

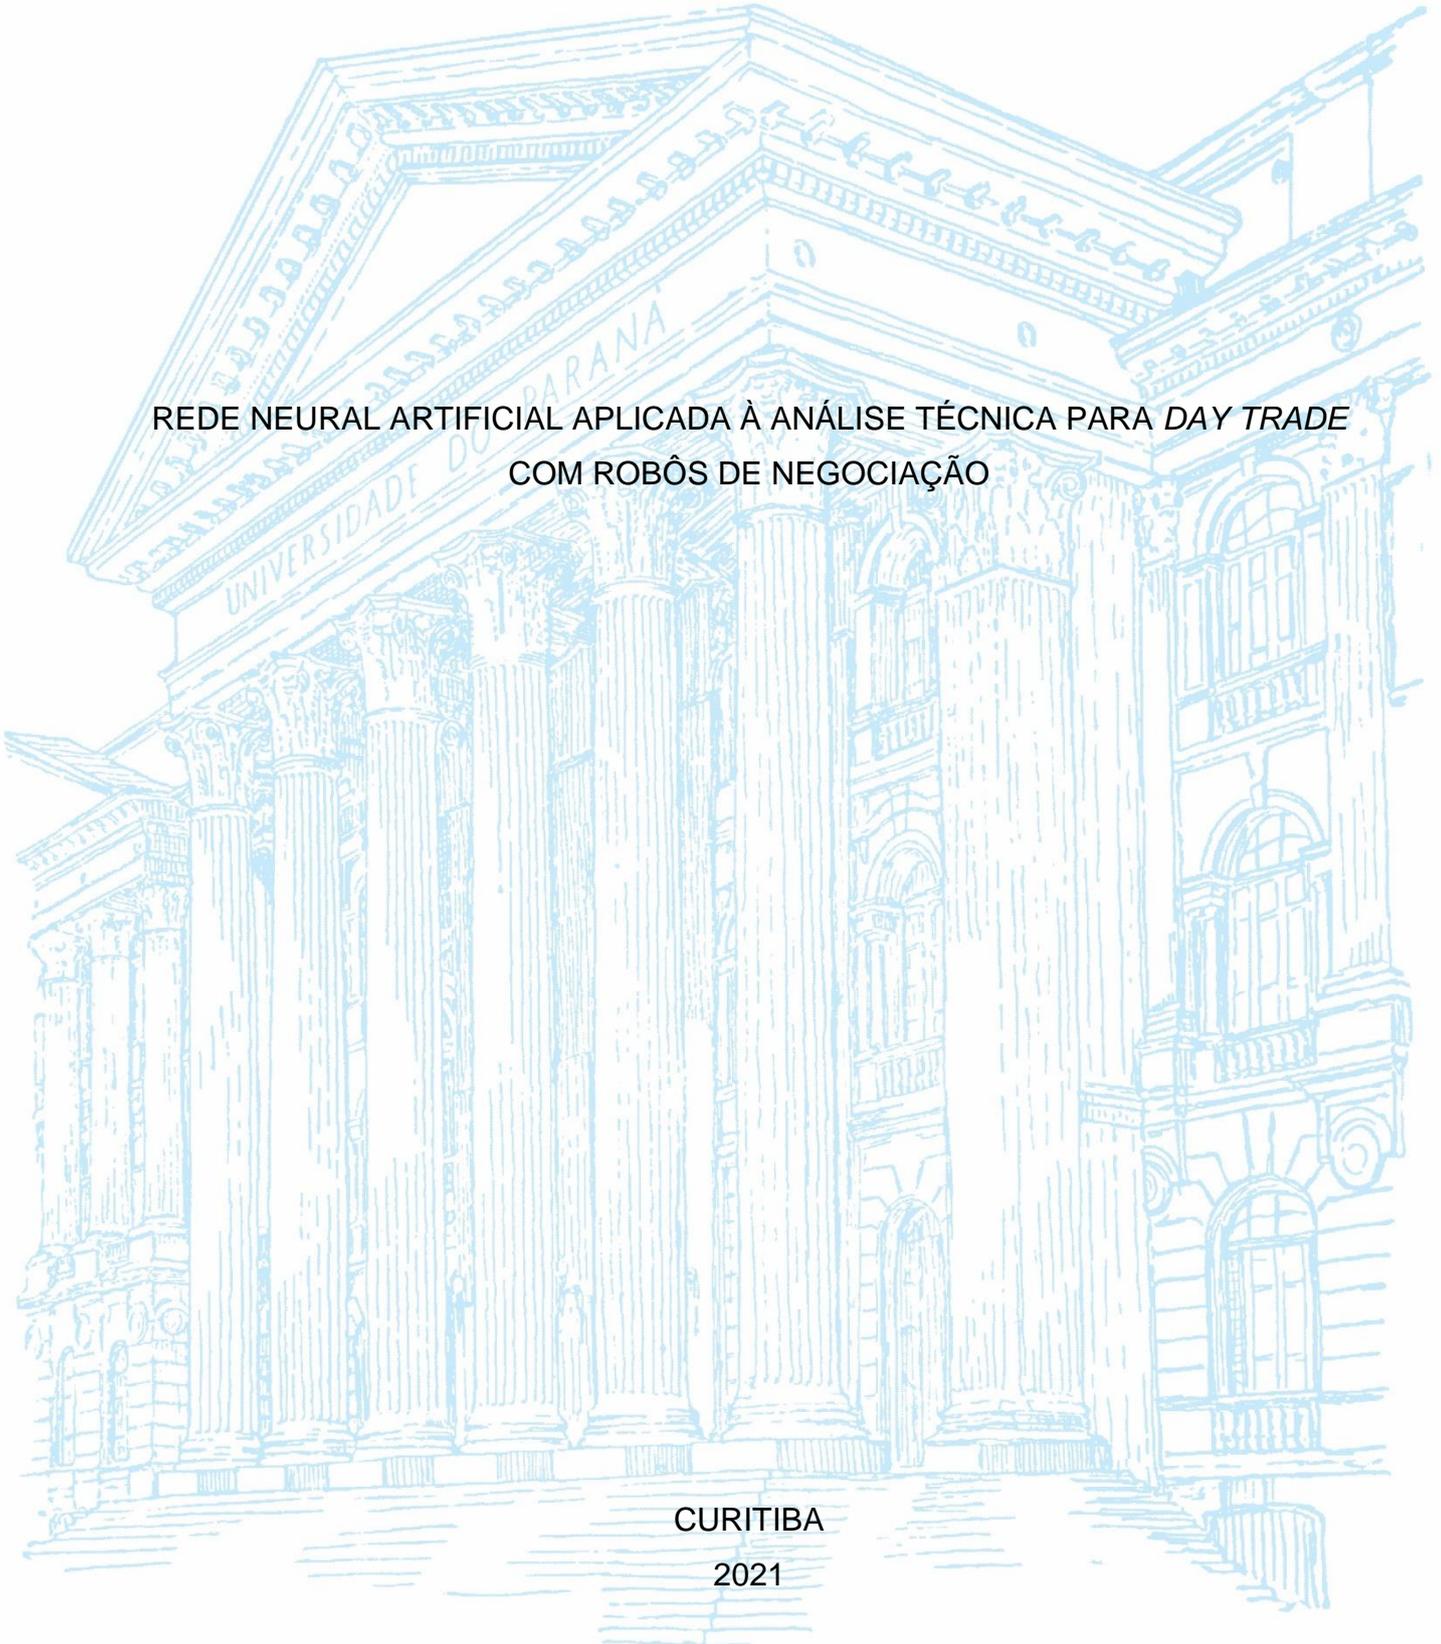
UNIVERSIDADE FEDERAL DO PARANÁ

GABRIEL SILVA DE QUEIROZ

REDE NEURAL ARTIFICIAL APLICADA À ANÁLISE TÉCNICA PARA *DAY TRADE*
COM ROBÔS DE NEGOCIAÇÃO

CURITIBA

2021



GABRIEL SILVA DE QUEIROZ

REDE NEURAL ARTIFICIAL APLICADA À ANÁLISE TÉCNICA PARA *DAY TRADE*
COM ROBÔS DE NEGOCIAÇÃO

TCC apresentado ao curso de Graduação em Engenharia de Produção Setor de Ciências, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia de Produção.

Orientador(a): Prof(a). Dr(a). Mariana Kleina.

CURITIBA

2021

“O ontem é história, o amanhã é um mistério, mas o hoje é uma dádiva. É
por isso que se chama presente.”

