

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
DE MINAS GERAIS (IFMG)
CAMPUS BAMBUÍ
BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO

Artur Francisco Pereira Carvalho

**APLICAÇÃO DE UMA META-HEURÍSTICA PARA OTIMIZAÇÃO DE PONTOS DE
SAÍDA DE OPERAÇÕES EM NEGOCIAÇÕES ENVOLVENDO O MINICONTRATO
FUTURO DO ÍNDICE BOVESPA**

BambuÍ – MG
2024

ARTUR FRANCISCO PEREIRA CARVALHO

APLICAÇÃO DE UMA META-HEURÍSTICA PARA OTIMIZAÇÃO DE PONTOS DE SAÍDA DE OPERAÇÕES EM NEGOCIAÇÕES ENVOLVENDO O MINICONTRATO FUTURO DO ÍNDICE BOVESPA

Trabalho de conclusão de curso apresentado ao Curso de Bacharelado em Engenharia de Computação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG) – *Campus* Bambuí para obtenção do grau de Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Ciniro Aparecido Leite Nametala

Catálogo na Fonte Biblioteca IFMG - Campus Bambuí

- C331a Carvalho, Artur Francisco Pereira.
Aplicação de uma meta-heurística para otimização de pontos de saída de operações em negociações envolvendo o minicontrato futuro do índice Bovespa. / Artur Francisco Pereira Carvalho. – 2024.
37 f.; il.: color.
- Orientador: Prof. Dr. Ciniro Aparecido Leite Nametala.
Trabalho de Conclusão de Curso (graduação) - Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – Campus Bambuí, MG, Curso Bacharelado em Engenharia da Computação, 2024.
1. Otimização por enxame de partículas. 2. Algoritmos de otimização. 3. Energia elétrica doméstica. I. Nametala, Ciniro Aparecido Leite. II. Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – Campus Bambuí, MG. III. Título.

CDD 005

Artur Francisco Pereira Carvalho

APLICAÇÃO DE UMA META-HEURÍSTICA PARA OTIMIZAÇÃO DE PONTOS DE SAÍDA DE OPERAÇÕES EM NEGOCIAÇÕES ENVOLVENDO O MINICONTRATO FUTURO DO ÍNDICE BOVESPA

Trabalho de conclusão de curso apresentado ao Curso de Bacharelado em Engenharia de Computação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG) – *Campus Bambuí* para obtenção do grau de Bacharel em Engenharia de Computação.

Aprovado em 11 de Dezembro de 2024 pela banca examinadora:

Prof. Dr. Ciniro Aparecido Leite Nametala – IFMG – *Campus Bambuí* – (Orientador)

Marcos Roberto Ribeiro – IFMG – *Campus Bambuí*

Matheus Clemente de Souza – IFMG – *Campus Bambuí*



Documento assinado eletronicamente por **Ciniro Aparecido Leite Nametala, Coordenador(a) de Curso**, em 11/12/2024, às 10:47, conforme Decreto nº 10.543, de 13 de novembro de 2020.



Documento assinado eletronicamente por **Marcos Roberto Ribeiro, Professor**, em 11/12/2024, às 10:49, conforme Decreto nº 10.543, de 13 de novembro de 2020.



Documento assinado eletronicamente por **Mateus Clemente de Sousa, Professor EBTT**, em 11/12/2024, às 10:49, conforme Decreto nº 10.543, de 13 de novembro de 2020.



A autenticidade do documento pode ser conferida no site <https://sei.ifmg.edu.br/consultadocs> informando o código verificador **2136445** e o código CRC **4573CF02**.

RESUMO

Este trabalho propõe a aplicação de uma meta-heurística para otimizar os pontos de saída de operações no mercado financeiro. A técnica utilizada é a Otimização por Enxame de Partículas (PSO). O estudo é focado no Minicontrato Futuro do Índice Bovespa (WINFUT). O objetivo é maximizar o retorno e minimizar o risco através da definição de pontos de *stop-loss* e *take-profit* ideais. Utilizando uma estratégia baseada no cruzamento de médias móveis, o algoritmo PSO é empregado para otimizar as operações de negociação. A pesquisa adota uma abordagem quantitativa e experimental, combinando análise de dados históricos com simulações para validar a eficácia da estratégia proposta. Os resultados são comparados com uma estratégia de proporção fixa de 3:1, comum em plataformas de negociação, destacando a eficácia do método desenvolvido.

