal fato pode ser verificado até mesmo analisando a Equação 2.5

Figura 8 – Média móvel exponencial calculada para 21 períodos.



Fonte: (METAQUOTES, 2020)

Índice de Direção do Movimento

Índice de movimento direcional, ou ADX, é um indicador de tendência o qual busca evidenciar se um ativo possui forte tendência e as sinalizações das movimentações futuras do ativo. Desenvolvido por J. Welles Wilder Jr, ele busca antecipar as movimentações através de cálculos utilizando a relação entre os preços anteriores. É composto por dois indicadores: Indicador Direcional Positivo (+DI) e Indicador Direcional Negativo (-DI). Estes por sua vez são calculados a partir das máximas e mínimas dado o período especificado (REIS, 2019).

O resultado do indicador ADX é dado por:

$$ADX(p) = MA \left(\frac{DI_1 - DI_2}{DI_1 + DI_2} \right) \cdot 100 \quad (2.6)$$

p representa o período, em dias;

$ADX(p)$ representa o resultado do índice;


DI_1 representa o indicador da direção positiva;

DI_2 representa o indicador da direção negativa;

$MA(x)$ representa a função de média móvel;

Os resultados contemplam o intervalo entre 0 e 100. Para os valores abaixo de 20, o indicador remete a um enfraquecimento da tendência. Para os valores acima de 25 remetem a uma crescente. Valores acima de 40 são identificados como uma tendência forte.

Figura 9 – Índice de Direção do Movimento.



Fonte: (METAQUOTES, 2020)

Estocástico

O indicador Estocástico surgiu na década de 1950. Elaborado por George C. Lane, tem como objetivo indicar pontos propícios para se realizar compras ou vendas de determinado ativo (SAFFI, 2003). É composto por duas linhas principais: o Estocástico rápido ($%K$) e o Estocástico lento ($%D$). Para o Estocástico rápido, temos:

$$%K(p) = 100 \left(\frac{P_t - L_p}{H_p - L_p} \right) \quad (2.7)$$

p representa o período analisado

$%K$ representa o valor do Estocástico rápido

P_t representa o preço de fechamento no momento

L_p representa a mínima no período analisado

H_p representa a máxima no período analisado

Para o Estocástico lento, temos:

$$%D(p) = MMS(%K, p) \quad (2.8)$$

p representa o número de períodos


$%D(p)$ representa o valor do Estocástico lento

$MMS(%K, p)$ representa o valor da média móvel simples para p períodos calculada a partir dos valores de $%K$

HiLo


Em 1998 publicado na revista *Stocks & Commodities Magazine*, *HiLo Activator* foi apresentado ao mundo pelo seu criador Robert Krausz. Trata-se de uma ferramenta a qual auxiliará o investidor a escolher o melhor ponto de entrada de operação e, além disso, pode indicar também os pontos de inversão de tendência do preço dos ativos. Ele é calculado a partir da média

Figura 10 – Estocástico calculado considerando %K igual a 5 períodos e %D igual a 3.



Fonte: (METAQUOTES, 2020)

Figura 11 – Exemplo de um gráfico aplicando um HiLo Activator.



Fonte: (METAQUOTES, 2020)

das altas (topo diário) ou quedas (mínima diária) do mercado, a depender da tendência gráfica (RIBEIRO, 2011).

Na Figura 11, quando a linha azul está plotada no gráfico abaixo dos *candles*, segundo o HiLo, trata-se de uma tendência de valorização do ativo. Nos períodos onde a linha vermelha está sendo exibida acima dos *candles*, remete-se a uma tendência de desvalorização do ativo.

Como estratégia de operações com base neste indicador, um sinal de compra é gerado no momento em que o ativo muda sua tendência de queda para tendência de alta (na Figura 11, representado pelos intervalos onde a linha do *HiLo* altera da cor vermelha para azul). Um sinal de venda possui o comportamento contrário: é gerado no momento em que o ativo muda sua tendência de alta para tendência de queda.

2.3.4 Técnicas para negociação

Além do uso de indicadores, existem algumas técnicas utilizadas por *traders* os quais buscam minimizar possíveis perdas e aumentar a assertividade nas operações, consequentemente melhorando os lucros obtidos. Algumas destas técnicas serão abordadas nesta seção.

Setup operacional

Para a realização de negociações utilizando como base a análise técnica, algumas estratégias são adotadas. Tais estratégias são compostas por um conjunto de critérios os


quais definem se deverá ser executado uma operação ou não em um determinado momento. Este conjunto de critérios é denominado *setup* operacional. Pode ser composto por diversas condições associadas à indicadores e seus respectivos valores em instante de tempo, como por exemplo: se um indicador ADX estiver indicando uma tendência forte, acima de 40, então, no cruzamento as médias móveis deverá ser executadas as operações de compra ou venda seguindo a tendência (PINHEIRO, 2019).

Setups operacionais são considerados pessoais, variando de *trader*¹ para *trader*, de acordo com as suas respectivas estratégias.

Stop Loss

Stop loss trata-se de uma ordem de compra ou venda na qual é posicionada de maneira a evitar perdas maiores caso a movimentação seja contrária a movimentação esperada pelo *trader* durante negociações anteriores. Exemplo: Suponha que um determinado *trader* acredite que o preço de um papel irá subir, então ele realiza uma compra a um preço X. Entretanto, o mercado passa a negociar o papel a um preço inferior se comparado ao valor X pago e este passa para uma tendência de baixa, podendo trazer grandes prejuízos especialmente se esta dinâmica ocorrer de forma veloz. Logo, uma maneira de minimizar estes riscos é definir um limite máximo aceitável de perda. Caso o preço do papel atinja este limite, a posição é desfeita evitando assim perdas ainda maiores (INFOMONEY, 2006). Em outras palavras, se o *trader* está em uma posição comprada e o papel passa a negociar em uma tendência de baixa atingindo o mínimo aceitável, o *trader* irá então realizar uma ordem de venda de acordo com a posição comprada, assumindo os prejuízos para evitar maiores perdas.

Figura 12 – Exemplo de um gráfico com stop loss.



Fonte: (METAQUOTES, 2020)

A figura 12 retrata um gráfico exemplificando uma situação de *stop loss*. Neste exemplo, trata-se de uma negociação buscando a queda do preço do ativo neste determinado instante. A linha verde representa o valor negociado e a linha em vermelho na horizontal representa o valor de uma ordem *stop loss* a fim de evitar maiores perdas caso o ativo altere sua tendência.

¹ *Day Trader*, ou apenas *trader*, é o nome dado às pessoas as quais realizam operações de compra e venda de um determinado ativo no mesmo dia, buscando ganhos financeiros.

Stop Gain

Stop gain, também conhecido como *take profit*, refere-se a um mecanismo similar ao *stop loss* descrito na seção 2.3.4. Este por sua vez comporta-se de uma maneira inversa, ou seja, é definido um valor considerado como sendo objetivo. Logo, uma vez que o papel alcance tal objetivo, é realizada a negociação independentemente se o ativo permanecer na tendência analisada ou não. Esta técnica busca garantir os lucros obtidos antes de uma possível reversão de tendência, o que poderia causar uma redução nos ganhos da operação (TORO, 2021).

Figura 13 – Exemplo de um gráfico com *stop gain* e *stop loss*.



Fonte: (METAQUOTES, 2020)


A figura 13 demonstra um gráfico contendo uma ordem de *stop gain*. Esta sendo representada pela linha vermelha pontilhada mais abaixo na figura, enquanto que a linha verde retrata o preço de negociação, sendo assim possível perceber o objetivo definido por tal negociação.

Trailing Stop

Trailing Stop refere-se a um mecanismo utilizado por traders os quais desejam gerenciar riscos e lucros de acordo com a movimentação do mercado. Trata-se de uma ferramenta a qual tem como objetivo reposicionar as ordens de *Stop Loss* de acordo com a tendência (NELOGICA, 2021).


As figuras 14 e 15 representam um exemplo de utilização do *Trailing Stop*. Ambas as figuras retratam a mesma janela de negociações. As linhas em vermelho representam os níveis das ordens de *stop loss* posicionadas enquanto que a linha em verde refere-se ao *candle* analisado. Na figura 14 é possível notar que a ordem de *stop loss* está posicionada em 5603 pontos. Logo em seguida, a movimentação do mercado mantém sua tendência, então, esta ordem de *stop loss* é reposicionada para 5608 pontos, sendo possível assim gerenciar os ganhos, mesmo que ocorra uma reversão de tendência.

Figura 14 – Exemplo de aplicação de um mecanismo de Trailing stop.



Fonte: (METAQUOTES, 2020)

Figura 15 – Exemplo de aplicação de um mecanismo de Trailing stop.



Fonte: (METAQUOTES, 2020)

2.3.5 Plataforma de negociações

Para realizar a compra e venda de ativos são utilizadas plataformas de negociações. Tais plataformas podem ser de alguma corretora de investimentos ou de outra empresa independente porém possui uma integração com as principais corretoras do mercado financeiro. Existem diversas opções para os investidores, entretanto, nesta seção nos ateremos apenas a 3 exemplos.

Profit Pro

Profit Pro é uma das plataformas mais conceituadas no mercado financeiro. Pertencente a empresa Nelogica, esta plataforma possui integração com diversas corretoras de investimentos. Para ter acesso o investidor deverá assinar e realizar o pagamento de uma mensalidade (este valor pode variar de acordo com a forma de contratação, se é por intermédio de alguma corretora ou diretamente pelo site da empresa proprietária).

Esta plataforma é mais difundida entre investidores mais qualificados e que realizam suas operações de maneira manual.

Figura 16 – Profit Pro.




Fonte: (NELOGICA, 2020)

Home Brokers

Home Broker é o nome dado as plataformas de negociação fornecidas pelas corretoras de investimentos. Normalmente são acessados via página WEB ou aplicativo de forma gratuita. É específico de cada corretora, mas em sua grande maioria são plataformas mais limitadas aos investidores mais experientes, sendo utilizadas majoritariamente por iniciantes ou investidores os quais realizam poucas operações durante o dia.

Figura 17 – Home Broker da corretora Clear.




Fonte: (CLEAR, 2020)

MetaTrader 5

Metatrader é uma plataforma para a realização de negociações online, realizar análise técnica, além de permitir a criação de operações automatizadas a partir de algoritmos específicos os quais podem ser codificados por desenvolvedores independentes e executados

dentro da plataforma. Possui integração com diversas corretoras, entretanto, pode haver custos durante a compra e venda de ativos variando de acordo com a corretora escolhida pelo investidor.

Figura 18 – Metatrader 5.



Fonte: (METAQUOTES, 2020)

Em comparação com as demais plataformas, o Metatrader possui uma usabilidade mais complexa, ao mesmo tempo que proporciona inúmeras funcionalidades já implementadas e disponíveis para usuários, sendo utilizada principalmente por usuários mais experientes ou os quais desejam operar de forma automatizada, por meio de robôs.

2.4 Ferramentas computacionais

Além de conceitos relacionados ao mercado financeiro, é necessário ter em mente algumas ferramentas importantes as quais facilitam o desenvolvimento de diversas aplicações, fornecendo diversos mecanismos os quais tornam a implementação mais ágil e segura. Algumas dessas ferramentas serão descritas nesta seção.

2.4.1 NodeJs

Node.js trata-se de uma *runtime engine* a qual permite que se execute códigos Javascript em servidores, o que torna-o muito eficiente em diversos cenários, sendo eles em ambientes com *hardware* limitado, grande volume de tarefas assíncronas simultâneas, entre outros (FOUNDATION, 2021b). Além disso, a utilização do Javascript como linguagem permite utilizar até mesmo uma mesma *codebase* em diversos ambientes, tanto em servidores quanto clientes, fornecendo uma ótima flexibilidade. Com os avanços dos conceitos da programação

orientada a objetos e do Typescript² tornou o desenvolvimento de soluções com o NodeJs ainda mais confiável, aumentando também sua manutenibilidade.

2.4.2 Express

Express é um framework para Node.js, tratado na seção 2.4.1, o qual fornece um conjunto de recursos os quais simplificam a criação de APIs para serem executadas no Node.js. Desta maneira, o gerenciamento de requisições HTTP é facilitado, além de apresentar uma boa performance (FOUNDATION, 2021a).

2.4.3 Tensorflow

Segundo Abadi et al. (2015), "Tensorflow é a principal biblioteca de código aberto para desenvolver e criar modelos de Machine Learning". Ela fornece bons níveis de abstração aos desenvolvedores os quais podem focar apenas na lógica aplicada e na modelagem, ao invés de gastar esforços implementando modelos de aprendizado de máquina manualmente, verificando aprendizados, entre outros. Além disto, por tratar de uma biblioteca mantida por diversos programadores, trata-se de uma ferramenta estável, reduzindo assim possíveis erros gerados durante a codificação de modelos.

Tensorflow.js possui implementações em diversas linguagens, tais como Python, Java e Javascript, permitindo utilizar modelos tanto no *Client Side*, quanto no *Server Side*, além de fornecer uma documentação de fácil entendimento diminuindo consideravelmente a curva de aprendizado.


² Typescript é um superset a partir da linguagem de programação Javascript o qual adiciona algumas funcionalidades a mais tais como tipagem de objetos, auxiliando no desenvolvimento. Para ser utilizado com o Nodejs, é necessário que seja feita a compilação para o Javascript

3 Procedimentos metodológicos

“Um bom começo é a metade”.
Aristóteles

Esta seção destina-se a evidenciar de forma detalhada todos os procedimentos metodológicos a serem utilizados para a realização do trabalho. A Figura 19 sintetiza o fluxo dos procedimentos metodológicos. As sessões seguintes descreve mais detalhadamente os passos citados.