Mestre Oogway

RESUMO

O número de investidores na bolsa de valores brasileira não para de crescer, entre os novos investidores há quem prefira colocar seu dinheiro em aplicações de baixo risco, ao mesmo passo que existem os que querem se aventurar nos ativos de alto risco buscando uma renda extra mensal no *day trade*, para esses, entre as possibilidades estão as negociações no minicontrato futuro de índice Bovespa. Para o manuseio dessas negociações, é amplamente utilizada a análise técnica, ou análise gráfica, que utiliza de diversas ferramentas para prever o movimento do mercado, entre elas, os indicadores técnicos. Nesse contexto, surgem grandes aliados para investidores, os robôs de negociação, ou *expert advisors*, que seguem à risca as estratégias pré-definidas pelo *trader* podendo fazer a leitura de até dezenas de indicadores ao mesmo tempo. O objetivo da análise técnica é, de forma geral, interpretar o passado para tentar prever o futuro, nesse sentido também trabalham as redes neurais artificiais, que se introduzem nesse trabalho buscando agregar no desempenho dos robôs de negociação e aumentar sua assertividade. Portanto, esse trabalho apresenta um estudo comparativo entre dois robôs de negociação que utilizam dos mesmos indicadores técnicos para gerar sinais de compra ou venda do minicontrato futuro de índice Bovespa. O primeiro deles utiliza os métodos clássicos da análise técnica, ou seja, interpreta os indicadores técnicos selecionados e toma a decisão de compra caso todos eles indiquem essa ação, ou venda, caso contrário. Já o outro robô utiliza a mesma leitura desses indicadores para gerar *inputs* para uma rede neural artificial do tipo *multilayer perceptron* que, após ter seus pesos sinápticos regulados por um algoritmo genético, processa os sinais dos indicadores para retornar um único sinal de compra ou venda. Por fim, apresentam-se as comparações dos resultados financeiros dos robôs no período de dez meses, sendo oito utilizados nas otimizações feitas com o algoritmo genético e dois para teste. Percebe-se a superioridade do robô que utiliza redes neurais artificiais, tendo melhor desempenho tanto no período de otimização quanto no de teste, mostrando a capacidade de generalização e reconhecimento dos padrões do mercado por parte da estrutura de rede neural *multilayer perceptron*.

Palavras-chave: Redes Neurais Artificiais. Algoritmo Genético. *Day Trade*. Minicontrato Futuro. *Expert Advisors*.

ABSTRACT

The number of investors on the Brazilian stock exchange continues to grow, among new investors there are those who prefer to put their money in low-risk investments, while there are those who want to venture into high-risk assets looking for extra monthly income there is no day trade, for these, between the options are listed in the mini Bovespa index futures contract. For the use of these tools, technical analysis is used, or graphical analysis, which uses various tools to predict market movements, including technical indicators. In this context, there are great allies for investors, trading processes, or Expert Advisors, who follow to the letter according to the strategy pre-defined by the trader, being able to read up to dozens of indicators at the same time. The objective of technical analysis is, in general, to interpret the past to try to predict the future, in this sense it also works as artificial neural networks, which are introduced in this work seeking to add to the performance of trading robots and increase their assertiveness. Therefore, this work presents a comparative study between two trading robots that use the same technical indicators to generate buy or sell signals for the mini Bovespa index futures contract. The first of them uses the classic methods of technical analysis, that is, it interprets the selected technical indicators and makes the decision to buy if they all indicate this action, or sell, otherwise. The other robot, on the other hand, uses the same reading of these indicators to generate inputs for an artificial neural network of the multilayer perceptron type that, after having its synaptic weights regulated by a genetic algorithm, processes the indicators' signals to return a single buy or sell signal. Finally, it is presented as comparisons of the financial results of the exercises over a period of ten months, eight being used in the optimizations made with the genetic algorithm and two for testing. It is noticed the superiority of the robot that uses artificial neural networks, having the best performance both in the optimization period and in the test, showing a generalization capacity and recognition of market patterns by the perceptron multilayer neural network structure.

Keywords: Neural Networks. Genetic Algorithm. Day Trade. Future Mini Contract. Expert Advisors.

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVOS	17
1.1.1 Objetivo geral	17
1.1.2 Objetivos específicos.....	17
2 REVISÃO DE LITERATURA	19
2.1 CONTRATOS FUTUROS DE ÍNDICE BOVESPA	19
2.1.1 Minicontratos futuros de índice Bovespa.....	19
2.2 ANÁLISE TÉCNICA	19
2.3 REDES NEURAIS ARTIFICIAIS	21
2.3.1 Neurônio biológico.....	21
2.3.2 Neurônio artificial.....	22
2.3.3 <i>Multilayer perceptron</i>	22
2.3.4 <i>Forward</i>	23
2.3.5 Funções de ativação	24
2.4 ALGORITMO GENÉTICO	25
2.4.1 Fases do processo evolutivo	25
3 MATERIAL E MÉTODOS	30
3.1 SELEÇÃO DO TIPO DE REDE NEURAL UTILIZADA	30
3.2 ESCOLHA DOS INDICADORES.....	30
3.3 IMPLEMENTAÇÃO COMPUTACIONAL DOS <i>EXPERT ADVISORS</i>	31
3.4 DEFINIÇÃO DOS INDICADORES E REGULAGEM DOS PARÂMETROS	33
3.5 SELEÇÃO DE DIFERENTES PERFIS.....	35
3.6 REGULAGEM DOS PESOS SINÁPTICOS DA REDE NEURAL	37
4 APRESENTAÇÃO DOS RESULTADOS	39
5 CONSIDERAÇÕES FINAIS	42
REFERÊNCIAS.....	43

1 INTRODUÇÃO

Cada vez mais brasileiros buscam por maiores rentabilidades investindo seu dinheiro na Bolsa de Valores. Segundo a B3 (2020), em setembro de 2020 foi atingida a marca de 3 milhões de investidores, o dobro em relação ao final de 2019 e o número continua crescendo.

Ao ingressar no mundo dos investimentos, o novo investidor se depara com diferentes tipos de estratégia para suas negociações, entre elas a estratégia de *day trade* que consiste na manutenção de operações curtas, abrindo uma ou mais posições no mercado e finalizando-a no mesmo dia. Essa estratégia é adotada por *players* que buscam um lucro mais rápido, porém, aceitando expor seu dinheiro à um maior risco (MURPHY, 1999).

Para saber a hora certa de comprar ou vender uma ação no *day trade*, usam-se técnicas de análise gráfica, ou análise técnica. Esse método consiste na leitura e interpretação de um ou mais indicadores técnicos que utilizam do histórico de preços e/ou volumes de negociação para projetar sinais que auxiliam o investidor na tomada de decisão. Por tratar-se de negociações rápidas, é necessário agilidade e acurácia na regulagem e interpretação desses indicadores técnicos. Quando a estratégia escolhida pelo *player* utiliza poucos indicadores, a leitura pode ser fácil, porém quando são utilizados três ou mais simultaneamente, o investidor fica sujeito a uma maior possibilidade de erros ou atrasos na interpretação durante suas análises, o que pode levá-lo a ter prejuízos. Nesse cenário, surgem os robôs de negociação, ou *expert advisors*, que por meio de uma estratégia de leitura de indicadores pré-estabelecida pelo investidor, tomam as decisões imediatamente após os sinais serem gerados pelo gráfico, aumentando a acurácia e permitindo que vários indicadores sejam lidos e interpretados ao mesmo tempo, fazendo com que a decisão de compra ou venda seja tomada à uma velocidade que o cérebro humano não é capaz de processar.

Portando, *expert advisors* são excelentes aliados para investidores em *day trade* que utilizam a análise gráfica, porém, a frieza na leitura e interpretação única de uma estratégia pré-estabelecida sem a flexibilidade de um senso crítico adquirido pela experiência pode colocar em xeque a utilização desses robôs. Nesse cenário, introduzem-se as Redes Neurais Artificiais, que tem o objetivo de reproduzir o aprendizado adquirido pela experiência como ocorre no cérebro humano, simulando

o senso crítico de um investidor experiente na hora da tomada de decisão após a leitura e interpretação dos indicadores.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Este trabalho tem o objetivo de fazer uma comparação dos resultados financeiros de um *expert advisor* que gera sinais de compra e venda a partir da leitura crua e direta de indicadores técnicos e de outro que usa os mesmos indicadores, mas com o acréscimo do processamento de uma rede neural artificial, para um mesmo período de simulação.