Palavras-chave: Otimização por Enxame de Partículas, PSO, Minicontrato Futuro do Índice Bovespa, *Stop-loss*, *Take-profit*, Algoritmos de Otimização

ABSTRACT

This paper proposes the application of a metaheuristic to optimize the exit points of operations in the financial market. The technique used is Particle Swarm Optimization (PSO). The study focuses only on the Mini Futures Contract of the Bovespa Index (WINFUT). The objective is to maximize return and minimize risk by defining ideal stop-loss and take-profit points. Using a strategy based on the crossover of moving averages, the PSO algorithm is employed to optimize trading operations. The research adopts a quantitative and experimental approach, combining historical data analysis with simulations to validate the effectiveness of the proposed strategy. The results are compared with a fixed ratio strategy of 3:1, common in trading platforms, highlighting the effectiveness of the developed method.

Keywords: Particle Swarm Optimization, PSO, Mini Bovespa Index Futures, Stop-loss, Take-profit, Optimization Algorithms.

LISTA DE SIGLAS

- B3 – Brasil, Bolsa, Balcão
- IFMG – Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais
- WINFUT – Minicontrato Futuro do Índice Bovespa
- TP – *Take-Profit*
- SL – *Stop-Loss*
- PSO – *Particle Swarm Optimization*
- SMA – *Simple Moving Average*
- LSTM – *Long Short-Term Memory*
- GGA – *Genetic Grouping Algorithm*
- ATR – *Average True Range*
- PE – Pregão Eletrônico
- PVV – Pregão Viva Voz

SUMÁRIO

1	INTRODUÇÃO	8
1.1	Justificativa e proposta	9
1.2	Objetivos	10
1.2.1	<i>Objetivo geral</i>	10
1.2.2	<i>Objetivos específicos</i>	10
1.2.3	<i>Características da pesquisa</i>	10
1.3	Estrutura do documento	11
2	FUNDAMENTAÇÃO TEÓRICA	12
2.1	Mercado financeiro	12
2.2	Minicontrato Futuro do Índice Bovespa	12
2.3	Relação risco e retorno	13
2.4	Negociação algorítmica	13
2.5	Médias móveis	14
2.6	Algoritmos de otimização	16
2.7	Otimização por Enxame de Partículas (PSO)	17
3	REVISÃO BIBLIOGRÁFICA	19
3.1	Evolução da área	19
3.2	Técnicas para definição de <i>Stop-loss</i> e <i>Take-profit</i>	20
3.3	Trabalhos relacionados	21
3.3.1	<i>Diferencial da abordagem apresentada</i>	22
4	METODOLOGIA	24
4.1	Extração e tratamento de dados	24

4.2	Fase de entrada do PSO	25
4.3	Aplicação do PSO	25
4.4	Análise e comparação entre abordagens	27
5	RESULTADOS	28
5.1	Pontos de saída obtidos	28
5.2	Comparação entre abordagens	28
6	CONCLUSÃO	31
	REFERÊNCIAS	32

1 INTRODUÇÃO

As negociações nos mercados financeiros, que antes eram realizadas em salas ocupadas por operadores humanos nos chamados ‘Pregão Viva Voz’ (PVV), já não existem atualmente. Nas últimas décadas, houve uma informatização intensiva dos mercados financeiros, substituindo operadores humanos por algoritmos automatizados. Embora esses algoritmos sejam criados por pessoas, as decisões sobre quando enviar ordens de compra ou venda são tomadas pelos próprios algoritmos e executadas automaticamente por meio de uma infraestrutura tecnológica que conecta empresas comerciais individuais às várias bolsas onde negociam. Isso transformou significativamente a natureza dos mercados financeiros e o funcionamento das organizações envolvidas. Além de reformular a relação entre humanos e tecnologia na indústria financeira, essa mudança atualizou os mercados através de arranjos sociotécnicos que permitem a interação entre agentes humanos e não-humanos (MIN; BORCH, 2022).

O mercado financeiro é influenciado por diversos fatores macroeconômicos e microeconômicos, incluindo a conjuntura econômica geral, eventos políticos, expectativas dos investidores institucionais, decisões de especuladores individuais e as estratégias operacionais das empresas comerciais. No entanto, os impactos específicos desses fatores sobre o sistema financeiro, que é dinâmico por natureza, ainda não são completamente compreendidos. Isso torna a previsão de dados financeiros desafiadora, devido à incerteza externa e à complexidade intrínseca envolvida (TANG *et al.*, 2022).

O gerenciamento de risco no mercado financeiro é uma tarefa complexa, dada a sua relação direta com a estabilidade financeira e a viabilidade econômica das empresas. A realização de atividades empresariais está intrinsecamente associada a riscos, sendo que as entidades empresariais frequentemente obtêm maiores lucros ao se envolverem em atividades com níveis elevados de risco (PAKHUCHA *et al.*, 2021). No entanto, isso também aumenta a ameaça de perda da estabilidade financeira. O risco financeiro, classificado como um risco especulativo, envolve a possibilidade de resultados tanto negativos quanto positivos, e é influenciado por um conjunto complexo de relações de causa e efeito.