Figura 19 – Procedimentos metodológicos.



Fonte: elaborada pelo autor

3.1 Classificação da pesquisa

Levando em consideração as classificações de pesquisa de Wazlawick (2010), o presente trabalho tem caráter exploratório devido ao objetivo de se examinar fenômenos relacionados aos ativos do mercado financeiro, especialmente o mini-dólar, buscando compreendê-los e realizar previsões com a menor taxa de erro possível. Sob a ótica de procedimentos técnicos, trata-se de uma pesquisa experimental na qual é estudado a cotação do ativo e a relação com indicadores técnicos a fim de identificar padrões, possibilitando assim realizar ajustes em pesos da rede neural de maneira a melhorar os resultados obtidos.

3.2 Revisão bibliográfica

Inicialmente foi realizado uma revisão bibliográfica da literatura no Capítulo 2. Como fonte principais de informações foi consultado o Portal de Periódico da CAPES, Google Scholar e canais relacionados ao mercado financeiro.

3.3 Definição dos indicadores utilizados

Os indicadores escolhidos foram Média Móvel Simples, Média Móvel Exponencial, ADX e o Estocástico para entradas. HiLo Activator será utilizado para definir os momentos certos de compra e venda das posições de forma a explorar as melhores oportunidades. Estes foram selecionados de acordo com as suas características principais, de forma que trabalhem em conjunto. O período de valores a ser utilizado por cada indicador será de acordo com o peso definido empiricamente para ele.

Além dos indicadores técnicos citados acima, será utilizado informações extras relacionadas à cotação do ativo no momento, tais como o preço de abertura, fechamento, máximas, mínimas, volume de negociação e um sinal indicando se o preço de fechamento foi superior ao preço de abertura.

3.4 Definição da plataforma de negociação

Para a realização da implementação foi escolhida a plataforma Metatrader 5 em virtude da sua ampla gama de funcionalidades, integrações, e principalmente devido a capacidade de criação de robôs por meio de algoritmos, permitindo assim a automatização das operações.

3.5 Definição das estratégias de *Day Trade*

Para a realização das negociações algumas estratégias de *Day Trade* foram utilizadas para gerenciar as ordens de compra e venda. O setup escolhido será a mudança de tendência ocasionada no indicador HiLo. Para cada negociação, foi utilizado a técnica de *Stop Loss*, *Trailing Stop* e *Stop Gain* descritas na seção 2.3.4. Estes parâmetros foram manipulados de acordo com a necessidade de adequação ao mercado.

3.6 Definição dos modelos a serem treinados

Com o objetivo de verificar o desempenho de diferentes variações de redes neurais artificiais, foram propostas 5 topologias escolhidas empiricamente a partir da revisão bibliográfica. Todas elas compartilham da aplicação de um MLP juntamente com o algoritmo de *Back Propagation*. A primeira camada será composta pelo mesmo número de entradas para todas, uma vez que todas utilizam os mesmos indicadores como entradas, como descrito na seção 3.3. O resultado processado pela camada de saída de cada rede é compreendido entre $[0, 1]$. Desta maneira, como trata-se de um problema de classificação, os valores presentes no intervalo $[0, 0,5[$ serão atribuídos a classe 0 e os valores entre $[0,5, 1]$ a classe 1.

Com intuito de obter um melhor aprendizado, para cada variação duas redes serão treinadas separadamente: uma para especialização em operações de compra e a outra especializada em operações de venda. Vale ressaltar que ambas possuem a mesma topologia.

3.6.1 Variação 1

A primeira variação proposta é constituída por um MLP contendo duas camadas, de acordo com a tabela 1, e função de otimização Adagrad.

Tabela 1 – Variação 1 - topologia da rede.

Camadas	nº de neurônios	nº de saídas	Função de ativação	Utilização do Bias
1ª camada	105	54	Tangente Hiperbólica	Não
2ª camada	54	1	Sigmoidal	Não

Fonte: Elaborada pelo autor.

3.6.2 Variação 2

A segunda variação proposta é constituída por um MLP contendo quatro camadas, de acordo com a tabela 2, e função de otimização Adagrad.

Tabela 2 – Variação 2 - topologia da rede.

Camadas	nº de neurônios	nº de saídas	Função de ativação	Utilização do Bias
1ª camada	105	105	Tangente Hiperbólica	Sim
2ª camada	105	54	Tangente Hiperbólica	Não
3ª camada	54	26	ReLU	Não
4ª camada	26	1	Sigmoidal	Não

Fonte: Elaborada pelo autor.

3.6.3 Variação 3

A terceira variação proposta é constituída por um MLP contendo três camadas, de acordo com a tabela 3, e função de otimização Adagrad.

Tabela 3 – Variação 3 - topologia da rede.

Camadas	nº de neurônios	nº de saídas	Função de ativação	Utilização do Bias
1ª camada	105	105	Tangente Hiperbólica	Sim
2ª camada	105	25	Tangente Hiperbólica	Sim
3ª camada	25	1	Sigmoidal	Sim

Fonte: Elaborada pelo autor.

3.6.4 Variação 4

A quarta variação proposta é constituída por um MLP contendo três camadas, de acordo com a tabela 4, e função de otimização Adam.

Tabela 4 – Variação 4 - topologia da rede.

Camadas	nº de neurônios	nº de saídas	Função de ativação	Utilização do Bias
1ª camada	105	105	ReLU	Sim
2ª camada	105	25	ReLU	Sim
3ª camada	25	1	Sigmoidal	Sim

Fonte: Elaborada pelo autor.

3.6.5 Variação 5

A quinta variação proposta é constituída por um MLP contendo três camadas, de acordo com a tabela 5, e função de otimização Adam.

Tabela 5 – Variação 5 - topologia da rede.

Camadas	nº de neurônios	nº de saídas	Função de ativação	Utilização do Bias
1ª camada	105	105	Tangente hiperbólica	Sim
2ª camada	105	25	ReLU	Não
3ª camada	25	1	Sigmoidal	Não

Fonte: Elaborada pelo autor.

3.7 Codificação

A codificação é uma importante fase do desenvolvimento. Esta seção irá descrever a arquitetura utilizada, bem como as estratégias utilizadas.

3.7.1 Obtenção dos dados

Para realizar o treinamento da RNA é preciso obter uma base de dados consistente e classificá-la para então inseri-la na rede. Para esta etapa, será implementado um algoritmo na linguagem MQL5 o qual será responsável por realizar a leitura dos dados de cada indicador, além das informações básicas sobre a cotação do ativo, e então salvá-los em um arquivo texto. Cada linha deverá conter todos os dados de um instante de tempo, separados por uma vírgula. MQL5 será utilizado nesta etapa devido à facilidade de obtenção dos dados através do Metatrader 5.


A obtenção dos dados se dá nos momentos propícios para cada rede de acordo com a saída do indicador HiLo, ou seja, os dados são coletados quando for disparado um sinal de compra ou um sinal de venda de acordo com o indicador HiLo, seguindo as definições a seguir:

- Para a rede especializada na compra: quando a saída do indicador HiLo alterar o sentido indicando a troca de tendência de baixa para alta e no instante seguinte esta tendência for confirmada, o sinal de compra será disparado na abertura do próximo *Candle*. Figura 20.

- Para a rede especializada na venda: quando a saída do indicador HiLo alterar o sentido indicando uma tendência de alta para baixa e no instante seguinte esta tendência for confirmada, o sinal de venda será disparado na abertura do próximo *Candle*. Figura 21.


Após a obtenção dos dados, estes são rotulados de acordo com os eventos futuros, indicando se eles realmente eram momentos adequados para a realização de operações ou não. Para cada operação ser considerada como adequada esta deve resultar em um ganho de no mínimo 5 pontos, independentemente se refere-se a compra ou venda.

Figura 20 – HiLo: exemplo de um sinal de compra.



Fonte: (METAQUOTES, 2020)

Figura 21 – HiLo: exemplo de um sinal de venda.



Fonte: (METAQUOTES, 2020)

3.7.2 Desenvolvimento de API para treinamento


Após a obtenção dos dados, o próximo passo é realizar o desenvolvimento e treinamento das redes neurais. Para esta etapa, é necessário então implementar uma API WEB utilizando as ferramentas NodeJS, Express e Tensorflow a qual seja capaz de receber requisições HTTP e executar métodos associados ao treinamento e previsão de acordo com parâmetros enviados juntamente com as requisições.

Para cada variação de MLP proposta na seção 3.6, uma rede neural artificial deve ser implementada utilizando a biblioteca Tensorflow. Para a realização do treinamento, o algoritmo deve ser capaz de realizar a leitura de arquivos de textos gerados na etapa de obtenção dos dados, descrita na seção 3.7.1, e então utilizá-los como base de treino para o processo. Após a realização do treinamento, o algoritmo deve então armazenar os respectivos pesos obtidos em um arquivo no sistema local para a utilização posterior.

Além de embarcar as redes neurais, esta API deve ser capaz de expor 3 interfaces para o processamento de dados, sendo elas:

- Treinar: esta interface deve ser capaz de receber parâmetros relacionados a qual especialização (compra ou venda) e o número de épocas desejado;
- Predizer: esta interface deve ser capaz de receber um conjunto de dados referente a apenas uma entrada e então responder a qual classe pertence os respectivos parâmetros;
- Predizer em lote: esta interface deve ser capaz de receber um conjunto de dados de diversas entradas, contendo valores dos indicadores e então responder a qual classe pertence cada entrada;

Figura 22 – Fluxograma evidenciando a integração entre a API e o Metatrader.



Fonte: elaborada pelo autor

A escolha de tecnologias baseadas em Nodejs foi devido a disponibilidade de uma implementação do Tensorflow e pela eficiência na execução de tarefas consumindo poucos recursos, tornando-o viável para execução em diversos ambientes. Além disso, capacidade de utilizar a linguagem Typescript fornece uma melhor legibilidade e confiabilidade durante o desenvolvimento, em virtude de ser fortemente tipada.

3.7.3 Testar a previsibilidade do modelo

Para verificar a previsibilidade do modelo treinado, um novo algoritmo deverá ser desenvolvido em Typescript, no qual deve ser capaz de realizar a leitura de um arquivo texto contendo uma base de dados rotulados e enviar requisições para a interface de predição em lote, descrita na seção 3.7.2, e então comparar o retorno obtido com o retorno esperado para cada uma das respectivas amostras. Ao final, o resultado final deve ser exibido em formato de porcentagem e indicadores de acerto/erro em cada entrada.

Vale ressaltar que para a obtenção dos dados deve se utilizar o mesmo algoritmo descrito na seção 3.7.1, entretanto de um período diferente do utilizado durante o treinamento a fim de evitar possíveis *overfits*, ocasionando uma má interpretação dos resultados.

3.7.4 Realizar negociações com a rede treinada

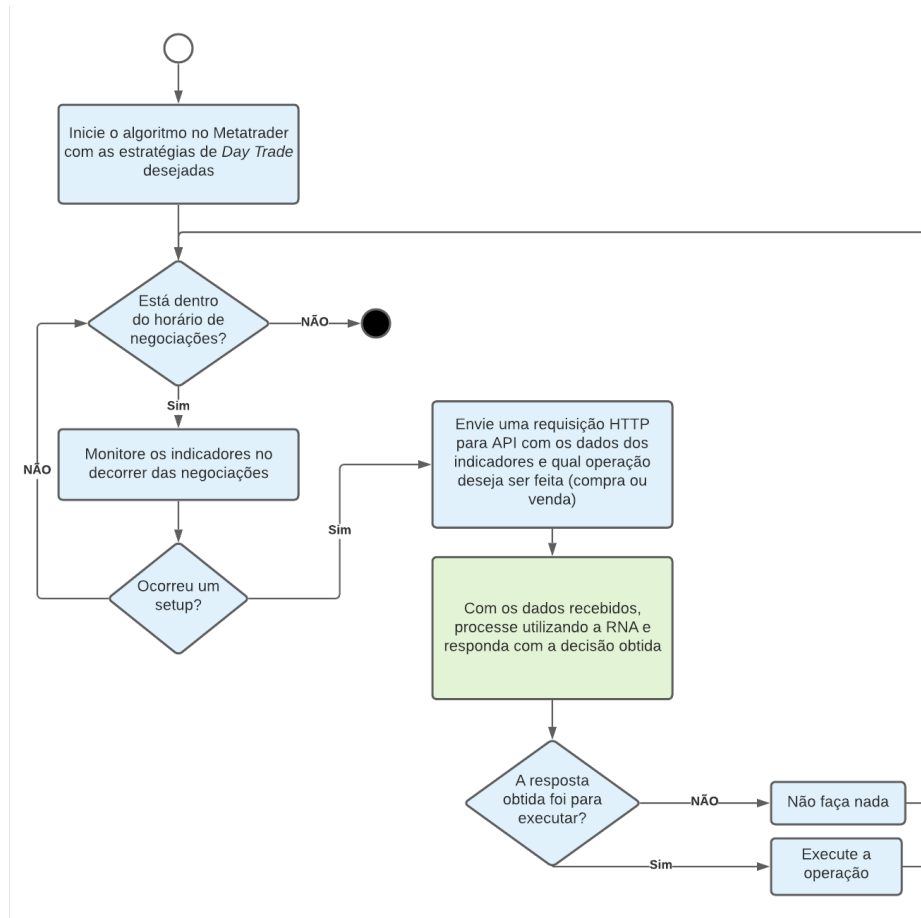
Uma vez que o modelo treinado tenha apresentado bons resultados durante os testes de previsibilidade, este está apto a realização de negociações em tempo real através do Metatrader. Para isto, um novo algoritmo em MQL5 deve ser implementado de maneira que seja capaz de:

- Realizar a leitura dos indicadores selecionados para o setup;
- Enviar requisições HTTP passando os parâmetros necessários;
- Identificar a resposta obtida das requisições, definindo se operações devem ser executadas em determinado instante ou não;
- Criar e manipular negociações aplicando as técnicas de *Day Trade* de acordo com a estratégia estipulada;
- Gerar relatórios evidenciando todas as negociações e seus respectivos lucros/prejuízos;

A figura 23 representa o fluxo da informação para a realização das negociações. Os passos em azul são executados no Metatrader, enquanto que os demais em verde são de responsabilidade da API.