1.1.2 Objetivos específicos

1. Selecionar um conjunto de indicadores utilizados na análise técnica para incorporá-los aos robôs;
2. Implementar o primeiro *expert advisor*: este deve fazer a leitura um a um dos indicadores selecionados no passo anterior e decidir seu posicionamento no mercado por meio da análise técnica;
3. Implementar o segundo *expert advisor*: este deve utilizar as mesmas lógicas de leitura de indicadores que o primeiro. Contudo, após gerar esses sinais, deve colocá-los em um vetor que servirá de *input* para uma rede neural artificial do tipo *multiplayer perceptron* de uma camada oculta. Este robô deverá ser implementado de forma que o tamanho da rede neural (número de neurônios nas camadas) possam ser alterados pelo usuário;
4. Regular os parâmetros do robô sem rede neural artificial por meio do algoritmo genético, esses parâmetros são: alvos de ganho e perda das negociações, quais indicadores entre os disponíveis serão efetivamente utilizados e suas respectivas configurações;
5. Fixar as configurações de indicadores e alvos definidas no passo anterior no *expert advisor* que utiliza rede neural artificial e por meio do algoritmo genético regular os parâmetros de rede: número de

neurônios na camada oculta, pesos sinápticos entre os neurônios e valores de *bias*;

6. Simular o desempenho de ambos robôs para um mesmo período de teste;
7. Comparar os resultados financeiros.

2 REVISÃO DE LITERATURA

2.1 CONTRATOS FUTUROS DE ÍNDICE BOVESPA

Contratos futuros são utilizados por quem deseja negociar ativos financeiros como índices, *commodities* ou moedas, utilizando das flutuações desses ativos para lucrar de acordo com especulações de seus valores futuros.

Diferentemente do mercado à vista, para negociar contratos futuros, o investidor não precisa ter uma grande quantidade de dinheiro em conta, uma vez que é possível operar usando uma margem de garantia de acordo com cada corretora.

Segundo Modalmis (2020), o índice Bovespa (Ibovespa) é o índice que melhor representa o desempenho médio das ações negociadas na B3, por isso, o contrato futuro Ibovespa é o contrato futuro com maior volume de negociação atualmente no Brasil.

2.1.1 Minicontratos futuros de índice Bovespa

Para negociar um contrato inteiro (cheio) de índice Bovespa, o investidor precisa comprar um lote mínimo de cinco contratos, o que representa uma quantia de R\$380.000,00, caso a cotação do índice esteja em 76.000 pontos, uma vez que cada ponto do índice Bovespa equivale a R\$1,00. Contudo, com a possibilidade de alavancagem disponibilizada pelas corretoras, o *trader* precisa ter uma margem de R\$625,00 em conta, R\$125,00 por contrato.

Os minicontratos foram criados com o objetivo de atender os investidores com baixo capital, no caso do minicontrato de índice Bovespa, a proporção é de 20% do contrato cheio, ou seja, para operar um lote de mini índice cada ponto vale R\$0,20 e a operação ficaria em torno de R\$15.200,00, porém, com a alavancagem o *trader* precisa ter uma margem de apenas R\$25,00 em conta (Clear Corretora, 2018).

2.2 ANÁLISE TÉCNICA

Segundo Murphy (1999), a análise técnica, ou também conhecida como análise gráfica, é o estudo dos movimentos do mercado, utilizando principalmente os gráficos de preços e volumes históricos, a fim de prever futuras tendências de preço.

As técnicas de análise gráfica podem ser aplicadas nos mais diversos tipos de ativos presentes no mercado de capitais e é usada na maioria das vezes por pequenos investidores (pessoas físicas), uma vez que sua aplicação não demanda conhecimentos profundos de economia, contabilidade ou áreas afins.

Segundo Murphy (1999), a análise técnica tem três pilares:

1. O movimento dos preços do mercado já consideram todos os fatores: essa premissa defende que todos os fatores que interferem no preço já estão absorvidos, ou seja, questões políticas, sociais, psicológicas, etc, já estão sendo refletidos no próprio preço do ativo, dessa forma o investidor só precisa se preocupar com o gráfico;
2. Preços seguem uma tendência: as forças externas citadas no pilar anterior sempre criarão períodos onde o otimismo dos investidores sobressairá ao pessimismo (tendência de alta) ou o contrário (tendência de baixa). Também haverá momentos em que o mercado ficará indeciso, lateralizando o gráfico, porém com o passar do tempo os movimentos acabam se sustentando em alguns patamares, seja de alta ou de baixa, redefinindo uma tendência bem definida;
3. O mercado é cíclico: um comportamento gráfico ocorrido anteriormente tem uma boa probabilidade de acontecer novamente, mesmo que não de forma exata e simétrica.

Tendo em vista essas premissas, o objetivo do investidor grafista é prever os movimentos cíclicos do mercado, identificar tendências e perceber com antecedência o final dessas tendências.

Nesse cenário, introduzem-se os indicadores técnicos que com o uso de diferentes estratégias e fórmulas matemáticas auxiliam na visualização dos sinais de tendência, reversões e ciclos que apenas olhando para o gráfico de preços, nem sempre são de fácil percepção.

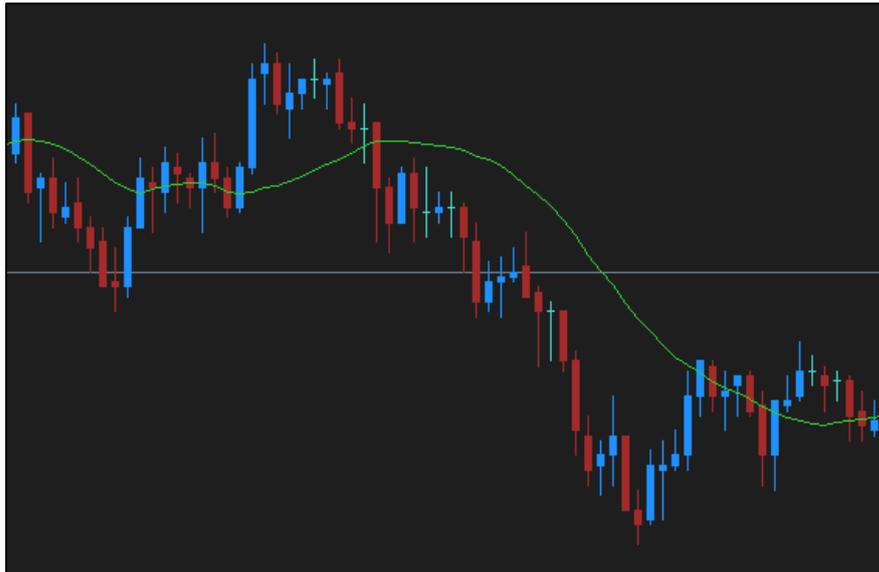
Por exemplo, um indicador amplamente utilizado para detecção de tendências no gráfico é a média móvel simples, dada pela Equação 1.

$$MMS = \frac{P1 + P2 + \dots + Pn}{n} \quad (1)$$

Onde P representa os preços de fechamento dos períodos anteriores e n o número de períodos anteriores a serem utilizados no cálculo.

A Figura 1 mostra uma média móvel simples de 21 períodos aplicada ao gráfico de 1 minuto do minicontrato futuro Ibovespa.

FIGURA 1– MÉDIA MÓVEL SIMPLES



FONTE: O autor (2021).

A interpretação mais comum para identificar a tendência do gráfico, de acordo com esse indicador, é a partir da seguinte lógica: caso os preços estiverem abaixo da linha traçada pelo indicador, está sendo indicada uma tendência baixa, ou seja, o investidor pode considerar a possibilidade vender o ativo analisado. Da mesma forma, se o patamar de preços estiver acima do indicador, a recomendação é de compra.