A situação econômica instável e a rápida introdução de novas tecnologias e instrumentos financeiros amplificam a importância dos riscos financeiros nas atividades econômicas e financeiras. Portanto, a identificação e a avaliação precisa dos riscos financeiros são essenciais para mitigar perdas potenciais e assegurar recursos financeiros adicionais, garantindo que o investidor alcance seus objetivos e supere os desafios ao longo de seu ciclo de vida (PAKHUCHA *et al.*, 2021). Dada a relevância do gerenciamento de risco, este trabalho tem como intuito a mitigação de riscos em

operações no mercado financeiro.

1.1 Justificativa e proposta

O mercado financeiro, com sua natureza altamente volátil, representa um desafio significativo para investidores que buscam maximizar retornos enquanto minimizam riscos. Em particular, o Minicontrato Futuro do Índice Bovespa (WINFUT) tem se destacado como um instrumento para investidores devido à sua capacidade de proporcionar alavancagem e oportunidades de lucro em diferentes condições de mercado. Em alguns estudos, como em Silva *et al.* (2021) e Prado *et al.* (2024), são aplicadas técnicas de previsão de séries temporais no WINFUT para auxiliar na tomada de decisão e reduzir a exposição ao risco, ilustrando a relevância do WINFUT no contexto de estratégias de investimento. No entanto, a volatilidade inerente e as rápidas oscilações de preço dificultam a gestão eficiente desses investimentos.

Duas estratégias envolvendo pontos de saída são comumente utilizadas: *stop-loss* (SL) e *take-profit* (TP), ambas relacionadas à saída do mercado por parte do investidor. O SL ocorre quando o preço do ativo atinge um nível desfavorável, enquanto o TP é acionado quando o preço atinge um nível suficientemente favorável. O uso dessas estratégias é uma prática comum para gerenciar riscos e assegurar lucros (WARBURTON; ZHANG, Z., 2006). No entanto, estudos como o de Santos *et al.* (2021), ressaltam a dificuldade de alcançar retornos satisfatórios com riscos mínimos, evidenciando a necessidade de métodos mais robustos e sistemáticos para otimizar decisões de negociação.

Nesse contexto, a aplicação de algoritmos de otimização meta-heurísticos, como o *Particle Swarm Optimization* (PSO), conhecido em português como Otimização por Enxame de Partículas (KENNEDY; EBERHART, 1995), emerge como uma solução promissora. Esses algoritmos, inspirados em fenômenos naturais e biológicos, são capazes de explorar eficientemente o espaço de busca, evitando ótimos locais e buscando soluções globais. O PSO, em particular, tem demonstrado eficácia em diversos domínios de otimização devido à sua capacidade de adaptar dinamicamente ao problema em questão (NAYAK *et al.*, 2023).

A proposta deste trabalho é desenvolver um modelo de otimização baseado no PSO para determinar pontos ideais de saída em operações de negociação com o WINFUT. O algoritmo foi projetado para lidar com números de ponto flutuante. O processo de otimização envolverá a análise do histórico de preços do WINFUT, combinado com a simulação de operações com o ativo por meio da geração de sinais de compra, que foram definidos utilizando uma estratégia baseada no cruzamento de médias móveis. A partir destes sinais foi realizado a otimização dos pontos de saída pelo algoritmo PSO, para maximizar os retornos e minimizar as perdas. Com os pon-

tos de saída definidos, foi feita uma comparação entre o potencial de retorno dessa abordagem em relação a uma estratégia já consolidada.

1.2 Objetivos

Este estudo propõe atender ao objetivo geral e aos objetivos específicos descritos a seguir.

1.2.1 Objetivo geral

Obter, por meio da implementação do algoritmo de otimização meta-heurística PSO, os pontos ótimos de saída, que neste estudo serão definidos pelo SL e TP, nas negociações do ativo WINFUT, de forma a alcançar a relação ideal entre risco e retorno para operar nesse ativo.

1.2.2 Objetivos específicos

- Obtenção do histórico de preços do minicontrato futuro do índice Bovespa.
- Realizar o cálculo das médias móveis nos preços obtidos, para definição de pontos de compra e venda.
- Implementar o algoritmo PSO para definir os valores ótimos de TP e SL, em que nele seja maximizado o lucro nas negociações a partir dos pontos de compra definidos.
- Avaliar os resultados obtidos pelo algoritmo de otimização e comparar com uma estratégia já utilizada no mercado.