É importante ressaltar que ao desenvolver em MQL5 apenas o necessário para a realização das negociações e em Typescript todo o código necessário para a rede neural reduz consideravelmente o acoplamento entre as partes do projeto, permitindo assim utilizar as principais funcionalidades de cada linguagem além de fornecer uma maior flexibilidade para a manipulação da rede neural, variando topologias, parâmetros, entre outros.

Figura 23 – Fluxo de operações para realização das negociações.



Fonte: elaborada pelo autor

3.8 Análise e exposição dos resultados obtidos

Ao final, os resultados são analisados utilizando as redes neurais treinadas durante o processo descrito para simular operações de compra e venda do ativo, verificando desta maneira se o procedimento culminou em uma boa previsibilidade, ou seja, se é possível obter ganhos financeiros com os procedimentos realizados no presente trabalho. Após cada período de negociações, um relatório financeiro deve ser gerado para fins comparativos.

4 Desenvolvimento

*“Há apenas um bem, o saber;
e apenas um mal, a ignorância”.*
Sócrates

Este capítulo destina-se a detalhar os passos utilizados para a realização do desenvolvimento do presente trabalho, seguindo os procedimentos metodológicos citados na seção 3.

4.1 Obtenção e rotulação dos dados

Inicialmente é necessário obter os dados dos respectivos indicadores escolhidos de acordo com a seção 3.3. Analisando os diversos indicadores que a plataforma Metatrader disponibiliza por padrão foi possível encontrar os indicadores Média Móvel Simples, Média Móvel Exponencial, ADX e Estocástico. Logo, para estes foi necessário realizar a leitura da documentação disponível para então utilizá-los. Entretanto, o Hilo não está disponível por padrão na plataforma, sendo necessário realizar a codificação do indicador de maneira que atenda os requisitos necessários para ser utilizado e gerar os sinais de operação necessários.

Tabela 6 – HiLo: configuração utilizada.

Parâmetro	Valor
Períodos	3
Média Móvel	Simples

Fonte: Elaborada pelo autor.

Tabela 7 – Estocástico: configuração utilizada.

Parâmetro	Valor
Períodos para %K	5
Períodos para %D	3
Média Móvel	Simples

Fonte: Elaborada pelo autor.

Tabela 8 – ADX: configuração utilizada.

Parâmetro	Valor
Períodos	9

Fonte: Elaborada pelo autor.

Tabela 9 – Médias Móveis: configuração utilizada.

Parâmetro	Valor
Períodos	5, 11, 21, 44 e 66
Média Móvel	Exponencial

Fonte: Elaborada pelo autor.

Com todos os indicadores disponíveis para a coleta dos dados, um algoritmo em MQL5 foi implementado de maneira que fosse possível realizar a leitura dos valores de cada indicador nos momentos propícios para a realização de negociações indicados pelo HiLo e a rotulação dos dados analisando os valores futuros. Para a execução, foi necessário definir apenas o intervalo desejado e o valor mínimo para que uma operação fosse rotulada como lucro (os demais valores serão definidos por padrão). Uma vez definidos, a rotulação seguirá a equação 4.1.


$$l(t, m) = \begin{cases} 1, & \text{caso } r \geq m \\ 0, & \text{caso } r < m \end{cases} \quad (4.1)$$

Onde:

- t representa o instante de tempo;
- r representa o resultado final da operação, em pontos;
- m representa o valor mínimo informado pelo usuário;

As figuras 24 e 25 mostram a tela do Metatrader para a obtenção dos dados. Na figura 24 é possível identificar o intervalo de data desejado. Na figura 25 é possível visualizar os parâmetros desejados bem como o valor mínimo para que uma operação seja considerada como lucrativa (parâmetro "Min. Valid profit(GERAR DADOS)", e receba rótulo 1, seguindo a equação 4.1.

Figura 24 – Exemplo visual da extração de dados através do Metatrader.



Fonte: elaborada pelo autor

Figura 25 – Exemplo visual da extração de dados através do Metatrader.

Variável	Valor	Iniciar	Passo	Parar	Passos
==> Geral					
Nro de Contratos	10	1	1	10	
Ativo Mini	WDO				
Ativo Cheio	DOL				
Ativo Letra/Ano	J21				
Time Frame	5 Minutes	current		1 Month	
==> Outros					
Tipo de média	Exponential	Simple		Linear weighted	
Modo operacao	Modo Gerar dados	Modo operar		Modo Gerar dados	
Habilitar Int.	true	false		true	
Formato dos dados gerados	Formatação CSV	Formatação Esp. branco		Formatação CSV	
==> Operacional					
Stop Loss	50	8.5	0.85	85.0	
Stop Gain	50	50	5.0	500.0	
TrailStop Hilo Habil	true	false		true	
TrailStop Hilo Dist	0	2	0.2	20.0	
Min. Valid profit (GERAR DADOS)	3	5	0.5	50.0	
==> Hilo					
Periodo Hilo	3	3	1	30	
Modo Hilo	Modo 2	Modo 1		Modo 2	
==> Horário de operação					
Hr e Mn p inicio de ordens (HHMM)	900	900	1	9000	
Hr e Mn limite p ordens (HHMM)	1730	1730	1	17300	
Hr e Mn fechar ordens e posições (HHMM)	1750	1750	1	17500	

Fonte: elaborada pelo autor

Levando em consideração que serão 2 redes neurais diferentes, uma especializada em compra e outra em venda, as informações são salvas em 2 arquivos de texto distintos, de acordo com a sua característica. No instante propício indicado pelo HiLo de acordo com o objetivo da rede em questão, os seguintes dados serão salvos em uma linha do arquivo:

- Valor do estocástico rápido para os últimos 5 *candles*;
- Valor do estocástico lento para os últimos 5 *candles*;

- Valor do ADX principal para os últimos 4 *candles*;
- Valor do indicador de direção positiva (ADX) para os últimos 4 *candles*;
- Valor do indicador de direção negativa (ADX) para os últimos 4 *candles*;
- Valor da média móvel alta do HiLo para os últimos 6 *candles*;
- Valor da média móvel baixa do HiLo para os últimos 6 *candles*;
- Valor de abertura para os últimos 5 *candles*;
- Valor máximo para os últimos 5 *candles*;
- Valor mínimo para os últimos 5 *candles*;
- Valor de fechamento para os últimos 5 *candles*;
- Relação do preço de fechamento subtraído pelo preço de abertura para os últimos 5 *candles*;
- Valor da média móvel exponencial de 5 períodos para os últimos 5 *candles*;
- Valor da média móvel exponencial de 11 períodos para os últimos 7 *candles*;
- Valor da média móvel exponencial de 21 períodos para 12 *candles* dentre os últimos 20 disponíveis escolhidos aleatoriamente;
- Valor da média móvel exponencial de 44 períodos para 11 *candles* dentre os últimos 43 disponíveis escolhidos aleatoriamente;
- Valor da média móvel exponencial de 66 períodos para 11 *candles* dentre os últimos 65 disponíveis escolhidos aleatoriamente;
- Data no formato AAAAMMDD, onde AAAA representa o ano, MM o mês e DD o dia;
- Hora no formato HHMM, onde HH representa a hora e MM os minutos;
- Rótulo da entrada, sendo 0 para operações as quais não resultaram em lucro e 1 para as que resultaram em lucros;

A identificação de cada linha de entrada é feita por meio das três últimas colunas do arquivo, sendo elas data, hora e rótulo respectivamente.

4.2 Desenvolvimento da API

Para embarcar as RNAs foi necessário desenvolver uma API em Nodejs para que executasse em uma máquina local, sendo esta a mesma utilizada para executar o Metatrader, desta maneira a latência durante a comunicação entre as aplicações seria baixa.

Os primeiro passos para inicializar a implementação da API foi a instalação do Nodejs, o gerenciador de pacotes NPM e os frameworks Expressjs e Tensorflow. Após instalados e

configurados, iniciou-se a codificação das camadas da aplicação a qual seria capaz de receber requisições HTTP na porta 80.

A divisão de camadas da aplicação foi a seguinte:

- **Controller:** recebe as requisições HTTP, identifica os parâmetros e chama a camada de serviço associada;
- **Service:** esta camada é composta por serviços responsáveis por todas as regras de negócios associadas as redes neurais, tais como topologia, préprocessamento dos dados e persistência dos pesos dos treinamentos em disco;

Ao estruturar a aplicação desta maneira é possível se ter um código mais limpo, de fácil manutenção, além de permitir uma maior facilidade para se alternar entre diferentes topologias de redes neurais, uma vez que basta substituir a camada de serviço pela rede desejada mantendo as interfaces, que todas as demais camadas continuarão funcionando da mesma maneira.

4.2.1 Interfaces disponíveis na API

Esta seção tem como objetivo detalhar as 3 interfaces desenvolvidas e apresentar alguns exemplos de utilização através de comandos cURL.

4.2.1.1 Treinar

Esta interface foi associada ao método HTTP GET */train*. Este recebe como parâmetro (*query params*) o código do ativo a ser treinando, o tipo de rede (compra ou venda) e o número de épocas desejado, e por sua vez retorna um objeto no formato JSON indicando se a API conseguiu interpretar os dados e iniciar um treinamento ou não.

Uma vez que a camada de Controller recebe os dados, ela encaminha para a camada de Service a qual irá criar uma nova instância da rede neural com a topologia desejada e então iniciar o treinamento, exibindo no *console* do servidor o progresso.

Listing 4.1 – Exemplo CURL de requisição.

```
curl --location --request GET 'http://localhost/train?s=WDO&type=sell&epochs=10'
```

4.2.1.2 Predizer

Esta interface foi associada ao método HTTP GET */predict*. Este recebe como parâmetro o código do ativo a ser treinando, o tipo de rede (compra ou venda) e uma lista com todos os valores dos indicadores, na mesma sequência da base de dados do treinamento, descrito na seção 4.1, exceto pelos valores de data, hora e rótulo.

Listing 4.2 – Exemplo CURL de requisição.

```
curl --location --request GET 'http://localhost/predict?type=buy&s=
WDO&d=0.5688&d=0.3492&d=0.2302&d=0.2039&d=0.4051&d=0.3827&d
=0.2611&d=0.2797&d=0.4135&d=0.5955&d=0.3746&d=0.3563&d=0.3333&d
=0.3726&d=0.2733&d=0.3416&d=0.2325&d=0.1906&d=0.1042&d=0.1302&d
=0.1628&d=0.2035&d=-2.0000&d=-3.5000&d=0.5000&d=5.0000&d=9.0000&d
=9.0000&d=-8.0000&d=-10.5000&d=-5.5000&d=-0.5000&d=4.50&d=4.50&d
=-2.00&d=-9.00&d=-7.50&d=-3.00&d=8.00&d=1.50&d=-2.00&d=-5.00&d
=-3.00&d=10.00&d=-3.00&d=-9.50&d=-11.00&d=-11.00&d=5.50&d=0.00&d
=-2.00&d=-9.00&d=-7.50&d=5.50&d=2.00&d=7.00&d=-1.50&d=-4.50&d
=-2.50&d=-1.00&d=-1.50&d=-2.00&d=-2.00&d=1.00&d=-0.50&d=-0.50&d
=-0.50&d=0.00&d=1.50&d=3.50&d=3.00&d=0.00&d=0.00&d=0.00&d=0.50&d
=1.00&d=2.00&d=1.50&d=0.50&d=-1.00&d=-1.00&d=0.00&d=0.50&d=1.00&d
=1.00&d=1.50&d=1.50&d=2.00&d=2.50&d=2.00&d=2.00&d=1.50&d=2.00&d
=3.00&d=3.00&d=3.00&d=3.50&d=3.50&d=4.00&d=4.00&d=4.00&d=4.00&d
=4.00&d=4.50&d=5.50'\
--header 'X-resp-format:json'
```

4.2.1.3 Predizer em lote

Esta interface foi associada ao método HTTP POST */predict/batch*. Este recebe como parâmetro o código do ativo a ser treinando, o tipo de rede (compra ou venda) e uma matriz de dados contendo várias entradas com todos os valores dos indicadores, na mesma sequência da base de dados do treinamento, descrito na seção 4.1, exceto pelos valores de data, hora e rótulo.