2.3 REDES NEURAIS ARTIFICIAIS

2.3.1 Neurônio biológico

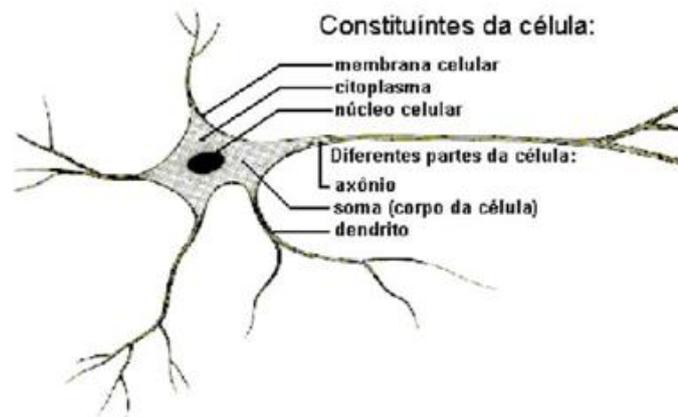
O sistema nervoso humano, inspiração para as redes neurais artificiais, é composto por mais de 100 bilhões de neurônios. O impulso que carrega a informação entra na célula neuronal por meio de sinapses em seus dendritos. Esses impulsos recebidos podem provir dos terminais do axônio de outro neurônio, que por sua vez recebeu informações de um terceiro, e assim por diante.

Segundo Figueiredo (2008), os neurônios são compostos, basicamente, por:

- Dendritos: recebem as informações em forma de impulsos nervosos por meio das sinapses;
- Corpo de Neurônio (Soma): Responsável por combinar as informações recebidas pelos dendritos;
- Axônio: Pode alcançar até alguns metros, sendo incumbido de levar as informações processadas em seu neurônio adiante.

O esquema descrito exemplifica uma rede neural biológica, conforme Figura 2.

FIGURA 2 – REPRESENTAÇÃO DO NEURÔNIO BIOLÓGICO



FONTE: Mine (2010).

2.3.2 Neurônio artificial

Tais como sua inspiração, as redes neurais artificiais são compostas por neurônios computacionais que se unem funcionalmente por meio de ligações sinápticas. Essas ligações podem ser ampliadas ou enfraquecidas de acordo com parâmetros atribuídos a elas, os pesos sinápticos.

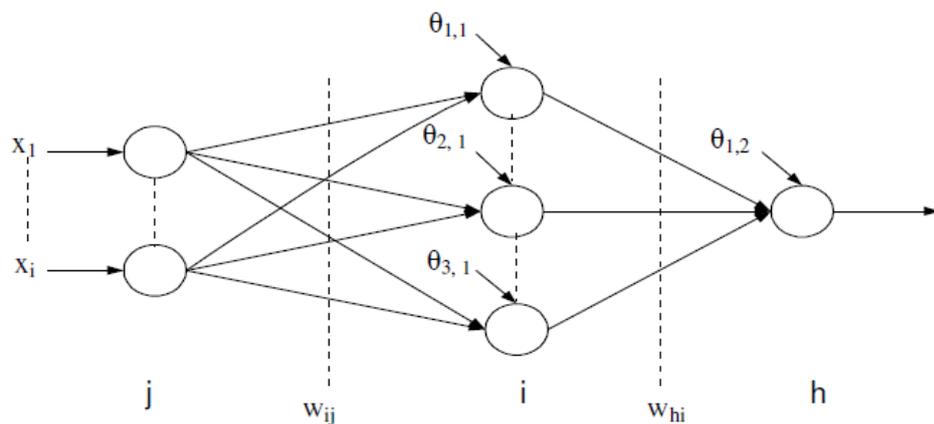
Em meio à rede artificial, os neurônios artificiais trabalham individualmente recebendo sinais de entrada, processando-os e encaminhando seus resultados aos próximos neurônios (PASCUOTTO, 2010).

2.3.3 Multilayer perceptron

As redes neurais do tipo *Multilayer Perceptron* são constituídas de três partes, ou três tipos de camadas, como são comumente chamadas em seu estudo. A primeira, chamada de camada de entrada, é a unidade sensorial, ou seja, é responsável por receber os sinais de entrada na rede e encaminhá-los para a próxima camada. O meio da rede é composto por uma ou mais camadas escondidas ou também chamadas de camadas ocultas, os neurônios que compõe essas camadas capacitam a rede a extrair as características dos padrões recebidos na camada de entrada. Por fim, tem-se a camada de saída, composta pelos neurônios encarregados de retornar a resposta da rede ao estímulo recebido na primeira camada (HAYKIN, 2001).

A Figura 3 representa uma rede do tipo *Multilayer Perceptron* com uma camada escondida, em que j identifica os neurônios da camada de entrada, i os da(s) camada(s) escondida(s), h os da camada de saída, w_{ij} e w_{hi} são os pesos relacionados aos respectivos neurônios e os θ são as constantes somadas ao final da função linear vinculada a cada neurônio, chamadas de *bias*.

FIGURA 3 – REDE NEURAL ARTIFICIAL DO TIPO *MULTILAYER PERCEPTRON* COM UMA ÚNICA CAMADA ESCONDIDA.



FONTE: Figueiredo (2008)

2.3.4 Forward

De acordo com Oliveira (2007), após receber os sinais de entrada, esses são multiplicados pelos seus respectivos pesos. Simbolicamente dizendo, o sinal x_j recebido pelo neurônio j da camada de entrada ligado ao neurônio i da primeira camada escondida, é multiplicado pelo peso sináptico w_{ij} .

Multiplicados os sinais de entrada por seus pesos sinápticos, é feita a somatória dessas ponderações no neurônio i , conforme Equação 2.

$$u_i = \sum_{j=1}^m w_{ij} x_j \quad (2)$$

Onde m é o número de neurônios na camada de entrada.

Em seguida, ainda no neurônio i , é aplicada uma função de ativação $\varphi(\cdot)$ (detalhada mais adiante) à somatória acrescida de um *bias*, simbolizado por θ_i e responsável por aumentar ou diminuir a entrada líquida da função de ativação. Dessa forma se obtém, por fim, a saída y_i do neurônio i , dada pela Equação 3.

$$y_i = \varphi(v_i) \quad (3)$$

Onde $v_i = u_i + \theta_i$.

Essas operações se repetem camada por camada em cada um de seus neurônios, sendo as entradas de um neurônio as próprias saídas da camada anterior. Por fim, na última camada (camada de saída), as saídas de seus neurônios serão os estados finais da rede, que são, portanto, seu retorno.

2.3.5 Funções de ativação

As funções de ativação são elementos que permitem mapeamentos mais elaborados para as saídas dos neurônios do que as combinações lineares da sua entrada. Sua escolha depende de vários aspectos, como principalmente o tipo de problema a ser assimilado pela rede e o algoritmo de treinamento a ser utilizado (FREITAS, 2008).

Alguns exemplos de funções de ativação geralmente empregadas são:

1. Função Linear por Partes

$$\varphi(v) = \begin{cases} 0, & v \leq v_0; \\ av + b, & v_0 < v < v_1; \\ 1, & v \geq v_1. \end{cases} \quad (4)$$

2. Função Limiar

$$\varphi(v) = \begin{cases} 0, & v < 0; \\ 1, & v \geq 0. \end{cases} \quad (5)$$

3. Função Sigmoidal Logística

$$\varphi(v) = \frac{c}{1 + \exp(-av)} + b. \quad (6)$$

4. Função tangente hiperbólica

$$\varphi(v) = \frac{\sinh v}{\cosh v} \quad (7)$$

2.4 ALGORITMO GENÉTICO

Algoritmos genéticos (AGs) são técnicas de otimização que se baseiam no princípio Darwiniano de seleção natural e reprodução genética, ou seja, o princípio de seleção privilegia os indivíduos mais aptos (MITCHELL, 1996).

Por meio de uma estratégia de busca paralela e estruturada, mas aleatória, busca por pontos de "alta aptidão", ou seja, pontos nos quais a função a ser minimizada (ou maximizada) tem valores relativamente baixos (ou altos). Apesar de aleatória, a busca por melhores resultados é direcionada, pois exploram informações históricas para encontrar novos pontos de busca onde é esperado melhor desempenho. Isto é feito por processos iterativos, onde cada iteração é chamada de geração.

Durante cada iteração, as regras de seleção e reprodução são aplicadas a uma população de candidatos que pode variar dependendo da complexidade do problema e dos recursos computacionais disponíveis. Na fase de seleção, se determina quais indivíduos conseguirão se reproduzir, gerando um número determinado de descendentes para a próxima geração, com uma probabilidade determinada pelo seu índice de aptidão.