1.2.3 Características da pesquisa

No que tange a metodologia científica esta pesquisa está caracterizada da seguinte forma:

- a) Quanto a finalidade: É uma pesquisa aplicada, visto que propõe o estudo e desenvolvimento de um algoritmo de otimização para resolver problemas específicos na área de negociação financeira, envolvendo a definição de pontos de saída para o minicontrato futuro do índice Bovespa;
- b) Quanto ao objetivo: É uma pesquisa exploratória, pois investiga e combina diferentes técnicas (PSO e médias móveis) para otimização de pontos de saída;

- c) Quanto a abordagem: É uma pesquisa quantitativa, visto que todas as decisões de implementação são guiadas por métricas numéricas, uma vez que envolve o uso de algoritmos e técnicas de otimização para definir pontos de TP e SL com base em dados históricos de mercado.
- d) Quanto ao método: É uma pesquisa experimental, pois testa a aplicação do PSO combinado com médias móveis em dados históricos do mercado financeiro para avaliar a eficácia da estratégia proposta. Este método envolve a realização de simulações e testes empíricos para validar os resultados.

1.3 Estrutura do documento

Este trabalho está organizado em seis capítulos que abordam o desenvolvimento e a aplicação de uma meta-heurística para otimização de pontos de saída em negociações com o Minicontrato Futuro do Índice Bovespa:

- Capítulo 1 - Introdução: Apresenta a motivação, a justificativa e os objetivos do estudo, fornecendo uma visão geral sobre a relevância da otimização de pontos de saída no contexto do mercado financeiro.
- Capítulo 2 - Fundamentação Teórica: Descreve os principais conceitos relacionados ao mercado financeiro, negociação algorítmica, e técnicas de análise técnica, além de uma revisão dos algoritmos de otimização, com ênfase no PSO.
- Capítulo 3 - Revisão Bibliográfica: Analisa o estado da arte nas técnicas para definir SL e TP em negociações, destacando abordagens semelhantes ao trabalho proposto e apresentando o diferencial da metodologia adotada.
- Capítulo 4 - Metodologia: Detalha os procedimentos adotados para coleta e tratamento dos dados, a definição das simulações de compra com médias móveis e a implementação do algoritmo PSO para otimização dos pontos de saída.
- Capítulo 5 - Resultados: Apresenta e discute os resultados obtidos com a aplicação do PSO e as comparações entre diferentes abordagens, evidenciando o desempenho da metodologia proposta.
- Capítulo 6 - Conclusão: Resume as contribuições e as principais descobertas do estudo, sugerindo direções para futuras pesquisas e aplicações práticas da abordagem desenvolvida.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é apresentada uma contextualização acerca do ambiente no qual se aplica o objeto de estudo da pesquisa. Iniciando-se pela grande área de mercado financeiro, serão apresentados conceitos fundamentais que visam munir o leitor sobre o funcionamento das negociações de ativos e o papel econômico que estas desempenham. Na sequência, com foco apenas no minicontrato futuro do índice Bovespa, é feita uma abordagem sobre os contratos futuros e sobre o Índice Bovespa. Logo em seguida estão as seções diretamente ligadas as formas de operação no mercado, onde é apresentado a relação entre risco e retorno, a negociação algorítmica, e a estratégia de negociação baseada no cruzamento de médias móveis. A seção é complementada por uma descrição dos algoritmos de otimização, conceituando e abordando os agrupamentos dos métodos de otimização. Ao final, é abordado o PSO.

2.1 Mercado financeiro

O sistema financeiro é composto por diversas instituições e instrumentos financeiros que permitem a movimentação de recursos dos fornecedores finais para os consumidores finais, além de garantir que títulos e valores mobiliários possam ser convertidos em dinheiro no mercado (CAVALCANTE; MISUMI; RUDGE, 2009).

Até o início da década de 1990, a bolsa de valores brasileira, conhecida na época como BOVESPA, utilizava principalmente o método de Pregão Viva Voz (PVV) para realizar transações entre investidores. Em 1999, foi introduzido o sistema de *Home Broker*, que são *softwares* que permitem que os investidores enviem ordens de compra e venda ao mercado por meio da corretora escolhida. A adoção do *Home Broker* possibilitou a intermediação eletrônica de operações pelas corretoras, levando à substituição do PVV pelo pregão eletrônico (PE) que era utilizado em bolsas de valores ao redor do mundo (NAMETALA, C., 2017).

Em março de 2017, a BM&FBOVESPA, que surgiu em 2008 da união entre BM&F e Bovespa Holding, também se uniu a Cetip com um propósito em comum de trabalhar para conectar, desenvolver e viabilizar o mercado financeiro e de capitais, formando assim a B3 S.A. - Brasil, Bolsa, Balcão (B3, 2020).

2.2 Minicontrato Futuro do Índice Bovespa

Os contratos futuros juntamente com as opções compõem o tipo de contrato chamado derivativo, estes são negociados ativamente em muitas bolsas de todo o mundo, a definição de derivativo envolve ser um instrumento financeiro que deriva de valores de outras variáveis subjacentes mais básicas, onde muitas vezes estas

variáveis são preços de ativos negociados. Entretanto, os derivativos podem depender tanto de fatores como preço de uma *commoditie* quanto de fatores climáticos de uma região (HULL, 2016).