Listing 4.3 – Exemplo CURL de requisição.

```
curl --location --request POST 'http://localhost/predict/batch?type=
buy&s=WDO' \
--header 'X-resp-format: json' \
--header 'Content-Type: application/json' \
--data-raw '{
  "inputs": [
    [
      0.179, 0.313, 0.6176, 0.3478, 0.2985, 0.3699, 0.4262,
        0.4213, 0.3184, 0.3949, 0.2642, 0.3237, 0.398, 0.3602,
        0.1946, 0.2432, 0.304, 0.2193, 0.1846, 0.2307, 0.0884,
        0.1105, 27, 30, 28, 28.5, 31, 32, 17, 25.5, 24, 24,
        25,
        25, 16.5, 27.5, 27.5, 24, 26.5, 19, 33.5, 29, 27.5, 28,
        -1.5, 26.5, 26, 23.5, 22.5, 0.5, 33.5, 27.5, 27.5,
        24.5,
```

```

        -16, 6, 0, 3.5, -2, 13, 19.5, 29, 27, 26.5, 18.5, 22.5,
        27, 25.5, 25, 24.5, 24.5, 20, 22, 24.5, 23.5, 23,
        22.5,
        22.5, 21.5, 19, 17.5, 18.5, 19, 20.5, 21.5, 22.5, 22,
        21.5, 21.5, 21.5, 21, 19.5, 19.5, 20, 22, 22.5, 23,
        23, 23,
        22.5, 22.5, 22.5, 21.5, 22, 23
    ]
]
}',

```

4.3 Implementação de testes de previsibilidade

Após a construção da arquitetura da API, foi necessário implementar um outro algoritmo em Typescript o qual foi responsável por ler arquivos de textos salvos em disco e então enviar requisições para a interface de previsibilidade em lote, descrita na seção 4.2.1.3. A base de dados utilizada foi definida durante a implementação das variações do MLP, sendo distintas para cada uma delas.

A figura 26 exibe o resultado final de um teste de previsibilidade executado utilizando o algoritmo de testes. As entradas são organizadas de acordo com a identificação de data e hora e em seguida, é exibido o valor obtido como resposta da API e o valor correto associado a respectiva entrada. Ao final, um resultado final é exibido mostrando a taxa de sucesso do teste.

Esta etapa foi de suma importância principalmente durante a implementação das RNAs, descritos na seção 4.4, e escolhas dos parâmetros utilizados para cada variação pois permite uma visão geral do aprendizado da rede estudada permitindo assim identificar casos de *overfits* de antemão.

Figura 26 – Saída de um teste de previsibilidade.

```

20210315 1510 => 0 : 0 HIT
20210315 1640 => 0 : 1 MISS
20210315 1715 => 0 : 1 MISS
20210316 1020 => 0 : 0 HIT
20210316 1110 => 1 : 0 MISS
20210316 1300 => 0 : 1 MISS
20210316 1405 => 0 : 0 HIT
20210316 1605 => 0 : 0 HIT
20210317 950 => 0 : 0 HIT
20210317 1105 => 1 : 1 HIT
20210317 1215 => 0 : 1 MISS
20210317 1340 => 0 : 1 MISS
20210317 1420 => 0 : 0 HIT
20210317 1500 => 1 : 0 MISS
20210317 1540 => 1 : 0 MISS
20210317 1630 => 0 : 0 HIT
20210317 1720 => 0 : 0 HIT
20210318 905 => 0 : 0 HIT
20210318 1100 => 1 : 0 MISS
20210318 1255 => 0 : 0 HIT
20210318 1415 => 0 : 0 HIT
20210318 1655 => 0 : 0 HIT
20210319 940 => 0 : 0 HIT
20210319 1015 => 0 : 0 HIT
20210319 1120 => 1 : 0 MISS
20210319 1310 => 1 : 1 HIT
20210319 1450 => 0 : 0 HIT
20210319 1635 => 0 : 0 HIT
===== FINAL RESULT | SELL =====
TOTAL: 184
ACCUR: 0.6684782608695652 | 123

```

Fonte: elaborada pelo autor

4.4 Implementação das RNAs

Uma vez que a camada de *controller* foi implementada, o próximo passo consistiu em implementar e treinar as redes neurais artificiais na camada de serviço, como relatado na seção 4.2. Seguindo os procedimentos metodológicos, 5 variações diferentes foram implementadas a fim de verificar o desempenho. Para cada topologia, 2 redes foram treinadas separadamente: uma para a compra e outra para a venda. Ao final de cada treinamento, foram salvos em disco os pesos e um arquivo descrevendo a rede treinada, de maneira que fosse possível carregar e utilizar posteriormente de acordo com as necessidades.

Todas as topologias adotadas, bem como as funções de ativação, número de neurônios nas camadas e as funções de otimização foram escolhidas de maneira empírica a fim de ve-

rificar diferentes configurações e respectivos resultados preliminares. A única exceção foi com relação a função de ativação Sigmoidal referente a última camada em todas as redes, a qual foi adotada devido a sua especialização para problemas de classificação e seu contradomínio restrito entre 0 e 1, assim como descrito na seção 2.2.1.

Durante os treinamentos foram utilizados um notebook Dell com processador Intel(R) Core(TM) i7-8565U CPU @ 1.80GHz 1.99 GHz, com memória RAM de 16GB, GPU integrada Intel (R) UHD Graphics 620, GPU dedicada NVIDIA GeForce MX150 sendo 2 GB de memória dedicada, além do sistema operacional Windows 10. Nos momentos em que estavam sendo treinadas, a máquina foi utilizada exclusivamente para este fim, executando apenas as tarefas essenciais do sistema operacional e o treinamento.

4.4.1 Variação 1

A implementação da primeira variação seguiu a configuração descrita na tabela 1. A estrutura adotada foi apenas 2 camadas, sendo uma de entrada e outra de saída. Para a realização do treinamento foi utilizado o algoritmo de obtenção de dados, descrito na seção 4.1, aplicando o intervalo de datas de 01/02/2016 até 12/02/2021, considerando como lucro as operações cujo ganhos foram superiores a 7 pontos, totalizando 6385 amostras para a rede especializada na compra e 6615 amostras para a rede especializada na venda.

As redes de compra e venda foram treinadas por 3000 épocas. Cada época levou cerca de 4000ms, totalizando em aproximadamente 3h e 20min para cada rede. A precisão de acerto obtida ao final do treinamento foi de 93% para rede de venda e 91 % para a rede de compra considerando apenas a base de treinamento.

Listing 4.4 – Trecho do algoritmo de definição da topologia da variação 1.

```
//Modelo
const model = tf.sequential();
model.add(tf.layers.dense({
  inputShape: [numOfFeatures],
  activation: 'tanh',
  units: parseInt(`${numOfFeatures} / 2`)
}));
model.add(tf.layers.dense({
  units: 1,
  activation: 'sigmoid'
}));

...

//Optimizer
optimizer: tf.train.adagrad(0.1),
```

Após o treinamento, uma nova base de dados foi extraída usando as mesmas configurações da base de treino, alterando apenas o intervalo de datas: 11/02/2021 até 19/03/2021. Esta foi utilizada como base de testes através do algoritmo para verificação de previsibilidade desenvolvido na seção 4.3. Como resultado, foi obtido um aproveitamento de 76,2% para a rede especializada na compra e 75,5 % para a especializada na venda.

4.4.2 Variação 2

A implementação da segunda variação seguiu a configuração descrita na tabela 2. A estrutura adotada foi com 4 camadas, sendo uma de entrada, duas escondidas e outra de saída. Para a realização do treinamento, foi reaproveitado a mesma base de dados descrita na seção 4.4.1.

As redes de compra e venda foram treinadas por 3000 épocas. Cada época levou cerca de 4200ms, totalizando em aproximadamente 3,5h para cada rede. A precisão de acerto obtida ao final do treinamento foi de 97,7% para rede de venda e 97 % para a rede de compra.

Listing 4.5 – Trecho do algoritmo de definição da topologia da variação 2.

```
//Modelo
const model = tf.sequential();
model.add(tf.layers.dense({
  inputShape: [numOfFeatures],
  activation: 'tanh',
  units: numOfFeatures,
  useBias: true
}));
model.add(tf.layers.dense({
  activation: 'tanh',
  units: parseInt(`${numOfFeatures / 2}`)
}));
model.add(tf.layers.dense({
  activation: 'relu',
  units: parseInt(`${numOfFeatures / 4}`)
}));
model.add(tf.layers.dense({
  units: 1,
  activation: 'sigmoid'
}));

...

//Optimizer
optimizer: tf.train.adagrad(0.1),
```

Para a realização dos testes foi utilizada a mesma base de dados descrita na seção 4.4.1. Como resultados temos 69% para a rede especializada na compra e 70,1% para especializada na venda.

4.4.3 Variação 3

A implementação da terceira variação seguiu a configuração descrita na tabela 3. A estrutura adotada foi com 3 camadas, sendo uma de entrada, uma escondida e outra de saída. Para a realização do treinamento, foi utilizado o algoritmo de obtenção de dados para extrair uma nova base de dados seguindo o intervalo de 01/02/2020 e 12/02/2021, considerando como lucrativas as operações cujo ganhos foram superiores a 5 pontos.

A alteração na base de dados foi proposta com a tentativa de diminuir o tempo gasto durante o treinamento e verificar a hipótese de aprendizado considerando apenas eventos mais recentes a fim de analisar os resultados. Além disso, durante os treinamentos anteriores verificou-se que grande parte das entradas não estavam sendo rotuladas como lucrativas, desta maneira, a quantidade de amostras de operações lucrativas eram menores, resultando assim em menos operações ao final do treinamento. Seguindo este modelo, foram coletadas 1836 amostras para a rede especializada na compra e 1851 para especializada na venda.

As redes de compra e venda foram treinadas por 1000 épocas. Cada época levou cerca de 1100ms, totalizando em aproximadamente 18min e 20seg para cada rede. A precisão de acerto obtida ao final do treinamento foi de 93 % para rede de venda e 92,7 % para a rede de compra. Vale ressaltar que as redes não foram treinadas por mais épocas pois mesmo após apenas 1000 épocas, elas já apresentavam boas aproximações. Além disso, a função de otimização Adagrad já apresentava sinais de que estagnação após o treinamento.

Listing 4.6 – Trecho do algoritmo de definição da topologia da variação 3.

```
//Modelo
const model = tf.sequential();
model.add(tf.layers.dense({
  inputShape: [numOfFeatures],
  activation: 'tanh',
  units: numOfFeatures,
  useBias: true
}));
model.add(tf.layers.dense({
  activation: 'tanh',
  units: 25,
  useBias: true
}));
model.add(tf.layers.dense({
  units: 1,
  activation: 'sigmoid',
  useBias: true
```

```

    )));

    ...

    //Optimizer
    optimizer: tf.train.adagrad(0.1),

```

Para a realização dos testes foi utilizada a mesma base de dados descrita na seção 4.4.1. Como resultados temos 72,3 % para a rede especializada na compra e 70,6 % para especializada na venda.

4.4.4 Variação 4

A implementação da quarta variação seguiu a configuração descrita na tabela 4. A estrutura adotada foi com 3 camadas, sendo uma de entrada, uma escondida e outra de saída. Para a realização do treinamento, foi reaproveitado a mesma base de dados descrita na seção 4.4.3.

As redes de compra e venda foram treinadas por 1000 épocas. Cada época levou cerca de 1300ms, totalizando em aproximadamente 21min e 40 seg para cada rede. A precisão de acerto obtida ao final do treinamento foi de 95,3 % para rede de venda e 93,6 % para a rede de compra. Assim como o relatado para o treinamento da variação 3 (seção 4.4.3), as variações para esta rede foram treinadas apenas por 1000 épocas devido às boas aproximações alcançadas após estes períodos. Caso prosseguisse, poderia ocasionar um *overfit*.

Listing 4.7 – Trecho do algoritmo de definição da topologia da variação 4.

```

//Modelo
const model = tf.sequential();
model.add(tf.layers.dense({
    inputShape: [numOfFeatures],
    activation: 'relu',
    units: numOfFeatures,
    useBias: true
}));
model.add(tf.layers.dense({
    activation: 'relu',
    units: 25,
    useBias: true
}));
model.add(tf.layers.dense({
    units: 1,
    activation: 'sigmoid',
    useBias: true
}));

```

```
...

//Optimizer
optimizer: tf.train.adam(0.001, 0.9, 0.999),
```

Para a realização dos testes foi utilizada a mesma base de dados descrita na seção 4.4.1. Como resultados temos 60,2% para a rede especializada na compra e 66,8% para especializada na venda. Embora a precisão tenha sido menor, foi percebido um aumento no número de negociações com acertos durante os testes de previsibilidade.

4.4.5 Variação 5

A implementação da quinta variação seguiu a configuração descrita na tabela 5. A estrutura adotada foi com 3 camadas, sendo uma de entrada, uma escondida e outra de saída. Para a realização do treinamento, foi reaproveitado a mesma base de dados descrita na seção 4.4.1.

As redes de compra e venda foram treinadas por 1500 épocas. Cada época levou cerca de 4700ms, totalizando em 2h17min para a rede especializada na venda e 2h2min para a rede especializada na compra. A precisão de acerto obtida ao final do treinamento foi de 92,4 % para rede de venda e 92,3 % para a rede de compra. A utilização da mesma base de dados utilizada na variação 1 se deve ao número de amostras, seguindo a hipótese de maiores situações para o aprendizado. A escolha pela quantidade de épocas se deve pelo tempo gasto para o treinamento e por possíveis *overfits* caso fosse aumentado a quantidade de épocas.

Listing 4.8 – Trecho do algoritmo de definição da topologia da variação 5.

```
//Modelo
const model = tf.sequential();
model.add(tf.layers.dense({
  inputShape: [numOfFeatures],
  activation: 'tanh',
  units: numOfFeatures,
  useBias: true
}));
model.add(tf.layers.dense({
  activation: 'relu',
  units: 25
}));
model.add(tf.layers.dense({
  units: 1,
  activation: 'sigmoid'
}));

...
```

```
//Optimizer
optimizer: tf.train.adam(0.001, 0.9, 0.999),
```


Para a realização dos testes foi utilizada a mesma base de dados descrita na seção 4.4.1. Como resultados temos 70,7% para a rede especializada na compra e 78,26% para especializada na venda, sendo aparentemente promissores.