2.4.1 Fases do processo evolutivo

Para adaptar a teoria darwinista ao algoritmo de otimização, Holland (1975) decompôs o funcionamento dos AGs nas etapas de inicialização, avaliação, seleção, cruzamento, mutação, atualização e finalização. Para o primeiro passo, o algoritmo cria uma população de possíveis soluções para o problema a ser otimizado e na sequência passa pelas seguintes etapas:

1. Avaliação

Avalia-se a aptidão das soluções geradas (indivíduos da população). Para isso, é utilizada uma função que melhor represente o problema a fim de fornecer a medida de aptidão de cada indivíduo da população corrente. Por exemplo, para a função $f(x) = -x^2 + 5x$, a aptidão de dois indivíduos representados por números binários, é descrita na Tabela 1.

TABELA 1 – EXEMPLO DA FASE DE APTIDÃO DE UM AG

	Indivíduo	x	f(x)
A1	0 0 1 0 0 1	9	-36
A2	0 0 0 1 0 0	4	4

FONTE: O autor (2021).

Caso o objetivo da otimização seja a maximização do resultado, o indivíduo A2 se mostra mais apto do que o A1, nesse exemplo.

2. Seleção

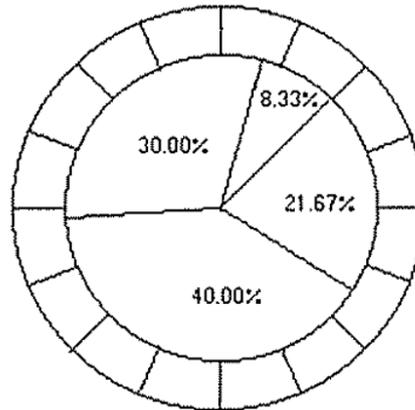
As soluções que no passo anterior tiveram maior aptidão, passam a ter uma probabilidade maior de se reproduzir, ou seja, as probabilidades são distribuídas de forma proporcional a aptidão calculada, ou seja, se f_i é a avaliação do indivíduo i na população corrente, a probabilidade P_i do indivíduo i ser selecionado para a reprodução é representada pela Equação 8.

$$P_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (8)$$

Onde N é o número de indivíduos da população.

A seleção para os algoritmos genéticos é tipicamente implementada como uma roleta, onde as probabilidades de cada indivíduo são distribuídas para sorteio, como exemplificado no esquema da Figura 4.

FIGURA 4 – ESTRUTURA DE ROLETA UTILIZADA NA FASE DE SELEÇÃO



FONTE: Soares (1997)

3. Cruzamento

As características das soluções selecionadas no passo anterior, são recombinadas, gerando novos indivíduos. Essa recombinação é feita por meio do operador de *crossover*, que consiste na troca de material genético a partir da geração aleatória de um ponto de corte em dois indivíduos selecionados na fase anterior, gerando seus descendentes como exemplificado na Tabela 2, que mostra a reprodução dos dois indivíduos mostrados na Tabela 1.

TABELA 2 – EXEMPLO DA FASE DE CRUZAMENTO DE UM AG

	Indivíduo
A1	0 0 1 0 0 1
A2	0 0 0 1 0 0
Descendente 1	0 0 1 1 0 0
Descendente 2	0 0 0 0 1

FONTE: O autor (2021).

4. Mutação

Características dos indivíduos gerados na fase de cruzamento são alterados aleatoriamente, simulando mutações naturais para gerar diversidade na população, ou seja, o conteúdo de uma posição do indivíduo é trocado de acordo com uma

determinada probabilidade, geralmente <1%. A Tabela 3 exemplifica um indivíduo antes e depois desse processo.

TABELA 3 – EXEMPLO DA FASE DE MUTAÇÃO DE UM AG

	Indivíduo
Antes	0 0 1 0 0 <u>1</u>
Depois	0 0 1 0 0 <u>0</u>

FONTE: O autor (2021).

5. Atualização

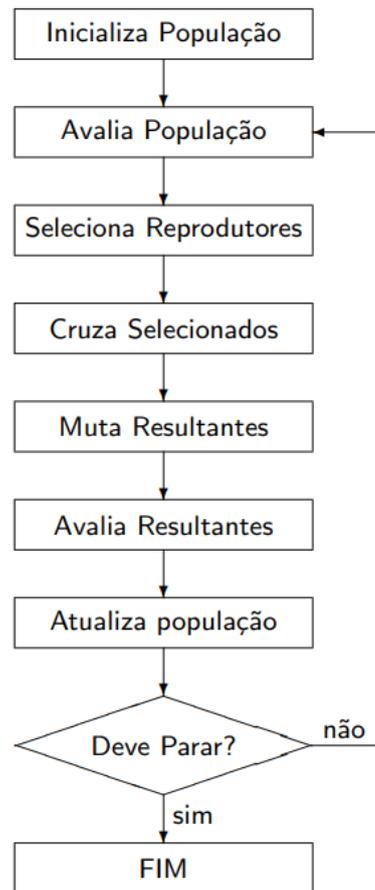
Os indivíduos gerados a partir das fases anteriores são adicionados a população.

6. Finalização

Finaliza o processo de evolução caso um resultado satisfatório já tenha sido atingido ou retorna a fase de avaliação, caso contrário.

As fases descritas são ilustradas no esquema da Figura 5.

FIGURA 5 – ESTRUTURA BÁSICA DE UM ALGORITMO GENÉTICO



FONTE: Lucas (2002)

3 MATERIAL E MÉTODOS

Para o desenvolvimento desse trabalho, será utilizado um ativo de alto risco comumente negociado por *day traders*, o minicontrato de índice Bovespa. Os dados históricos desse ativo estão disponíveis para *download* nas bases de dados de qualquer corretora brasileira.

A criação dos robôs será feita na plataforma gratuita de negociação *Metatrader 5*, que permite por meio de sua linguagem própria de programação, a criação dos mais diversos tipos de *expert advisors*. A plataforma também disponibiliza um algoritmo de otimização genética para a melhor parametrização desses robôs, o que auxiliará tanto na regulagem dos parâmetros dos indicadores quanto nos da rede neural artificial utilizada mais adiante.

Tendo em vista o objetivo de comparar os resultados financeiros de operações na bolsa de valores no mini índice Bovespa dos dois métodos para o mesmo período de simulação, foram estabelecidas um conjunto de etapas, explicadas adiante.

3.1 SELEÇÃO DO TIPO DE REDE NEURAL UTILIZADA

Duas considerações foram feitas na escolha do tipo de rede neural artificial utilizada no trabalho: primeiramente, analisou-se se o tipo de RNA atendia os objetivos, ou seja, a factibilidade de utilizar-se valores de indicadores técnicos como *inputs*, retornando um comando de compra ou venda, mas principalmente se havia a possibilidade de os pesos sinápticos da rede serem regulados a partir de um algoritmo genético. Em segundo lugar, a viabilidade da implementação computacional da rede no *Software* utilizado para fazer as simulações e aplicação do algoritmo genético (*Metatrader 5*). Dessa forma, foi escolhida a RNA do tipo *Multilayer Perceptron*.

3.2 ESCOLHA DOS INDICADORES

Para selecionar os melhores indicadores técnicos para essa pesquisa, foram utilizados dois critérios:

- Os indicadores usados devem ter apenas 1 retorno interpretativo de seus valores, ou seja, por mais complexa que seja a leitura desses

indicadores, a conclusão de sua interpretação deve ser apenas um sinal de compra ou de venda;

- Esses indicadores devem estar disponíveis gratuitamente na plataforma *Metatrader 5*.

Por fim, foram selecionados um total de quatorze indicadores que serão dados como opção de uso nos *expert advisors*, são eles: *Accelerator Oscillator*, *Adaptive Moving Average*, *Awesome Oscillator*, *Chaikin Oscillator*, *Force Index*, *Money Flow Index*, *Moving Average of Oscillator*, *Parabolic Stop and Reverse system*, *Relative Strength Index*, *Triple Exponential Moving Averages Oscillator*, *Larry Williams' Percent Range*, *Moving Averages Convergence/Divergence* e *Average True Range*.

3.3 IMPLEMENTAÇÃO COMPUTACIONAL DOS EXPERT ADVISORS

Utilizando a plataforma de negociação *Metatrader 5* e seu editor de linguagem *MetaQuotes*, foi criado primeiramente o código que gera sinais de compra ou venda diretamente a partir da leitura e interpretação dos indicadores selecionados no passo anterior, esses sinais computacionalmente representam compra quando tem valor “1”, venda quando “-1” e “0” quando o mercado está lateralizado e nenhuma ação deve ser feita. Quando o robô está em seu horário de funcionamento, essa análise ocorre ao início de cada novo minuto.