O Índice Bovespa (Ibovespa) é uma carteira teórica de ativos que mede o desempenho das ações mais representativas do mercado brasileiro. Atualmente, ele é considerado um termômetro do cenário político e econômico do país. O Ibovespa é revisado a cada quatro meses, com base na liquidez das ações nos últimos doze meses, dando maior peso às empresas mais líquidas. Utilizado como referência para cálculos de risco e beta, inclui apenas ativos listados na B3. Para investidores, o Ibovespa serve como parâmetro de desempenho, sendo ideal que a carteira alcance um desempenho igual ou superior ao índice (NUNES; COMPAGNORE; SALES, 2020).

2.3 Relação risco e retorno

Risco e retorno são conceitos essenciais no mundo dos investimentos. O risco envolve à avaliação dos perigos individuais, incorporando a compreensão das interações entre diferentes ativos, expressas por meio das covariâncias e variâncias. Enquanto o retorno de um investimento é geralmente determinado de maneira mais direta. Ele representa o montante total de lucros ou prejuízos obtidos ao longo de um determinado intervalo de tempo (ASSAF NETO, 2014).

De acordo com Warburton e ZG Zhang (2006), entre as abordagens mais utilizadas no mundo dos investimentos, para lidar eficazmente com as incertezas envolvidas nas negociações de ações, futuros e outros ativos, estão as estratégias baseadas em preços para entrar ou sair do mercado. A seguir, estão duas das principais abordagens que estão entre as mais utilizadas nessas estratégias.

- *Stop-loss* (SL): Ordens de *stop-loss* são utilizadas para limitar as perdas. Quando o preço de um ativo atinge um nível desfavorável, o investido sai do mercado aceitando o prejuízo atual, de forma a evitar um resultado ainda pior.
- *Take-profit* (TP): Metas de lucro são usadas para garantir ganhos. Quando o preço se torna suficientemente favorável, o investido sai do mercado e reavalia a situação, possivelmente acreditando que o mercado está inflacionado e prestes a passar por uma correção.

2.4 Negociação algorítmica

Para dar suporte as negociações no mercado, surgiu a negociação algorítmica que é definida por Hendershott e Riordan (2012), como a automação do processo de tomada de decisões de negociação, que inclui a submissão de ordens ao mercado

e o gerenciamento das respostas a essas ordens, tudo isso realizado por meio de algoritmos computacionais. Outra definição é dada por Portnoy (2011), que diz que a negociação algorítmica envolve examinar estatisticamente o histórico de um ativo específico, considerando também as condições atuais do mercado. Seu objetivo é prever a direção dos movimentos nos preços e identificar oportunidades de lucro através de operações baseadas nessas previsões.

Uma decisão de investimento de mercado pode ser complexa devido a incerteza da tarefa e à sua alta dinâmica, ou seja, uma estratégia que estava correta no momento t não é correta no momento $t + 1$. Assim, para tais tarefas, dois estágios são necessários para o desenvolvimento dos algoritmos: imitar o processo de decisão humana em um alto nível, e imitar o funcionamento do cérebro humano para reproduzir essa boa decisão (WILINSKI; KOVALERCHUK, 2017).

2.5 Médias móveis

As médias móveis formam uma das construções estatísticas que são utilizadas na negociação nos mercados financeiros de todos os tipos, ações mais do que outros, em uma variedade de diferentes interpretações de estratégias (ou regras) de negociação. Sendo um elemento básico de negociação na análise técnica, suas propriedades e eficácia foram consideradas em muitos estudos acadêmicos anteriores (PAPAILIAS; THOMAKOS, 2015).

A equação (2.1) representa como a *Simple Moving Average* (SMA) conhecida em português como média móvel simples do preço, é calculada. Esta média é móvel porque, no final de cada período de negociação, é adicionado o período mais recente e descartado o período mais antigo da média anterior.

$$SMA_n = \frac{1}{n} \sum_{i=0}^{n-1} P_{t-i} \quad (2.1)$$

em que:

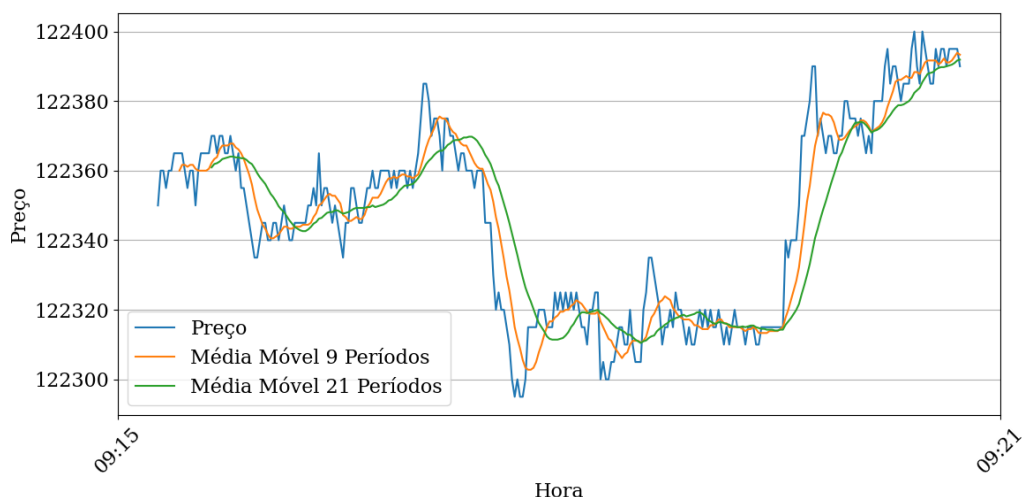
- SMA_n é a Média Móvel Simples no período n ,
- n é o número de períodos,
- P_{t-i} é o preço de fechamento no segundo $t - i$.

De acordo com El-Khodary (2009), um dos indicadores de estratégia de investimento relacionado a análise técnica que gera um maior retorno baseado no movimento do histórico de preços é o cruzamento de médias móveis. O principal conceito por trás da média móvel é calcular a média de um número n de pontos/preços de dados anteriores. Esta média calculada representa a área de preço mais próxima de um número proporcionalmente grande de negociações naquele período especificado. O cruzamento de médias móveis é dado quando o valor de uma média de curto prazo

encontra com uma de longo prazo.

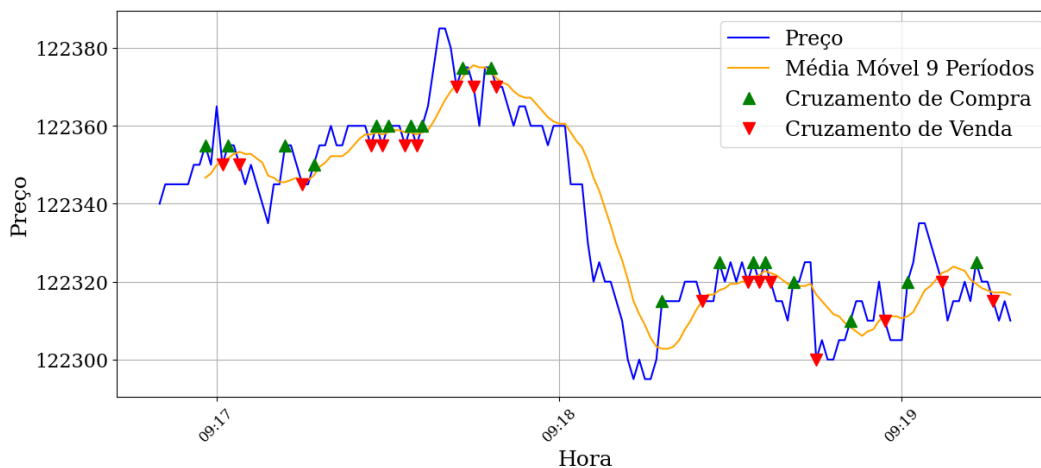
A figura 1 mostra o gráfico de preços de fechamento para o ativo WINQ24 (Mini índice Bovespa no ano de 2024) em um período de 300 segundos, com o cálculo de duas SMA's. Uma rápida (em amarelo) de 9 segundos e outra lenta (verde) de 21 segundos.

Figura 1 – Cruzamento de médias móveis



Fonte: Elaborado pelo Autor, 2024.

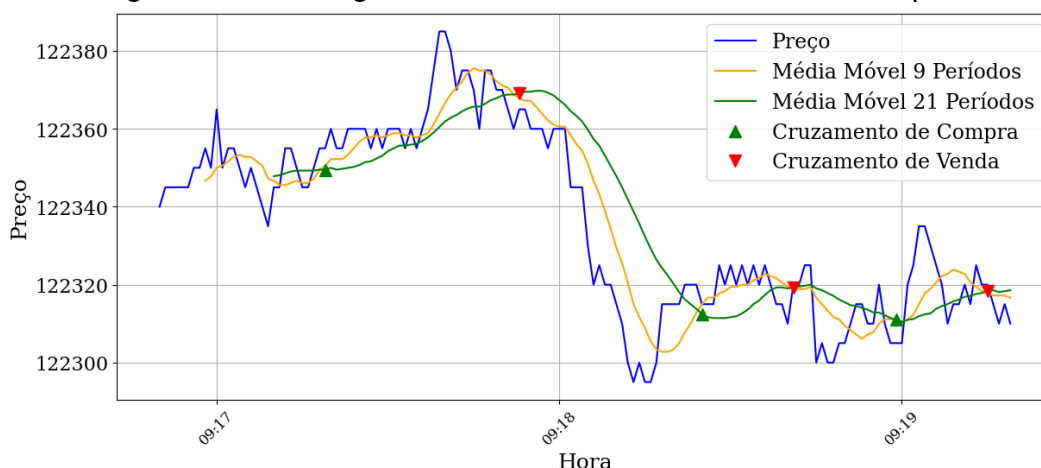
Figura 2 – Estratégia preço x média móvel