4.5 Negociações utilizando RNAs

Com todas as redes neurais implementadas e treinadas foi possível então utilizá-las em negociações a fim de verificar o desempenho de cada uma. Como estratégia, foi definido que cada rede neural deveria executar durante o período de 1 semana durante todo o período de negociações disponíveis para o mini dólar, ou seja, entre 9h as 18h, iniciando na semana do dia 08/03/2021 e se encerrando dia 09/04/2021. Durante este período seria definido apenas os parâmetros de *stop loss*, *stop gain* e *trailing stop*. Uma vez definidos no início da semana, estes permaneceram imutáveis durante toda a semana.

Para a realização das negociações foi utilizada a plataforma do Metatrader 5 com uma conta de demonstração. Este tipo de conta permitiu que fosse simuladas todas as negociações em tempo real, registrando ganhos e perdas, porém sem comprometer nenhum patrimônio real. Para as operações definidas pela IA foi utilizado o ambiente padrão de negociações. Já para as operações sem interferência da IA foi utilizado a ferramenta Testador de Estratégia da plataforma, permitindo assim simular a estratégia escolhida em poucos segundos, diferentemente do ambiente de negociação padrão.

Figura 27 – Exemplo gráfico durante uma negociação.



Fonte: (METAQUOTES, 2020)

As figuras 30, 33, 36 e 39 a seguir representam a movimentação do mini-índice dólar durante o período selecionado para cada variação. Além da movimentação dos preços, é possível identificar também a presença do indicador HiLo, identificado pelas linhas em azul e vermelho.


As próximas seções descrevem com maiores detalhes todas as negociações realizadas e resultados obtidos durante o processo.

Figura 28 – Exemplo dos logs extraídos do Metatrader.

Horário	Fonte	Mensagem
2021.03.17 11:35:00.239	ExpertHilo4 (WDOJ21,M5)	TradeModify::trailingStopHilo: PositionModify: true - ResultRetCode: 10009
2021.03.17 11:39:59.747	ExpertHilo4 (WDOJ21,M5)	TradeModify::trailingStopHilo: PositionModify: true - ResultRetCode: 10009
2021.03.17 11:44:59.431	ExpertHilo4 (WDOJ21,M5)	Webrequest Response: IA: 1
2021.03.17 11:44:59.694	ExpertHilo4 (WDOJ21,M5)	TradeModify::trailingStopHilo: PositionModify: true - ResultRetCode: 10009
2021.03.17 11:49:59.493	ExpertHilo4 (WDOJ21,M5)	TradeModify::trailingStopHilo: PositionModify: true - ResultRetCode: 10009
2021.03.17 11:55:01.525	ExpertHilo4 (WDOJ21,M5)	TradeModify::trailingStopHilo: PositionModify: true - ResultRetCode: 10009
2021.03.17 11:59:59.816	ExpertHilo4 (WDOJ21,M5)	TradeModify::trailingStopHilo: PositionModify: true - ResultRetCode: 10009
2021.03.17 12:14:59.476	ExpertHilo4 (WDOJ21,M5)	Webrequest Response: IA: 0
2021.03.17 12:29:59.640	ExpertHilo4 (WDOJ21,M5)	Webrequest Response: IA: 0
2021.03.17 13:39:59.508	ExpertHilo4 (WDOJ21,M5)	Webrequest Response: IA: 0

Fonte: (METAQUOTES, 2020)

Figura 29 – Exemplo visual da integração entre a API e o Metatrader.



Fonte: (METAQUOTES, 2020)

4.5.1 Variação 1

A primeira variação implementada foi utilizada para realizar negociações no período de 08/03/2021 à 12/03/2021, operando 10 contratos de WDOJ21. Como estratégias de *day trade* foram utilizados 10 pontos para *stop loss*, 50 pontos de *stop gain* e 2 pontos de distância para *trailing stop* considerando as médias de alta e baixa do HiLo como suporte.

A utilização de parâmetros de *day trade* relativamente agressivos se deu pela hipótese de uma maior assertividade da rede, desta forma, o intuito era limitar ao máximo a interferência da estratégia. Entretanto, um ponto negativo se dá ao final das operações as quais mesmo que lucrativas, poderiam ser ainda melhores.

Figura 30 – Movimentação do mini dólar durante o período de 08/03/2021 à 12/03/2021.



Fonte: (METAQUOTES, 2020)

As figuras 31 e 32 representam relatórios gerados pelo Metatrader referente as negociações realizadas durante este período considerando a estratégia definida. Com elas é possível visualizar detalhes sobre os resultados obtidos. Percebe-se que a utilização da variação 1 resultou em um lucro de R\$ 7.000,00 enquanto que a mesma estratégia sem a utilização da IA resultou em um prejuízo de R\$ 7.850,00, mesmo executando menos operações.

Figura 31 – Resultados das negociações sem IA.

Resultados					
Qualidade do histórico:	100%	Ticks:	11336	Ativos:	1
Barras:	570	Rebaixamento Absoluto do Saldo :	9 400.00	Rebaixamento Absoluto do Capital Líquido :	9 400.00
Lucro Líquido Total:	-7 850.00	Rebaixamento Máximo do Saldo :	9 400.00 (940.00%)	Rebaixamento Máximo do Capital Líquido :	10 350.00 (530.77%)
Lucro Bruto:	31 150.00	Rebaixamento Relativo do Saldo :	940.00% (9 400.00)	Rebaixamento Relativo do Capital Líquido :	530.77% (10 350.00)
Perda Bruta:	-39 000.00				
Fator de Lucro:	0.80	Retorno Esperado (Payoff):	-103.29	Nível de Margem:	
Fator de Recuperação:	-0.76	Índice de Sharpe: -92 233 720 368 547 758.08		Z-Pontuação:	1.19 (76.60%)
AHPR: 1.0620 (6.20%)		Correlação LR :	-0.46	Resultado OnTester:	0
GHPR: 0.9131 (-8.69%)		Erro Padrão LR :	1 833.93		
Total de Negociações:	76	Posições Vendidas (% e ganhos):	39 (38.46%)	Posições Compradas (% de ganhos):	37 (18.92%)
Ofertas Total:	152	Negociações com Lucro (% of total):	22 (28.95%)	Negociações com Perda (% of total):	54 (71.05%)
		Maior lucro da negociação:	5 300.00	Maior perda na Negociação:	-1 000.00
		Média lucro da negociação:	1 415.91	Média perda na Negociação:	-722.22
		Máximo ganhos consecutivos (\$):	3 (4 500.00)	Máximo perdas consecutivas (\$):	7 (-4 500.00)
		Máxima lucro consecutivo (contagem):	5 300.00 (1)	Máxima perda consecutiva (contagem):	-4 850.00 (6)
		Média ganhos consecutivos:	1	Média perdas consecutivas:	3

Fonte: (METAQUOTES, 2020)

Analisando a relação entre o número de negociações e o desempenho das estratégias, temos que sem a utilização da rede neural ocorreram 76 negociações no total, sendo 28,95% delas operações lucrativas, enquanto que utilizando a rede neural foram realizadas 20 negociações sendo 50% delas consideradas lucrativas. Se compararmos o desempenho entre as redes especializada na compra e venda, temos que a rede de compra realizou 9 negociações sendo 33% delas com lucro enquanto que a rede especializada na venda realizou 11 negociações sendo 63,64% lucrativas.

Figura 32 – Resultados das negociações utilizando a variação 1.


Resultados			
Lucro Líquido Total:	7 000.00	Lucro Bruto:	14 500.00
Fator de Lucro:	1.93	Retorno Esperado (Payoff):	350.00
Fator de Recuperação:	2.03	Índice de Sharpe:	0.08
Rebaixamento do Saldo:			
Rebaixamento Absoluto do Saldo :	3 450.00	Rebaixamento Máximo do Saldo :	3 450.00 (100.00%)
		Rebaixamento Relativo do Saldo :	32.47% (1 250.00)
Total de Negociações:	20	Posições Vendidas (% e ganhos):	11 (63.64%)
		Negociações com Lucro (% of total):	10 (50.00%)
		Maior lucro da negociação:	5 450.00
		Média lucro da negociação:	1 450.00
		Máximo ganhos consecutivos (\$):	5 (5 650.00)
		Máxima lucro consecutivo (contagem):	5 650.00 (5)
		Média ganhos consecutivos:	3
		Posições Compradas (% de ganhos):	9 (33.33%)
		Negociações com Perda (% of total):	10 (50.00%)
		Maior perda na Negociação:	-1 100.00
		Média perda na Negociação:	-750.00
		Máximo perdas consecutivas (\$):	4 (-3 450.00)
		Máxima perda consecutiva (contagem):	-3 450.00 (4)
		Média perdas consecutivas:	2

Fonte: (METAQUOTES, 2020)

4.5.2 Variação 2

A segunda variação implementada foi utilizada para realizar negociações no período de 15/03/2021 à 19/03/2021, operando 10 contratos de WDOJ21. Como estratégias de *day trade* foram utilizadas as mesmas descritas para a variação 1 (seção 4.5.1), sendo elas 10 pontos para *stop loss*, 50 pontos de *stop gain* e 2 pontos de distância para *trailing stop* considerando as médias de alta e baixa do HiLo como suporte. A manutenção dos parâmetros adotados foi em virtude dos bons resultados apresentados pela variação 1.

Figura 33 – Movimentação do mini dólar durante o período de 15/03/2021 à 19/03/2021.



Fonte: (METAQUOTES, 2020)

As figuras 34 e 35 representam relatórios gerados pelo Metatrader referente as negociações realizadas durante este período considerando a estratégia definida. Com elas é possível visualizar detalhes sobre os resultados obtidos. Percebe-se que a utilização da variação 2 resultou em um lucro de R\$ 1.050,00 enquanto que a mesma estratégia sem a utilização da IA resultou em um lucro de R\$ 11.750,00. Vale ressaltar que o número de negociações utilizando a IA durante o período foi consideravelmente menor se comparado ao mesmo período operando sem a interferência de uma IA.

Figura 34 – Resultados das negociações sem IA.

Resultados					
Qualidade do histórico:	100%				
Barras:	540	Ticks:	10792	Ativos:	1
Lucro Líquido Total:	11 750.00	Rebaixamento Absoluto do Saldo :	0.00	Rebaixamento Absoluto do Capital Líquido:	750.00
Lucro Bruto:	35 350.00	Rebaixamento Máximo do Saldo :	7 000.00 (40.00%)	Rebaixamento Máximo do Capital Líquido:	8 850.00 (45.97%)
Perda Bruta:	-23 600.00	Rebaixamento Relativo do Saldo :	44.40% (5 750.00)	Rebaixamento Relativo do Capital Líquido:	78.26% (900.00)
Fator de Lucro:	1.50	Retorno Esperado (Payoff):	199.15	Nível de Margem:	
Fator de Recuperação:	1.33	Índice de Sharpe:	0.14	Z-Pontuação:	-0.16 (12.71%)
AHPR:	1.1524 (15.24%)	Correlação LR :	0.48	Resultado OnTester:	0
GHPR:	1.0441 (4.41%)	Erro Padrão LR :	2 412.52		
Total de Negociações:	59	Posições Vendidas (% e ganhos):	28 (39.29%)	Posições Compradas (% de ganhos):	31 (32.26%)
Ofertas Total:	118	Negociações com Lucro (% of total):	21 (35.59%)	Negociações com Perda (% of total):	38 (64.41%)
		Maior lucro da negociação:	8 250.00	Maior perda na Negociação:	-1 000.00
		Média lucro da negociação:	1 683.33	Média perda na Negociação:	-621.05
		Máximo ganhos consecutivos (\$):	2 (8 500.00)	Máximo perdas consecutivas (\$):	9 (-5 900.00)
		Máxima lucro consecutivo (contagem):	8 500.00 (2)	Máxima perda consecutiva (contagem):	-5 900.00 (9)
		Média ganhos consecutivos:	2	Média perdas consecutivas:	3

Fonte: (METAQUOTES, 2020)

Figura 35 – Resultados das negociações utilizando a variação 2.

Resultados					
Lucro Líquido Total:	1 050.00	Lucro Bruto:	8 300.00	Perda Bruta:	-7 250.00
Fator de Lucro:	1.14	Retorno Esperado (Payoff):	55.26		
Fator de Recuperação:	0.27	Índice de Sharpe:	0.19		
Rebaixamento do Saldo:					
Rebaixamento Absoluto do Saldo :	1 500.00	Rebaixamento Máximo do Saldo :	3 850.00 (81.91%)	Rebaixamento Relativo do Saldo :	81.91% (3 850.00)
Total de Negociações:	19	Posições Vendidas (% e ganhos):	7 (57.14%)	Posições Compradas (% de ganhos):	12 (16.67%)
		Negociações com Lucro (% of total):	6 (31.58%)	Negociações com Perda (% of total):	13 (68.42%)
		Maior lucro da negociação:	3 800.00	Maior perda na Negociação:	-1 000.00
		Média lucro da negociação:	1 383.33	Média perda na Negociação:	-557.69
		Máximo ganhos consecutivos (\$):	3 (3 500.00)	Máximo perdas consecutivas (\$):	6 (-3 850.00)
		Máxima lucro consecutivo (contagem):	3 800.00 (1)	Máxima perda consecutiva (contagem):	-3 850.00 (6)
		Média ganhos consecutivos:	2	Média perdas consecutivas:	3

Fonte: (METAQUOTES, 2020)


Verificando a relação entre o número de negociações e o desempenho das estratégias, temos que sem a utilização da rede neural ocorreram 59 negociações no total, sendo 35,59% delas operações lucrativas, enquanto que utilizando a rede neural foram realizadas 19 negociações sendo 31,58% delas consideradas lucrativas. Se compararmos o desempenho entre as redes especializada na compra e venda, temos que a rede de compra realizou 12 negociações sendo 16,67% delas com lucro enquanto que a rede especializada na venda realizou 7 negociações sendo 57,14% lucrativas.