Para o usuário, a seleção dos indicadores a serem efetivamente utilizados durante as negociações e seus respectivos parâmetros acontece por meio do painel mostrado na Figura 6.

FIGURA 6 – PARTE DO PAINEL DE CONFIGURAÇÃO DOS INDICADORES DO *EXPERT ADVISOR* DE ANÁLISE TÉCNICA

Indicadores	
<input type="checkbox"/> AC: Usar	false
<input type="checkbox"/> AC: Estratégia	Tendência
<input type="checkbox"/> AC: Timeframe	10 Minutes
<input type="checkbox"/> AMA: Usar	false
<input type="checkbox"/> AMA: Período	34
<input type="checkbox"/> AMA: Fast	18
<input type="checkbox"/> AMA: Slow	44
<input type="checkbox"/> AMA: Timeframe	6 Minutes
<input type="checkbox"/> AO: Usar	false
<input type="checkbox"/> AO: Estratégia	Tendência
<input type="checkbox"/> AO: Timeframe	6 Minutes
<input type="checkbox"/> CO: Usar	true
<input type="checkbox"/> CO: Estratégia	Cruzamento 0
<input type="checkbox"/> CO: Fast	22
<input type="checkbox"/> CO: Slow	12
<input type="checkbox"/> CO: Timeframe	6 Minutes

FONTE: O autor (2021).

Cada indicador tem seus parâmetros específicos a serem regulados e podem ser distinguidos no painel por meio da sigla de cada indicador: “AC” para o *Accelerator Oscillator*, “AMA” para o *Adaptive Moving Average*, “AO” para o *Awesome Oscillator*, e assim por diante. Portanto, como mostrado na Figura 6, a primeira parametrização de cada indicador é a seleção de “true” ou “false” para que o robô utilize ou não esse indicador em suas análises, respectivamente, já os campos seguintes são os parâmetros particulares de cada indicador.

Em seguida, o segundo *expert advisor* foi implementado, inicialmente exatamente igual ao primeiro, porém com o acréscimo da fase de *forward* da estrutura *multilayer perceptron*, implementada de modo genérico, ou seja, o painel de definição dos parâmetros permite escolher o número de neurônios nas camadas de entrada e escondida, o único parâmetro de rede fixo no código é a função de ativação, definida como a função tangente hiperbólica. Para a camada de entrada a definição do número de neurônios será dada pelo número de indicadores definidos como “true” no parâmetro “Usar” de cada indicador, porém com uma restrição de no máximo 8, devido a limitações computacionais. Já a camada escondida tem o número de neurônios definido pelo usuário a partir do painel, como mostrado na Figura 7, com uma restrição de no máximo 10 neurônios, também por conta de limitações computacionais.

FIGURA 7 – PARTE DO PAINEL DE CONFIGURAÇÃO DOS PARÂMETROS DE REDE DO *EXPERT ADVISOR* COM REDE NEURAL ARTIFICIAL



FONTE: O autor (2021).

Por fim, o painel reserva um espaço para todos os pesos sinápticos e valores de *bias* a serem imputados pelo usuário, de modo que j identifica os neurônios da camada escondida, i os da camada de entrada e k os da camada de saída, portanto, o parâmetro w_{i2j1} representa o peso sináptico entre o segundo neurônio da camada de entrada e o primeiro da camada escondida, o parâmetro $bias_{j3}$ representa o valor do *bias* do terceiro neurônio da camada escondida e assim por diante, como exemplificado na Figura 8.

FIGURA 8 – PARTE DO PAINEL DE DEFINIÇÃO DOS PESOS SINÁPTICOS NO *EXPERT ADVISOR* COM REDE NEURAL ARTIFICIAL

Pesos	
<input type="checkbox"/> w_{i1j1}	0.5
<input type="checkbox"/> w_{i1j2}	-0.45
<input type="checkbox"/> w_{i1j3}	-0.9
<input type="checkbox"/> w_{i1j4}	0.85
<input type="checkbox"/> w_{i1j5}	-1.6
<input type="checkbox"/> w_{i1j6}	-1.7
<input type="checkbox"/> w_{i1j7}	-1.15
<input type="checkbox"/> w_{i1j8}	0.6
<input type="checkbox"/> w_{i1j9}	0.4
<input type="checkbox"/> w_{i1j10}	-1.2
<input type="checkbox"/> w_{i2j1}	-2.0
<input type="checkbox"/> w_{i2j2}	-1.55

FONTE: O autor (2021).

3.4 DEFINIÇÃO DOS INDICADORES E REGULAGEM DOS PARÂMETROS

Essa primeira etapa após a implementação computacional, consiste na utilização do algoritmo genético disponibilizado pelo *Metatrader 5* para regulagem do *expert*

advisor sem rede neural artificial. O algoritmo decidirá: quais os alvos de ganho e perda, quais indicadores efetivamente serão utilizados dentre os disponíveis e os valores dos respectivos parâmetros de cada indicador.

Na plataforma, é possível selecionar o ativo negociado, o robô a ser otimizado e o período utilizado na otimização. O ativo utilizado no trabalho é o minicontrato Ibovespa, selecionado pela sigla “WIN@N”, o robô foi denominado “EA sem RNA” e o período foi definido de 01/08/2020 até 01/04/2021, como mostrado na Figura 9.

FIGURA 9 – PAINEL DE SELEÇÃO DOS PARÂMETROS DE OTIMIZAÇÃO NO METATRADER 5 PARA O ROBÔ SEM RNA

Expert Advisor (Robô): EA sem RNA.ex5

Ativo: WIN@N M1

Data: Período personalizado 2020.08.01 2021.04.01

FONTE: O autor (2021).

Na sequência, define-se quais *inputs* do robô serão regulados por meio da otimização genética, selecionando no painel os indicadores e seus respectivos parâmetros, como na Figura 10.

FIGURA 10 – SELEÇÃO DOS PARÂMETROS A SEREM OTIMIZADOS

Variável	Valor	Iniciar	Passo	Parar	Passos
Indicadores					
<input checked="" type="checkbox"/> AC: Usar	false	false		true	2
<input checked="" type="checkbox"/> AC: Estratégia	Tendência	Sinal		Tendência_Sinal	4
<input checked="" type="checkbox"/> AC: Timeframe	10 Minutes	1 Minute		10 Minutes	7
<input checked="" type="checkbox"/> AMA: Usar	false	false		true	2
<input checked="" type="checkbox"/> AMA: Período	0	4	6	48	8
<input checked="" type="checkbox"/> AMA: Fast	0	2	4	24	6
<input checked="" type="checkbox"/> AMA: Slow	0	12	8	72	8
<input checked="" type="checkbox"/> AMA: Timeframe	6 Minutes	1 Minute		10 Minutes	7
<input checked="" type="checkbox"/> AO: Usar	false	false		true	2

FONTE: O autor (2021).

Nesta fase, para cada linha selecionada para ser otimizada pelo algoritmo genético, devem ser estabelecidos os limites de variação e o tamanho do passo, para cada um dos parâmetros. Por exemplo, na Figura 10, o parâmetro “AMA: Período” poderá ser variado aleatoriamente pelo algoritmo genético entre 4 e 48 à passos de 6 em 6, e assim por diante.

Sobre esta fase, cabe destacar que o que está sendo feito com a seleção dos parâmetros para otimização nada mais é que a definição do tamanho dos indivíduos que serão gerados durante os processos iterativos do algoritmo genético. Por exemplo, para os parâmetros selecionados na Figura 10, em algum momento do processo iterativo podemos ter os indivíduos A1 e A2, que por meio do processo de cruzamento gerarão os descendentes D1 e D2, como mostra a Tabela 4.

TABELA 4 – EXEMPLO DA FASE DE CRUZAMENTO DE UM AG APLICADO AO ROBÔ SEM RNA

	INDIVÍDUO								
	AC: Usar	AC: Estratégia	AC: Timeframe	AMA: Usar	AMA: Período	AMA: Fast	AMA: Slow	AMA: Timeframe	AO: Usar
A1	False	Sinal	1 min	True	12	22	64	5 min	True
A2	True	Sinal	1min	False	30	6	36	10 min	True
D1	False	Sinal	1 min	True	12	6	36	10 min	True
D2	True	Sinal	1min	False	30	22	64	5 min	True

FONTE: O autor (2021).