Fonte: Elaborado pelo Autor, 2024.

Duas das estratégias para negociação que fazem uso de médias móveis baseiam-se no cruzamento de preços e no cruzamento de médias móveis. A primeira estratégia, representada na figura 2, emite um sinal para realizar a compra de um ativo quando o preço do ativo ultrapassa a SMA, enquanto a segunda estratégia, representada na figura 3, emite o sinal de compra quando uma SMA mais rápida cruza acima de uma SMA mais lenta. Os sinais para realização da venda do ativo comprado são

Figura 3 – Estratégia média móvel lenta x média móvel rápida



Fonte: Elaborado pelo Autor, 2024.

definidos na direção oposta, ou seja, quando a SMA mais lenta cruza acima de uma média móvel mais rápida (PAPAILIAS; THOMAKOS, 2015).

2.6 Algoritmos de otimização

A otimização pode ser definida como um conjunto de técnicas e algoritmos utilizados para encontrar a melhor solução possível dentro de um conjunto de alternativas viáveis, de forma iterativa. Esses métodos são amplamente empregados em problemas complexos, como aqueles de natureza combinatória, onde o objetivo é maximizar ou minimizar uma função de acordo com os critérios do problema (PERES; CASTELLI, 2021).

Os primeiros métodos utilizados para resolver problemas de otimização eram métodos matemáticos ou numéricos nos quais a solução final é determinada alcançando um ponto onde a derivada da função é zero. Contudo, resolver problemas não lineares e não convexos, que envolvem muitas variáveis e restrições, utilizando esses métodos se torna praticamente impossível, especialmente à medida que o número de dimensões aumenta, resultando em um espaço de busca que cresce exponencialmente. Além disso, os métodos numéricos podem ficar presos em pontos de ótimos locais nos quais a derivada também é zero. Isso implica que não há garantia de encontrar a solução ótima global ao empregar tais métodos numéricos (ZERVOUDAKIS; TSAFARAKIS, 2020).

Segundo Mirjalili e Lewis (2016) os algoritmos de otimização por meta-heurística estão se popularizando em aplicações de engenharia pela capacidade de evitar ótimos locais e ampla aplicabilidade. Os algoritmos de meta-heurística inspirados na natureza resolvem problemas de otimização imitando fenômenos biológicos ou físicos. Eles podem ser agrupados em três categorias principais:

- Métodos baseados na evolução: Inspirados na evolução natural, começam com uma população aleatória que evolui ao longo das gerações, combinando os melhores indivíduos para otimização. Exemplos incluem Algoritmos Genéticos (GA) e Estratégia de Evolução (ES).
- Métodos baseados na física: Imitam regras físicas do universo. Exemplos incluem Recozimento Simulado (SA) e Algoritmo de Busca Gravitacional (GSA).
- Métodos baseados em enxames: Imitam o comportamento social de animais. Exemplos incluem Otimização por Enxame de Partículas (PSO) e Otimização por Colônia de Formigas (ACO).

2.7 Otimização por Enxame de Partículas (PSO)

Diversas aplicações de engenharia fazem uso de algoritmos de otimização para abordar problemas de forma eficiente e eficaz, resolvendo desafios específicos. Entre os problemas de otimização do mundo real, grande parte é solucionada por meio de algoritmos meta-heurísticos. Um desses algoritmos é o PSO, introduzido por Kennedy e Eberhart (1995). A ideia e a formulação do algoritmo PSO foram inspiradas pela observação do comportamento social de bandos de pássaros e cardumes de peixes, em que os integrantes do grupo seguem um líder que está mais próximo da comida. Esse comportamento social pode ser traduzido em operações algorítmicas, como no PSO, para resolver problemas de otimização, onde o bando de pássaros é representado como um enxame de partículas, e cada partícula corresponde a uma solução candidata. Durante a fase de exploração, as partículas percorrem o espaço de busca extensivamente, enquanto a fase de exploração foca em regiões promissoras (SHAMI *et al.*, 2022).