4.5.3 Variação 3

A terceira variação implementada foi utilizada para realizar negociações no período de 21/03/2021 à 26/03/2021, operando 10 contratos de WDOJ21. Como estratégias de *day trade* foram utilizadas 3 pontos para *stop loss*, 6 pontos de *stop gain* e adotado o nível de *trailing stop* como sendo as médias de alta e baixa do HiLo.

As alterações descritas foram com o intuito de melhorar a assertividade das operações tanto quanto nas entradas quanto nas saídas, buscando diminuir o tempo posicionado e aumentar o número de entradas no decorrer do dia. Ou seja, a estratégia deveria diminuir o lucro por operação porém aumentar o número de operações, melhorando os resultados finais. Vale ressaltar que houveram alterações na base de dados para o treinamento de maneira que a rede fosse capaz de identificar operações mais curtas como sendo lucrativas (seção 4.4.3).

Figura 36 – Movimentação do mini dólar durante o período de 21/03/2021 à 26/03/2021.



Fonte: (METAQUOTES, 2020)

As figuras 37 e 38 representam relatórios gerados pelo Metatrader referente as negociações realizadas durante este período considerando a estratégia definida. Percebe-se que a utilização da variação 3 resultou em um prejuízo de R\$ 550,00 enquanto que a mesma estratégia sem a utilização da IA resultou em um prejuízo de R\$ 100,00. Houve um aumento considerável do número de operações, especialmente sem a utilização da IA, porém o resultado não foi o esperado, embora tenham sido próximos.

Analisando a relação entre o número de negociações e o desempenho das estratégias, temos que sem a utilização da rede neural ocorreram 73 negociações no total, sendo 32,88% delas operações lucrativas, enquanto que utilizando a rede neural foram realizadas 21 negociações sendo 28,57% delas consideradas lucrativas. Se compararmos o desempenho entre as redes especializada na compra e venda, temos que a rede de compra realizou 15 negociações sendo 26,67% delas com lucro enquanto que a rede especializada na venda realizou 6 negociações sendo 33,33% lucrativas.

Figura 37 – Resultados das negociações sem IA.

Resultados					
Qualidade do histórico:	0%	Ticks:	10792	Ativos:	1
Barras:	540	Rebaixamento Absoluto do Saldo :	1 150.00	Rebaixamento Absoluto do Capital Líquido:	1 200.00
Lucro Líquido Total:	-100.00	Rebaixamento Máximo do Saldo :	2 400.00 (106.67%)	Rebaixamento Máximo do Capital Líquido:	2 450.00 (108.89%)
Lucro Bruto:	14 400.00	Rebaixamento Relativo do Saldo :	106.67% (2 400.00)	Rebaixamento Relativo do Capital Líquido:	108.89% (2 450.00)
Perda Bruta:	-14 500.00				
Fator de Lucro:	0.99	Retorno Esperado (Payoff):	-1.37	Nível de Margem:	
Fator de Recuperação:	-0.04	Índice de Sharpe:	0.04	Z-Pontuação:	0.08 (6.38%)
AHPR: 1.0305 (3.05%)		Correlação LR :	-0.19	Resultado OnTester:	0
GHPR: 0.9986 (-0.14%)		Erro Padrão LR :	515.87		
Total de Negociações:	73	Posições Vendidas (% e ganhos):	37 (37.84%)	Posições Compradas (% de ganhos):	36 (27.78%)
Ofertas Total:	146	Negociações com Lucro (% of total):	24 (32.88%)	Negociações com Perda (% of total):	49 (67.12%)
		Maior lucro da negociação:	600.00	Maior perda na Negociação:	-300.00
		Média lucro da negociação:	600.00	Média perda na Negociação:	-295.92
		Máximo ganhos consecutivos (\$):	3 (1 800.00)	Máximo perdas consecutivas (\$):	8 (-2 400.00)
		Máxima lucro consecutivo (contagem):	1 800.00 (3)	Máxima perda consecutiva (contagem):	-2 400.00 (8)
		Média ganhos consecutivos:	2	Média perdas consecutivas:	3

Fonte: (METAQUOTES, 2020)

Figura 38 – Resultados das negociações utilizando a variação 3.

Resultados			
Lucro Líquido Total:	-550.00	Lucro Bruto:	3 450.00
Fator de Lucro:	0.86	Retorno Esperado (Payoff):	-26.19
Fator de Recuperação:	-0.17	Índice de Sharpe:	0.21
Rebaixamento do Saldo:			
Rebaixamento Absoluto do Saldo :	1 550.00	Rebaixamento Máximo do Saldo :	3 250.00 (191.18%)
		Rebaixamento Relativo do Saldo :	191.18% (3 250.00)
Total de Negociações:	21	Posições Vendidas (% e ganhos):	6 (33.33%)
		Negociações com Lucro (% of total):	6 (28.57%)
		Maior lucro da negociação:	850.00
		Média lucro da negociação:	575.00
		Máximo ganhos consecutivos (\$):	3 (1 000.00)
		Máxima lucro consecutivo (contagem):	1 650.00 (2)
		Média ganhos consecutivos:	2
		Posições Compradas (% de ganhos):	15 (26.67%)
		Negociações com Perda (% of total):	15 (71.43%)
		Maior perda na Negociação:	-300.00
		Média perda na Negociação:	-266.67
		Máximo perdas consecutivas (\$):	12 (-3 250.00)
		Máxima perda consecutiva (contagem):	-3 250.00 (12)
		Média perdas consecutivas:	8


Fonte: (METAQUOTES, 2020)

4.5.4 Variação 4

A quarta variação implementada foi utilizada para realizar negociações no período de 29/03/2021 à 02/04/2021, operando 10 contratos de WDOJ21 e WDOK21 separadamente (uma vez que o período contempla a alteração do mês, ocorreu um vencimento para o contrato WDOJ21, sendo necessário realizar as negociações através do WDOK21, de acordo com os vencimentos descritos na seção 2.3.1). Como estratégias de *day trade* foram utilizadas 10 pontos para *stop loss*, 15 pontos de *stop gain* e 2 pontos de distância para *trailing stop* considerando as médias de alta e baixa do HiLo como suporte.

As novas alterações nas estratégias foram devido ao mau resultado apresentado pela variação 3, especialmente se comparado as variações 1 e 2. A escolha pelo *stop gain* mais curto é com o objetivo de buscar garantir lucros antes mesmo que ocorram reversões.

Figura 39 – Movimentação do mini dólar durante o período de 29/03/2021 à 02/04/2021.



Fonte: (METAQUOTES, 2020)

As figuras 40 e 41 representam relatórios gerados pelo Metatrader referente as negociações realizadas durante este período considerando a estratégia definida. Percebe-se que a utilização da variação 4 resultou em um prejuízo de R\$ 1.555,00 enquanto que a mesma estratégia sem a utilização da IA resultou em um lucro de R\$ 7.500,00. Esta variação foi a que apresentou os piores resultados se comparada às demais. Ao final, foram executadas apenas 5 operações apenas, sendo elas todas posições vendidas.

Figura 40 – Resultados das negociações sem IA.

Resultados			
Qualidade do histórico:	0%	Ticks:	8624
Barras:	432	Ativos:	1
Lucro Líquido Total:	7 500.00	Rebaixamento Absoluto do Saldo :	3 100.00
Lucro Bruto:	28 250.00	Rebaixamento Absoluto do Capital Líquido:	3 350.00
Perda Bruta:	-20 750.00	Rebaixamento Máximo do Saldo :	6 250.00 (123.76%)
		Rebaixamento Máximo do Capital Líquido:	6 750.00 (131.07%)
		Rebaixamento Relativo do Saldo :	310.00% (3 100.00)
		Rebaixamento Relativo do Capital Líquido:	223.68% (4 250.00)
Fator de Lucro:	1.36	Retorno Esperado (Payoff):	147.06
Fator de Recuperação:	1.11	Índice de Sharpe:	0.22
AHPR: 1.4066 (40.66%)		Correlação LR :	0.89
GHPR: 1.0429 (4.29%)		Erro Padrão LR :	1 911.61
Nível de Margem:		Z-Pontuação:	-1.23 (78.13%)
		Resultado OnTester:	0
Total de Negociações:	51	Posições Vendidas (% e ganhos):	28 (35.71%)
Ofertas Total:	102	Posições Compradas (% de ganhos):	23 (47.83%)
		Negociações com Lucro (% of total):	21 (41.18%)
		Negociações com Perda (% of total):	30 (58.82%)
		Maior lucro da negociação:	3 400.00
		Maior perda na Negociação:	-1 000.00
		Média lucro da negociação:	1 345.24
		Média perda na Negociação:	-691.67
		Máximo ganhos consecutivos (\$):	4 (7 150.00)
		Máximo perdas consecutivas (\$):	7 (-6 250.00)
		Máxima lucro consecutivo (contagem):	7 150.00 (4)
		Máxima perda consecutiva (contagem):	-6 250.00 (7)
		Média ganhos consecutivos:	2
		Média perdas consecutivas:	3

Fonte: (METAQUOTES, 2020)

Figura 41 – Resultados das negociações utilizando a variação 4.

Resultados			
Lucro Líquido Total:	-1 555.00	Lucro Bruto:	0.00
Fator de Lucro:	0.00	Retorno Esperado (Payoff):	-311.00
Fator de Recuperação:	-1.00	Índice de Sharpe:	0.78
Rebaixamento do Saldo:			
Rebaixamento Absoluto do Saldo :	1 555.00	Rebaixamento Máximo do Saldo :	1 555.00 (100.00%)
		Rebaixamento Relativo do Saldo :	0.00% (0.00)
Total de Negociações:	5	Posições Vendidas (% e ganhos):	5 (20.00%)
		Negociações com Lucro (% of total):	1 (20.00%)
		Maior lucro da negociação:	0.00
		Média lucro da negociação:	0.00
		Máximo ganhos consecutivos (\$):	1 (0.00)
		Máxima lucro consecutivo (contagem):	0.00 (1)
		Média ganhos consecutivos:	1
		Posições Compradas (% de ganhos):	0 (0.00%)
		Negociações com Perda (% of total):	4 (80.00%)
		Maior perda na Negociação:	-750.00
		Média perda na Negociação:	-388.75
		Máximo perdas consecutivas (\$):	2 (-800.00)
		Máxima perda consecutiva (contagem):	-800.00 (2)
		Média perdas consecutivas:	2

Fonte: (METAQUOTES, 2020)


Verificando a relação entre o número de negociações e o desempenho das estratégias, temos que sem a utilização da rede neural ocorreram 51 negociações no total, sendo 41,18% delas operações lucrativas, enquanto que utilizando a rede neural foram realizadas 5 negociações sendo 20% delas consideradas lucrativas. Entretanto, não é possível realizar um comparativo entre as redes especializada na venda e compra pois apenas a rede especializada na venda realizou negociações, sendo que apenas 1 delas resultou em lucro.

4.5.5 Variação 5

A quinta variação implementada foi utilizada para realizar negociações no período de 05/04/2021 à 09/04/2021, operando 10 contratos de WDOK21. Como estratégias de *day trade* foram utilizadas 8,5 pontos para *stop loss*, 20 pontos de *stop gain* e 2 pontos de distância para *trailing stop* considerando as médias de alta e baixa do HiLo como suporte.

As novas alterações nas estratégias foram devido ao mau resultado apresentado pelas variação 3 e 4, especialmente se comparado as variações 1 e 2. Logo, foi novamente ampliado o *stop loss* para o mesmo valor utilizado pela variação 1, porém reduzindo o *stop gain* consideravelmente a fim de garantir possíveis lucros de antemão evitando perdas com reversões.

Figura 42 – Movimentação do mini dólar durante o período de 05/04/2021 à 09/04/2021.



Fonte: (METAQUOTES, 2020)

As figuras 43 e 44 representam relatórios gerados pelo Metatrader referente as negociações realizadas durante este período considerando a estratégia definida. Percebe-se que a utilização da variação 5 resultou em um prejuízo de R\$ 750,00 enquanto que a mesma estratégia sem a utilização da IA resultou em um prejuízo de R\$ 6.850,00.

Figura 43 – Resultados das negociações sem IA.