3.5 SELEÇÃO DE DIFERENTES PERFIS

Após a definição de quais indicadores usar e os valores de seus respectivos parâmetros por meio da otimização genética, o *software* disponibiliza a lista de todos indivíduos resultantes na ordem de melhor para a pior aptidão, que nesse caso, é definida pela rentabilidade financeira, ou fator de lucro, no período otimizado, como exemplificado na Figura 11.

FIGURA 11 – EXEMPLOS DE RESULTADOS DA OTIMIZAÇÃO GENÉTICA

Lucro	Total de neg...	Fator de Lucro	use_AC	ac_strategy	timeframeAC	use_AMA	AMA_period
179.00	6	4.89	true	Tendência	6 Hours	true	32
121.00	5	4.36	false	Sinal	3 Minutes	true	42
121.00	5	4.36	false	Sinal	1 Hour	false	81
105.00	6	2.67	true	Tendência_Si...	4 Hours	true	21
105.00	6	2.67	true	Tendência_Si...	4 Hours	true	21
286.00	19	2.38	false	Sinal	current	false	9
286.00	19	2.38	false	Sinal	current	false	9
104.00	7	2.05	false	Tendência	12 Hours	false	82
436.00	37	1.93	false	Sinal	current	false	9
436.00	40	1.89	false	Sinal	current	false	9
158.00	41	1.24	false	Sinal	current	false	9
116.00	41	1.17	false	Sinal	current	false	9

FONTE: O autor (2021).

Contudo, não ter a maior rentabilidade (fator de lucro) não significa que a combinação de parâmetros não seja viável, dependerá do perfil do investidor, por exemplo: é possível que se faça três negociações durante o dia, sendo elas duas com lucro de 10 reais cada, e uma com prejuízo também de 10, dessa forma, no final do dia o *trader* teria um lucro de 10 reais e um fator de lucro de 2. Em contra partida, um outro *trader* mais agressivo pode preferir reduzir o fator de lucro de suas operações visando um maior lucro, fazendo 20 negociações em um dia sendo elas: 12 ganhadoras de 10 reais cada e 8 perdedoras também de 10 reais, tendo no final do dia um lucro de 40 reais, 4 vezes maior que o do primeiro investidor, porém com um fator de lucro menor, de 1.5.

Dito isso, foram selecionados entre os indivíduos gerados na otimização genética, três perfis para o robô sem rede neural artificial: um mais conservador que visa a maior rentabilidade, fazendo poucas negociações ao dia, um mais arrojado que busca por um lucro mais alto mesmo isso custando uma diminuição na rentabilidade e portanto um aumento no risco, e entre eles um terceiro com perfil moderado.

A Tabela 5 mostra os indicadores selecionados com “*true*” pelo algoritmo genético, ou seja, que serão utilizados pelo *expert advisor* para cada perfil de investidor.

TABELA 5 – INDICADORES SELECIONADOS POR PERFIL

PERFIL	NÚMERO DE INDICADORES	INDICADORES
CONSERVADOR	8	<i>Accelerator Oscillator, Adaptive Moving Average, Force Index, Money Flow Index, Moving Average of Oscillator, Parabolic Stop and Reverse system, Triple Exponential Moving Averages Oscillator e Moving Averages Convergence/Divergence.</i>
MODERADO	6	<i>Awesome Oscillator, Moving Average of Oscillator, Relative Strength Index, Triple Exponential Moving Averages Oscillator, Larry Williams' Percent Range e Moving Averages Convergence/Divergence.</i>
AGRESSIVO	6	<i>Chaikin Oscillator, Force Index, Money Flow Index, Relative Strength Index, Larry Williams' Percent Range e Moving Averages Convergence/Divergence.</i>

FONTE: O autor (2021).

3.6 REGULAGEM DOS PESOS SINÁPTICOS DA REDE NEURAL

Nesta etapa serão gerados os resultados do *expert advisor* que utiliza a rede neural artificial, para isso, os parâmetros de otimização genética serão regulados da mesma forma apresentada na Figura 9, a única alteração será no robô utilizado, denominado “*Perceptron*”, como mostra a Figura 12.

FIGURA 12 – PAINEL DE SELEÇÃO DOS PARÂMETROS DE OTIMIZAÇÃO NO METATRADER 5 PARA O ROBÔ COM RNA

Expert Advisor (Robô): Perceptron.ex5

Ativo: WIN@N M1

Data: Período personalizado 2020.08.01 2021.04.01

FONTE: O autor (2021).

Para os três perfis, um por vez, são fixados os indicadores de acordo com a Tabela 3 e seus respectivos parâmetros definidos no passo anterior. Então, apenas os pesos sinápticos e o número de neurônios na camada escondida são selecionados para a otimização genética, como exemplificado nas Figuras 13 e 14, respectivamente.

FIGURA 13 – EXEMPLO DE SELEÇÃO DOS PESOS SINÁPTICOS PARA OTIMIZAÇÃO GENÉTICA

Variável	Valor	Iniciar	Passo	Parar	Passos
Pesos					
<input checked="" type="checkbox"/> wi1j1	0.9	-2	0.05	2	81
<input checked="" type="checkbox"/> wi1j2	-0.9	-2	0.05	2	81
<input checked="" type="checkbox"/> wi1j3	0.5	-2	0.05	2	81
<input checked="" type="checkbox"/> wi1j4	-0.4	-2	0.05	2	81
<input checked="" type="checkbox"/> wi1j5	-0.85	-2	0.05	2	81
<input checked="" type="checkbox"/> wi1j6	0.2	-2	0.05	2	81

FONTE: O autor (2021).

A variação desses pesos pelo algoritmo genético deve obedecer a restrição de permanecer no intervalo de -2 até 2 e variar em passos de 0.05, devido a limitações

computacionais. Aqui entende-se o mesmo funcionamento do explicado anteriormente na Tabela 4.

FIGURA 14 – SELEÇÃO DO PARÂMETRO DE NÚMERO DE NEURÔNIOS NA CAMADA ESCONDIDA PARA OTIMIZAÇÃO GENÉTICA



FONTE: O autor (2021).

Portanto, o número de neurônios na camada oculta e seus respectivos pesos sinápticos serão regulados ao mesmo tempo pelo algoritmo genético.

O número de neurônios na camada de entrada definidos no passo anterior por meio da seleção dos indicadores utilizados, e o número de neurônios na camada oculta (definidos após a otimização), para cada perfil, são mostrados na Tabela 6.

TABELA 6 – NÚMERO DE NEURÔNIOS NAS CAMADAS DE ENTRADA E OCULTA

PERFIL	NÚMERO DE NEURÔNIOS NA CAMADA DE ENTRADA	NÚMERO DE NEURÔNIOS NA CAMADA ESCONDIDA
CONSERVADOR	8	8
MODERADO	6	7
AGRESSIVO	6	7

FONTE: O autor (2021).

Nesse processo, espera-se que os resultados financeiros de cada perfil sejam maximizados pelo uso da rede neural artificial treinada pelo algoritmo genético.

4 APRESENTAÇÃO DOS RESULTADOS

A Tabela 7 mostra lado a lado os resultados dos três perfis de cada robô para o período utilizado na aplicação do algoritmo genético para a regulação dos parâmetros dos indicadores e pesos sinápticos da rede neural, 01/08/2020 até 01/04/2021.

TABELA 7 – COMPARATIVO NO PERÍODO DE REGULAGEM

	PERÍODO DE REGULAGEM					
	Análise Técnica Pura			Com Rede Neural		
	Lucro	Fator de Lucro	Neg/dia	Lucro	Fator de Lucro	Neg/dia
Conservador	R\$ 2.253,00	2,03	0,84	R\$ 2.425,00	2,11	0,86
Moderado	R\$ 3.125,00	1,6	1,43	R\$ 3.876,00	1,77	1,42
Agressivo	R\$ 5.267,00	1,42	2,49	R\$ 6.569,00	1,57	2,38

FONTE: O autor (2021).

Os dados da Tabela 7 mostram uma clara capacidade da rede neural artificial de maximizar o resultado obtido apenas pela análise crua dos indicadores, dado que houve um aumento no desempenho tanto no lucro quanto no fator de lucro para os três cenários testados. Isso se deve pelo seu poder de, devido a regulação dos pesos sinápticos, priorizar a leitura dos indicadores que historicamente se mostram mais importantes e reduzir o impacto na tomada de decisão dos que no histórico não foram tão efetivos.

Os percentuais de melhoria são apresentados na Tabela 8.