Resultados					
Qualidade do histórico:	0%				
Barras:	540	Ticks:	10788	Ativos:	1
Lucro Líquido Total:	-6 850.00	Rebaixamento Absoluto do Saldo :	9 350.00	Rebaixamento Absoluto do Capital Líquido:	9 450.00
Lucro Bruto:	24 050.00	Rebaixamento Máximo do Saldo :	9 350.00 (935.00%)	Rebaixamento Máximo do Capital Líquido:	10 550.00 (502.38%)
Perda Bruta:	-30 900.00	Rebaixamento Relativo do Saldo :	935.00% (9 350.00)	Rebaixamento Relativo do Capital Líquido:	502.38% (10 550.00)
Fator de Lucro:	0.78	Retorno Esperado (Payoff):	-96.48	Nível de Margem:	
Fator de Recuperação:	-0.65	Índice de Sharpe:	-0.09	Z-Pontuação:	0.82 (58.78%)
AHPR:	0.8067 (-19.33%)	Correlação LR :	-0.28	Resultado OnTester:	0
GHPR:	0.9073 (-9.27%)	Erro Padrão LR :	2 184.64		
Total de Negociações:	71	Posições Vendidas (% e ganhos):	35 (20.00%)	Posições Compradas (% de ganhos):	36 (33.33%)
Ofertas Total:	142	Negociações com Lucro (% of total):	19 (26.76%)	Negociações com Perda (% of total):	52 (73.24%)
		Maior lucro da negociação:	3 450.00	Maior perda na Negociação:	-850.00
		Média lucro da negociação:	1 265.79	Média perda na Negociação:	-594.23
		Máximo ganhos consecutivos (\$):	2 (5 700.00)	Máximo perdas consecutivas (\$):	10 (-5 000.00)
		Máxima lucro consecutivo (contagem):	5 700.00 (2)	Máxima perda consecutiva (contagem):	-5 200.00 (7)
		Média ganhos consecutivos:	1	Média perdas consecutivas:	3

Fonte: (METAQUOTES, 2020)

Figura 44 – Resultados das negociações utilizando a variação 5.

Resultados			
Lucro Líquido Total:	-750.00	Lucro Bruto:	9 550.00
Fator de Lucro:	0.93	Retorno Esperado (Payoff):	-28.85
Fator de Recuperação:	-0.19	Índice de Sharpe:	0.07
Perda Bruta:			-10 300.00
Rebaixamento do Saldo:			
Rebaixamento Absoluto do Saldo :	3 900.00	Rebaixamento Máximo do Saldo :	3 950.00 (254.84%)
		Rebaixamento Relativo do Saldo :	254.84% (3 950.00)
Total de Negociações:	26	Posições Vendidas (% e ganhos):	13 (23.08%)
		Negociações com Lucro (% of total):	6 (23.08%)
		Maior lucro da negociação:	2 800.00
		Média lucro da negociação:	1 591.67
		Máximo ganhos consecutivos (\$):	2 (2 900.00)
		Máxima lucro consecutivo (contagem):	2 900.00 (2)
		Média ganhos consecutivos:	1
		Posições Compradas (% de ganhos):	13 (23.08%)
		Negociações com Perda (% of total):	20 (76.92%)
		Maior perda na Negociação:	-850.00
		Média perda na Negociação:	-515.00
		Máximo perdas consecutivas (\$):	7 (-3 900.00)
		Máxima perda consecutiva (contagem):	-3 950.00 (5)
		Média perdas consecutivas:	4

Fonte: (METAQUOTES, 2020)

Verificando a relação entre o número de negociações e o desempenho das estratégias, temos que sem a utilização da rede neural ocorreram 71 negociações no total, sendo 26,76% delas operações lucrativas, enquanto que utilizando a rede neural foram realizadas 26 negociações sendo 23,08% delas consideradas lucrativas.

4.5.6 Comparativo geral

Esta sessão destina-se a realizar um comparativo geral analisando os resultados obtidos após o período de negociações, verificando a relação entre número de operações, percentual de operações bem sucedidas, relação entre operações realizadas pelas redes especializadas na compra e venda.


A tabela 10 e a figura 45 representam o compilado final do ponto de vista do lucro obtido ao final do período analisado utilizando o setup HiLo. Analisando as variações, é possível notar uma oscilação considerável, sendo períodos onde os resultados apresentados sem a utilização das redes neurais foi expressivamente melhor, enquanto que em outros cenários ocorreu o inverso. É válido ressaltar também que mesmo em casos onde ocorreram prejuízos, a utilização das redes reduziu consideravelmente (cenário onde foi utilizado a variação 5). Por fim é possível notar que negociações utilizando as redes neurais resultaram em um desempenho superior a não utilização.

Tabela 10 – Comparativo entre as variações - Lucros financeiros.

Desempenho financeiro		
Variação	Sem IA	Com IA
Variação 1	R\$ -7.850,00	R\$ 7.000,00
Variação 2	R\$ 11.750,00	R\$ 1.050,00
Variação 3	R\$ -100,00	R\$ -550,00
Variação 4	R\$ 7.500,00	R\$ -1.555,00
Variação 5	R\$ -6.850,00	R\$ -750,00
Total	R\$ 4.450,00	R\$ 5.195,00

Fonte: Elaborada pelo autor.

Figura 45 – Comparativo entre as variações, considerando lucros financeiros.



Fonte: Elaborada pelo autor.


Analisando a tabela 11 e a figura 47 sob a ótica de número de negociações realizadas é possível identificar uma notória diferença entre a utilização e não utilização das redes, uma vez que a não utilização resultou em um número de negociações 3 vezes maior em relação a utilização da rede. Além disso, a não utilização das RNAs apresentou um percentual de operações lucrativas próximo ao resultado obtido pelas negociações utilizando as RNAs, porém ainda sim superior.

Tabela 11 – Comparativo entre as variações - número de operações.

Número de operações		
Variação	Sem IA	Com IA
Variação 1	76 (28,95% lucrativas)	20 (50% lucrativas)
Variação 2	59 (35,59% lucrativas)	19 (31,58% lucrativas)
Variação 3	73 (32,88% lucrativas)	21 (28,57% lucrativas)
Variação 4	51 (41,18% lucrativas)	5 (20% lucrativas)
Variação 5	71 (26,76% lucrativas)	26 (23,08% lucrativas)
Total	330 (32,42% lucrativas)	91 (31,86% lucrativas)

Fonte: Elaborada pelo autor.

Figura 46 – Comparativo entre as variações, considerando taxas de acerto nas negociações.



Fonte: Elaborada pelo autor.


A tabela 12 retrata um comparativo entre o desempenho obtido pelas redes de compra e de venda, uma vez que possuem a mesma topologia, entretanto, são treinadas com bases de dados distintas de acordo com os seus objetivos. Assim como aconteceu durante os treinamentos, as redes especializadas na venda, em sua maioria, apresentaram melhores performances do que as redes especializadas na compra, mesmo executando um número menor de operações.

Tabela 12 – Comparativo entre as variações - desempenho entre redes especializadas na compra e venda.

Desempenho entre rede especializada na compra e venda		
Varição	Especializada na compra	Especializada na venda
Varição 1	9 (33% lucrativas)	11 (63,64% lucrativas)
Varição 2	12 (16,67% lucrativas)	7 (57,14% lucrativas)
Varição 3	15 (26,67% lucrativas)	6 (33,33% lucrativas)
Varição 4	0 (não se aplica)	5 (20% lucrativas)
Varição 5	13 (23,08% lucrativas)	13 (23,08% lucrativas)
Total	49 (24,48% lucrativas)	42 (40,47% lucrativas)

Fonte: Elaborada pelo autor.

Figura 47 – Comparativo entre as especializações, considerando taxas de acerto nas negociações.



Fonte: Elaborada pelo autor.

5 Conclusão

“As palavras fogem quando precisamos delas e sobram quando não pretendemos usá-las.”
Carlos Drummond de Andrade

O presente trabalho se justifica pela necessidade de um maior entendimento das movimentações dos preços dos ativos do mercado financeiro, bem como ferramentas que forneçam aos investidores um maior potencial de acerto nas negociações e também formas de minimizar os prejuízos durante as operações. Para isto foi necessário realizar um estudo em técnicas utilizadas para as práticas atuais, bem como conceitos aplicados no mercado financeiro a fim de aumentar o domínio do assunto. A fim de aplicar os conceitos na prática, o mini dólar foi escolhido como objeto de estudo. Em seguida, foi desenvolvida uma metodologia para o desenvolvimento de ferramentas computacionais as quais auxiliam os investidores durante as tomadas de decisões com base na aplicação de técnicas de inteligência artificial para o aprendizado de movimentações passadas.

Em virtude do seu caráter experimental, diversos testes foram realizados alterando as topologias das redes neurais artificiais, bem como os parâmetros operacionais utilizados em técnicas de *day trade* a fim de realizar um comparativo entre elas e obter um maior entendimento sobre o cenário e possíveis abordagens na resolução do problema. Após o desenvolvimento, foi possível identificar bons resultados iniciais, principalmente sob a ótica de lucros monetários, os quais foram obtidos ao se utilizar as redes neurais como ferramenta se comparado com a realização de negociações sem esta ferramenta.

Desta maneira foi possível ressaltar a importância do presente trabalho especialmente para a comunidade econômica e entusiastas no assunto uma vez que tal solução se mostra muito promissora e pode ser replicada até mesmo para diferentes ativos do mercado financeiro, sejam eles presentes na B3 ou não, de acordo com o suporte fornecido pelas ferramentas utilizadas.

A seção 5.1 apresenta os principais resultados alcançados, enquanto que a seção 5.2 apresenta discussões e limitações da pesquisa. Por fim, a seção 5.3 aponta algumas direções para trabalhos futuros.

5.1 Resultados

Este trabalho apresentou um resultado final importante uma vez que diversos trabalhos têm sido realizados na área, com outras abordagens e nem sempre apresentam lucros financeiros. O relatório agregado apresenta lucros financeiros relativamente expressivos. Nem todas as variações apresentadas e estratégias foram totalmente lucrativas, porém é possível identificar bons resultados especialmente se tratando das variações 1 e 2, e até mesmo da

variação 5, uma vez que esta foi capaz de reduzir o prejuízo ocasionado durante as negociações.

Comparando apenas entre as variações de RNAs implementadas foi possível obter números animadores especialmente com relação a variação 1 quando comparada com as demais. Levando em consideração apenas lucros financeiros, seu ganho isoladamente foi superior a todas as demais, mesmo que somados os resultados. Seu percentual de acerto, em especial a especialização na venda, foi totalmente relevante servindo como um importante ponto de partida para evoluções de redes futuras uma vez que apresentou uma taxa de acerto de 63,64% nas negociações realizadas. Vale ressaltar que analisando sua topologia, esta foi a única abordagem com apenas 2 camadas.

Um ponto de atenção refere-se aos baixos índices de negociações bem sucedidas apresentados na tabela 11, tanto utilizando as redes neurais quanto sem a utilização, uma vez que a taxa de lucro foi em torno de 32 % para ambos os cenários ao final do experimento. Uma hipótese remete a ineficiência dos parâmetros escolhidos para as negociações, os quais em diversas situações finalizaram as operações abertas antes do esperado resultando em prejuízos.

Além das topologias estudadas, vale ressaltar a importância dos indicadores utilizados. A escolha se deu após análises a resultados comuns e a avaliações encontradas em bibliografias, especialmente as descritas na seção 2.3.3. Estes tiveram o intuito de descrever as movimentações do mercado de diferentes maneiras de acordo com as respectivas de cada um. O lucro final foi um indicativo de que a escolha foi bem sucedida, porém ainda sim há espaço para melhorias.

Considerando um cenário real de aplicação da metodologia e solução apresentada, é necessário ressaltar também a necessidade de uma margem de garantia para a realização das operações. Logo, de acordo com a margem de garantia necessária para efetivar as operações é imprescindível analisar os valores exigidos a fim de verificar a viabilidade sob a perspectiva de risco versus retorno. Tal fato não diminui os ganhos obtidos, principalmente por ter gerado lucros financeiros ao final, entretanto é um fator crucial para optar pela realização ou não das operações.

5.2 Considerações e limitações

Analisando os resultados finais obtidos durante as negociações descritas na seção 4.5.6 é possível notar que o presente trabalho apresentou bons resultados, porém durante o desenvolvimento algumas limitações foram encontradas e são relevantes para discussões.

A primeira limitação encontrada durante o desenvolvimento refere-se a uma limitação da plataforma Metatrader. Por definição, a plataforma não permite que o algoritmo realize requisições HTTP durante modos de testes utilizando bases históricas, sendo possível apenas durante negociações em tempo real, mesmo que utilizando contas de demonstração. Em virtude disso, a simulação das negociações utilizando as redes neurais precisou ser realizada durante períodos reais, fato que gera uma considerável demora para a obtenção dos resulta-

dos finais.

Uma segunda limitação relacionada ao Metatrader também foi encontrada durante o desenvolvimento. Devido as características limitadas com relação a realização de requisições HTTP em modo de teste e o curto período de desenvolvimento do trabalho, não foi possível comparar todas as redes neurais em um mesmo período de tempo. Tal possibilidade poderia ter evidenciado melhor as diferenças entre as topologias apresentadas, mitigando possíveis discrepâncias nos resultados em virtude de movimentações específicas do mercado durante um período de teste.


A terceira limitação encontrada refere-se ao comportamento volátil do mercado. Durante as negociações foi percebido momentos onde haviam variações bruscas, apresentando, por exemplo, 38 pontos de variação em um único *candle* (figura 48). Uma vez que cada ponto do dólar representa uma variação de R\$ 10,00 e que durante os testes foram negociados 10 minicontratos, este único *candle* representaria uma variação de R\$ 3800,00. Considerando um cenário como este, mesmo que a rede neural houvesse indicado a efetivação da operação no início da tendência de maneira correta, esta operação geraria prejuízos no momento em que ocorresse esta oscilação possivelmente atingindo o *stop loss* posicionado.

Figura 48 – Exemplo de volitividade ocorrida durante dia 07/04/2021.



Fonte: (METAQUOTES, 2020)

Uma importante consideração sobre as técnicas de *day trade* são que elas podem gerar perdas em casos de grande volitividade do mercado e quando são mau utilizadas. A figura 49 representa 2 situações onde ocorreram perdas durante as negociações realizadas pela variação 2. Durante o período, as redes neurais instruíram a realização das operações de compra e venda ao início da tendência indicadas pelo HiLo. E ao analisarmos o gráfico, é possível notar que a movimentação foi acertada, uma vez que a tendência continuou em ambos os casos, entretanto, as operações resultaram em perdas em virtude de terem atingido os patamares mínimos estipulados pelas operações de *stop loss* utilizadas.

Figura 49 – Exemplo de perdas em virtude do *stop loss*.

Fonte: (METAQUOTES, 2020)

Além destas, é importante salientar que durante o desenvolvimento foi realizado testes iniciais da metodologia apresentada com outro ativo da bolsa de valores: mini índice bovespa. Todavia, este ativo apresenta características muito diferentes, apresentando tendências menores, maior volatilidade, além de variações em escalas diferentes quando comparado ao mini dólar. Logo, foi identificado que seria necessário um estudo maior sobre o ativo, compreendendo as principais características da sua movimentação e parâmetros operacionais eficientes para que pudesse ser realizado os experimentos com uma maior assertividade. Como não houve tempo hábil para tal, esta abordagem não foi explorada com maiores detalhes, mas é um objeto de estudo relevante para trabalhos futuros.

5.3 Trabalhos futuros

Os resultados deste trabalho sugerem algumas direções promissoras de trabalho futuro: a utilização da mesma metodologia em outros ativos, realização do treinamento utilizando diferentes intervalos de tempo para a extração dos dados, aplicação de algoritmos genéticos para a definição dos parâmetros operacionais, a utilização de outros indicadores da análise técnica e a utilização de outros setups e estratégias de *day trade*.

Uma vez que a metodologia proposta foi eficiente para o desenvolvimento do trabalho e os algoritmos implementados são possuem parametrizações do papel negociado, uma outra possível utilização seria a aplicação desta em outros ativos, tais como o mini índice bovespa (assim como citado na sessão 5.2), algum ativo de contratos futuros ou até mesmo criptomoedas tais como Bitcoin e Ethereum. Para isto, seria necessário realizar um estudo prévio das características do ativo para compreender melhor a sua movimentação e definir bons parâmetros operacionais, podendo aplicar os mesmos indicadores utilizados no presente trabalho e então verificar os resultados.

Analisando o desenvolvimento do trabalho e as negociações realizadas, foi identificado um possível objeto de estudo o qual seria propor quais parâmetros operacionais tais como *stop loss* e *stop gain* gerariam os melhores resultados. Durante os testes, diversos momentos foram percebidos que a rede identificou bons momentos de entrada, porém os lucros financeiros poderiam ter sido mais expressivos caso os parâmetros operacionais estivessem melhor definidos. Considerando este cenário, uma possível abordagem em um trabalho futuro seria a aplicação de algoritmos genéticos para o aprendizado e definição dos melhores parâmetros operacionais de acordo com o ativo estudado. Uma vez definidos, poderiam trabalhar em conjunto com as redes neurais, potencializando os ganhos.

Devido a natureza totalmente volátil do mercado, uma hipótese refere-se a base de dados utilizada para o treinamento. Alguns testes iniciais foram realizados neste trabalho, entretanto, uma análise mais aprofundada seria um objeto de estudo totalmente relevante. O ponto principal seria analisar se o treinamento das redes neurais apenas com dados mais recentes, tais como última semana, mês, ou até mesmo 3 meses, poderia influenciar nas negociações uma vez que as RNAs estariam expostas apenas ao comportamento do ciclo mais recente, e não tão influenciada por fatores econômicos passados. Além da variação do período, uma outra abordagem seria a definição de pesos para as entradas, atribuindo pesos maiores para as entradas mais recentes. Tais variações na obtenção das bases de dados geraria a necessidade de treinamentos constantes para a realização de negociações, porém a metodologia aplicada seria a mesma.

Outra possível abordagem a partir deste trabalho seria a utilização de outros indicadores da análise técnica como entradas para as redes neurais e então, realizar novos treinamentos e negociações. São diversos indicadores disponíveis tais como Bandas de Bollinger, RSI, etc, podendo ser configurados de diversas maneiras. Ou até mesmo, utilizar os mesmos indicadores apresentados alterando os parâmetros de inicialização (períodos desejados).

Além destas, um possível objeto de estudo seria a utilização de outros setups emitindo

sinais de compra ou venda, alterando também parâmetros de *day trade* utilizados (*stop loss*, *stop gain* e *trailing stop*). Desta maneira, novos pontos de entrada poderiam ser identificados nos gráficos, gerando novas oportunidades de aprendizado e consequentemente, novos pontos de decisão para as redes neurais. Para isto, seria necessário identificar bons setups de mercado e então realizar a atualização, porém a metodologia utilizada para extrair as bases de dados, realizar o treinamento e a integração poderiam ser mantidas.

Referências

- ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>. Citado na página 33.
- AIRES, D. B.; DAMETTO, R. C.; CREPALDI, A. F. Financial time series forecast using artificial neural networks: a comparative in the 2008 crisis. *Revista Gestão da Produção Operações e Sistema*, A Fundacao para o Desenvolvimento de Bauru (FunDeB), v. 11, p. 177–205, 3 2018. ISSN 1984-2430. Citado na página 14.
- ANDRADE, J. *B3 bate recorde e movimenta R\$ 26 bilhões por dia em 2020 – Investimentos – E-Investidor*. 2020. Acessado em 10 de novembro de 2020. Disponível em: <<https://einvestidor.estadao.com.br/investimentos/b3-recorde-26-bilhoes-dia>>. Citado na página 13.
- B3. *Futuro Mini de Taxa de Câmbio de Reais por Dólar Comercial*. 2020. Acessado em 10 de novembro de 2020. Disponível em: <http://www.b3.com.br/pt_br/produtos-e-servicos/negociacao/moedas/futuro-mini-de-taxa-de-cambio-de-reais-por-dolar-comercial.htm>. Citado nas páginas 13 e 21.
- B3. *Institucional*. 2020. Acessado em 10 de novembro de 2020. Disponível em: <http://www.b3.com.br/pt_br/b3/institucional/quem-somos/>. Citado na página 13.
- CASTRO, L. N. D. Fundamentals of natural computing: an overview. *Physics of Life Reviews*, v. 4, p. 1–36, 2007. Disponível em: <www.elsevier.com/locate/plrev>. Citado na página 16.
- CLEAR. *Candlestick: saiba o que é e para que serve*. 2011. Acessado em 16 de março de 2021. Disponível em: <<https://blog.clear.com.br/candlestick/>>. Citado na página 22.
- CLEAR. *Pit de Negociações*. 2020. Acessado em 10 de novembro de 2020. Disponível em: <<https://www.clear.com.br/site/pit-de-negociacoes>>. Citado na página 31.
- EDWARDS, R.; MAGEE, J.; BASSETTI, W. *Technical Analysis of Stock Trends*. Taylor & Francis, 2018. ISBN 9781351631433. Disponível em: <<https://books.google.com.br/books?id=cVJmDwAAQBAJ>>. Citado na página 13.
- FOUNDATION, O. *Expressjs*. 2021. Acessado em 24 de março de 2021. Disponível em: <<https://expressjs.com/pt-br/>>. Citado na página 33.
- FOUNDATION, O. *Nodejs*. 2021. Acessado em 24 de março de 2021. Disponível em: <<https://nodejs.org/en/>>. Citado na página 32.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, 2019. 126, 144, 288, 344–351 p. ISBN 9781492032618. Disponível em: <<https://books.google.com.br/books?id=HHetDwAAQBAJ>>. Citado nas páginas 17, 18, 19 e 20.
- GOMES, F. R. A bolsa de valores brasileira como fonte de informações financeiras. *Perspectivas em ciência da informação*, v. 2, n. 2, 1997. Citado na página 13.
- GURESEN, E.; KAYAKUTLU, G.; DAIM, T. U. Using artificial neural network models in stock market index prediction. 2011. Citado na página 16.

HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007. 183 p. Citado na página 17.

HENRIQUES, P.; NEVES, F. *Previsão de séries temporais utilizando uma combinação não-linear entre ARIMA e Redes Neurais Artificiais*. 2017. Citado na página 20.

INFOMONEY, E. *Stop Loss: entenda o conceito e aprenda a limitar suas perdas de forma eficiente*. 2006. Acessado em 17 de março de 2021. Disponível em: <<https://www.infomoney.com.br/mercados/stop-loss-entenda-o-conceito-e-aprenda-a-limitar-suas-perdas-de-forma-eficiente/>>. Citado na página 28.

INVESTIDOR, B. do. *Como Interpretar o Gráfico de Candlestick*. 2013. Acessado em 16 de março de 2021. Disponível em: <<https://bussoladoinvestidor.com.br/grafico-de-candlestick/>>. Citado na página 23.

INVESTIDOR, P. do. *Mercado Futuro*. 2020. Acessado em 11 de novembro de 2020. Disponível em: <https://www.investidor.gov.br/menu/Menu_Investidor/derivativos/mercado_futuro.html>. Citado na página 20.

KUMAR, G.; JAIN, S.; SINGH, U. P. Stock market forecasting using computational intelligence: A survey. *Archives of Computational Methods in Engineering*, Springer, p. 1–3, 2020. ISSN 18861784. Tradução nossa. Citado nas páginas 15 e 16.

LIU, F.; WANG, J. Fluctuation prediction of stock market index by legendre neural network with random time strength function. 2012. Disponível em: <www.elsevier.com/locate/neucom>. Citado nas páginas 15 e 20.

METAQUOTES. *Metatrader 5*. 2020. Acessado em 10 de novembro de 2020. Disponível em: <<https://www.metatrader5.com/>>. Citado nas páginas 24, 25, 26, 27, 28, 29, 30, 32, 38, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 71 e 72.

NASCIMENTO, L. A. et al. Geração automatizada de séries temporais de dados posicionais utilizando o ibge-ppp. p. 1, 2017. Disponível em: <<http://dx.doi.org/10.1590/S1982-21702017000100010>>. Citado na página 20.

NELOGICA. *Profit Pro*. 2020. Acessado em 10 de novembro de 2020. Disponível em: <<https://www.nelogica.com.br/produtos/profit-pro>>. Citado na página 31.

NELOGICA, E. *Trailing Stop*. 2021. Acessado em 24 de março de 2021. Disponível em: <<https://ajuda.nelogica.com.br/hc/pt-br/articles/360049175772-O-essencial-sobre-Trailing-Stop>>. Citado na página 29.

PINHEIRO, L. *Setup do trader: como criar uma estratégia para operar no mercado*. 2019. Acessado em 17 de março de 2021. Disponível em: <<https://blog.nelogica.com.br/setup-do-trader-como-criar-uma-estrategia-para-operar-no-mercado/>>. Citado na página 28.

REIS, T. *ADX: o que é e como funciona o Average Directional Index?* 2019. Acessado em 16 de março de 2021. Disponível em: <<https://www.suno.com.br/artigos/adx/>>. Citado na página 25.

RIBEIRO, R. de S. *Em busca de uma melhor estratégia de saída? Conheça o HiLo Activator*. 2011. Acessado em 10 de novembro de 2020. Disponível em: <<https://www.infomoney.com.br/onde-investir/em-busca-de-uma-melhor-estrategia-de-saida-conheca-o-hilo-activator/>>. Citado na página 27.

RICO. *Minicontratos de Índice e Dólar: o que são e como operar (Guia)*. 2021. Acessado em 28 de março de 2021. Disponível em: <<https://blog.rico.com.vc/mini-contratos-o-que-sao>>. Citado na página 21.

RUDGE, L.; CAVALCANTE, F. As bolsas de valores: estrutura e funcionamento. *Mercado de capitais*, v. 3, p. 169–204, 1996. Citado na página 13.

SAFFI, P. A. C. *Análise Técnica: Sorte ou Realidade?* 2003. Citado nas páginas 24 e 26.

SHYNKEVICH, Y. et al. Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing*, v. 264, p. 71–88, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.neucom.2016.11.095>>. Citado na página 14.

SOUZA, R. C. T. D. *Previsão de séries temporais utilizando rede neural treinada por filtro de Kalman e evolução diferencial*. 2008. Citado na página 16.

TORO, E. *Conheça o Stop Loss! Veja como ele pode salvar seus investimentos*. 2021. Acessado em 17 de março de 2021. Disponível em: <<https://www.tororadar.com.br/investimento/bovespa/stop-loss-o-que-e>>. Citado na página 29.

TRADINGVIEW. *Gráficos futuros de mercadorias WDO1!* 2021. Acessado em 03 de abril de 2021. Disponível em: <<https://br.tradingview.com/chart/?symbol=BMFBOVESPA%3AWDO1!>> Citado na página 22.

VANSTONE, B.; FINNIE, G.; HAHN, T. Creating trading systems with fundamental variables and neural networks: The aby case study. *Mathematics and Computers in Simulation*, v. 86, p. 78–91, 2012. Disponível em: <www.sciencedirect.com>. Citado na página 16.

WAZLAWICK, R. S. Uma reflexão sobre a pesquisa em ciência da computação à luz da classificação das ciências e do método científico. *Revista de Sistemas de Informação da FSMA*, v. 6, p. 3–10, 2010. Citado na página 34.

WIKIPEDIA. *Ramp function*. 2021. Acessado em 28 de março de 2021. Disponível em: <https://en.wikipedia.org/wiki/Ramp_function>. Citado na página 17.

WIKIPEDIA. *Sigmoid function*. 2021. Acessado em 28 de março de 2021. Disponível em: <https://en.wikipedia.org/wiki/Sigmoid_function>. Citado na página 18.

WIKIPEDIA. *Tangente hiperbólica*. 2021. Acessado em 28 de março de 2021. Disponível em: <https://es.wikipedia.org/wiki/Tangente_hiperbólica>. Citado na página 18.