TABELA 8 – PERCENTUAIS DE MELHORIA A PARTIR DO USO DA REDE NEURAL ARTIFICIAL NO PERÍODO DE REGULAGEM

	PERÍODO DE REGULAGEM	
	% de aumento dos desempenhos	
	Lucro	Fator de Lucro
Conservador	7,6%	3,9%
Moderado	24,0%	10,6%
Agressivo	24,7%	10,6%

FONTE: O autor (2021).

Contudo, um importante aspecto para a viabilidade da utilização desses robôs é a habilidade de generalização, ou seja, os bons resultados devem prevalecer não só no período utilizado na otimização genética como também em um período posterior de teste. Na Tabela 9 são mostrados os resultados dos dois robôs para o período de teste de 01/04/2021 até 01/06/2021.

TABELA 9 – COMPARATIVO NO PERÍODO DE TESTE

	PERÍODO DE TESTE					
	Análise Técnica Pura			Com Rede Neural		
	Lucro	Fator de Lucro	Neg/dia	Lucro	Fator de Lucro	Neg/dia
Conservador	-R\$ 281,00	0,54	0,84	-R\$ 277,00	0,58	0,91
Moderado	R\$ 123,00	1,13	1,20	R\$ 388,00	1,55	0,95
Agressivo	R\$ 554,00	1,25	2,09	R\$ 1.143,00	1,56	2,25

FONTE: O autor (2021).

Dessa forma, evidencia-se a superioridade também de capacidade de generalização e, portanto, adaptação as variações do mercado, quando se faz o uso da rede neural artificial. Os percentuais de melhoria para o período de teste são mostrados na Tabela 10.

TABELA 10 – PERCENTUAIS DE MELHORIA A PARTIR DO USO DA REDE NEURAL ARTIFICIAL NO PERÍODO DE TESTE

	PERÍODO DE TESTE	
	% de aumento dos desempenhos	
	Lucro	Fator de Lucro
Conservador	1,4%	7,4%
Moderado	215,4%	37,2%
Agressivo	106,3%	24,8%

FONTE: O autor (2021).

A partir dos resultados obtidos, evidencia-se a melhoria dos retornos financeiros a partir da utilização da rede neural artificial em conjunto da análise técnica, contudo, um dos cenários não mostrou capacidade de generalização, uma vez que os resultados para o período de teste não foram tão bons quanto para o período de regulagem, em ambos robôs. Isso pode se explicar pelo fato do mercado ser muito volátil, principalmente quando se trata de minicontratos futuros, ou seja,

ativos de alto risco, portanto, flutuações no desempenho são sempre esperadas. Além disso, o baixo número de negociações feito pelo perfil conservador faz com que sua estratégia seja muito especializada, esperando sempre um movimento muito específico do mercado para tomar a decisão de abrir uma posição, seja de compra ou de venda, isso dificulta o aumento do poder de generalização, refletindo então nos resultados abaixo do esperado quando aplicado a períodos de teste.

As duas configurações do robô que melhor se saíram (moderado e agressivo), foram submetidas a uma segunda rodada de teste. Desta vez em um período de grande estabilidade do mercado: os três primeiros meses em que a pandemia da covid-19 chegou ao Brasil (fev/2019 à abr/2019). A Tabela 11 mostra os resultados obtidos.

TABELA 11 – RESULTADOS DOS MELHORES PERFIS NO ROBÔ COM RNA NO INÍCIO DA PANDEMIA DA COVID-19

	INÍCIO DA PANDEMIA		
	Lucro	Fator de Lucro	Neg/dia
Moderado	R\$ 117,00	1,08	1,03
Agressivo	R\$ 54,00	1,01	2,33

FONTE: O autor (2021).

Apesar do resultado financeiro ter sido ínfimo para um período de três meses, levando em conta as divergências de padrões de mercado devido à distância temporal entre o período de regulagem e teste, e principalmente a instabilidade do período testado, o resultado positivo evidencia novamente a capacidade de generalização e adaptação proporcionado pela utilização da rede neural artificial.

5 CONSIDERAÇÕES FINAIS

O algoritmo genético é uma poderosa ferramenta para *day traders*. A regulagem dos parâmetros dos indicadores usados por um investidor, quando feito de forma manual, pode demorar semanas ou até meses para atingir o desempenho esperado e dependerá do conhecimento e atenção do investidor. Mesmo que este não queira utilizar robôs para automatizar suas negociações, ele pode utilizar dessa ferramenta para, por meio do algoritmo genético, definir a melhor configuração para seus indicadores.

Redes neurais artificiais podem ser treinadas de forma satisfatória por meio de algoritmos genéticos. Para a utilização desenvolvida nesse trabalho, o algoritmo genético se mostrou eficiente para fazer a regulagem dos pesos sinápticos da estrutura *multilayer perceptron*, além de escolher seu número de neurônios.

Sinais de indicadores técnicos podem ser interpretados por uma estrutura de rede neural artificial, retornando bons resultados. Durante suas análises diárias, um investidor experiente consegue perceber oportunidades no mercado mesmo que nem todos os indicadores que ele utiliza evidenciem um sinal bem definido, uma vez que alguns indicadores podem ter um maior peso na tomada de decisão do que outros, esse peso e a experiência do investidor podem ser reproduzidos de forma satisfatória por uma rede neural artificial bem treinada, aumentando o desempenho de uma estratégia de análise técnica baseada em indicadores.

Dito isso, futuros trabalhos podem utilizar para esse mesmo método, diferentes indicadores e diferentes interpretações para esses indicadores. Além de ser possível variar também o tipo de rede neural utilizada.

REFERÊNCIAS

ABE, M. **Manual de Análise Técnica: Essência e Estratégias Avançadas**. 1.Ed. São Paulo: Novatec, 2009.

B3, Histórico de Pessoas Físicas. Disponível em: http://www.b3.com.br/pt_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/historico-pessoas-fisicas/. Acesso em: 26 jul. 2021.

CLEAR CORRETORA. Como operar minicontratos, 2018. Disponível em: https://blog.clear.com.br/como-operar-minicontratos/?gclid=CjwKCAjw9aiIBhA1EiwAJ_GTSm75rV9hEcnISOSmyHBogy_Uit eN-B5Q2w0ybrDQS6NVBrMWRfKnBoCbaQQAvD_BwE. Acesso em: 26 jul. 2021.

FIGUEIREDO, C. J. **Previsão de Series Temporais Utilizando a Metodologia Box-Jenkins e Redes Neurais para Inicialização de Planejamento e Controle de Produção**. Dissertação (Mestrado) – UFPR Universidade Federal do Paraná, Curitiba. PR. 2008.

FREITAS, F. D. de. Modelo de Previsão de Carteiras Baseado em Erros de Predição. Tese (Doutorado) – UFES Universidade Federal do Espírito Santo, Vitória, ES, 2008.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. Ed. Porto Alegre: Bookman Companhia, 2001.

HOLLAND, J. **Adaptation in natural and artificial systems**. Ann Arbor: Univ. of Michigan Press, 1975.

LUCAS, D. C. Algoritmo Genético: uma introdução. Apostila de sala de aula. Ferramentas de Inteligência Artificial. (Professor Luís Otávio Alvares). UFRGS Universidade Federal do Rio Grande do Sul. RS. 2002.

MINE, O. M. **Previsão de Demanda de Autopeças com Redes Neurais**. Dissertação (Mestrado). Universidade Federal do Espírito Santo. Vitória. ES. (2010).

MITCHELL, M. **An Introduction to Genetic Algorithms**. MIT Press, 1996.

MODALMAIS. Mini índice: o que é e como operar?, 2020. Disponível em: <https://www.modalmais.com.br/mercado-futuro/mini-indice> . Acesso em: 27 jul. 2021.

MURPHY, J. **Technical Analysis of the Financial Markets**. 1. Ed. New York: NYIF, 1999.

OLIVEIRA, M. A. de. Aplicação de Redes Neurais Artificiais na Análise de Séries Temporais Econômico-Financeiras. Tese (Doutorado). USP Universidade de São Paulo. São Paulo. SP. 2007.

PASQUOTTO, J. L. D. **Previsão de Séries Temporais no Varejo Brasileiro:** Uma investigação comparativa da aplicação de Redes Neurais recorrentes de Elman. Dissertação (Mestrado). USP Universidade de São Paulo. São Paulo. SP. 2010.

SOARES, G. L. **Algoritmo Genético:** Estudo, novas técnicas e aplicações. Dissertação (Mestrado). UFMG Universidade Federal de Minas Gerais. Belo Horizonte. MG. 1997.