O PSO é uma técnica de otimização que modela o conjunto de possíveis soluções de problemas como um conjunto de partículas se movimentando em um espaço virtual. O método original do PSO consiste em um espaço virtual onde se instancia várias partículas formando um enxame e cada uma começa com uma posição $(x_{i,j})$ e uma velocidade $(v_{i,j})$ aleatórias no espaço de busca n -dimensional, onde i representa o índice da partícula e j representa a dimensão no espaço de busca. As partículas otimizam as soluções candidatas ao se movimentar através do espaço virtual, atraindo-se para posições que resultaram nos melhores desempenhos (PUGH; MARTINOLI; ZHANG, Y., 2005).

As partículas são organizadas em vizinhanças, que facilitam a comunicação entre as partículas enquanto buscam os pontos ótimos. Existem diversas topologias de enxame, ou sociometrias, como estrela, anel, pirâmide e Von Neumann, e estas influenciam o desempenho do PSO. A equação de atualização da velocidade é

composta por três componentes: o termo de *momentum*, o termo cognitivo e o termo social. O termo de *momentum* direciona o movimento da partícula para continuar na direção do movimento anterior, facilitando trajetórias mais suaves. O termo cognitivo orienta o movimento da partícula em direção a áreas do espaço de busca que a partícula já encontrou como promissoras para um ótimo. Por fim, o componente social direciona o movimento da partícula para áreas do espaço de busca identificadas por qualquer partícula na vizinhança relevante como promissoras para um ótimo. A melhor posição social de cada vizinhança é definida como a melhor posição pessoal da partícula que encontrou o melhor resultado dentro daquela vizinhança (ZYL; ENGELBRECHT, A. P., 2023).

Muitos pesquisadores como Erwin e Andries Engelbrecht (2023) e Correa, Freitas e Johnson (2006), realizaram modificações no algoritmo original, resultando em um grande número de variantes do PSO com desempenho aprimorado. As principais estratégias de modificação incluem a alteração dos parâmetros de controle do PSO, hibridização do PSO com outros algoritmos meta-heurísticos, e técnicas de cooperação e multi-enxame. Algumas dessas variantes incluem o PSO binário, que adapta o PSO para espaços de busca discretos, e topologias de vizinhança no PSO, que influenciam como as partículas interagem e compartilham informações (SHAMI *et al.*, 2022).

3 REVISÃO BIBLIOGRÁFICA

Este capítulo faz uma revisão bibliográfica que tem por objetivo apresentar o estado da arte. Inicialmente é feita uma introdução às principais técnicas utilizadas para definir pontos de saída de operações em negociações no mercado financeiro. Concluindo a revisão, será abordado sobre definição de pontos de saída, e os trabalhos que fazem a definição desses pontos utilizando uma abordagem semelhante a utilizada nesse trabalho.

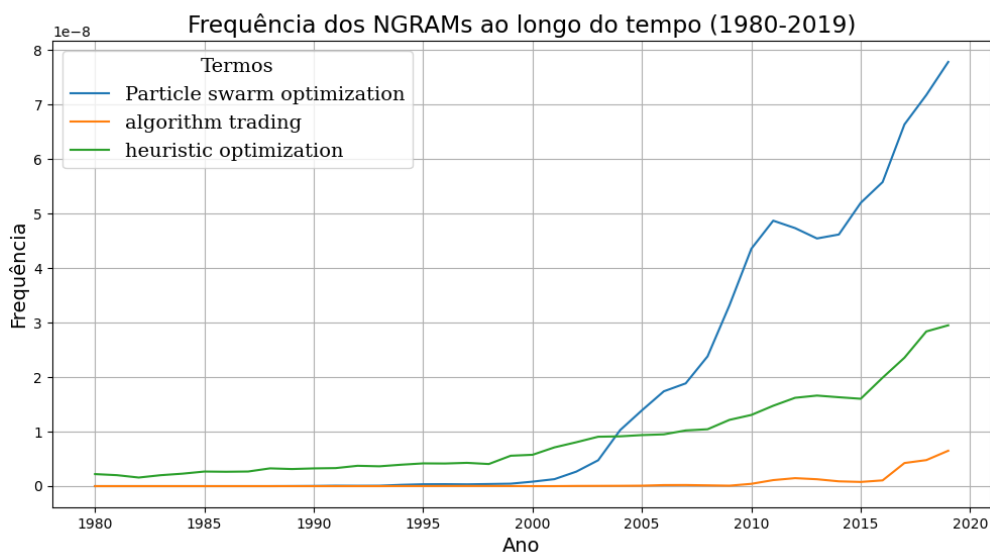
3.1 Evolução da área

Para verificar o crescimento da relevância de alguns dos temas relacionados ao trabalho proposto, foi utilizado a ferramenta *Google Books Ngram Viewer*, permitindo a visualização da frequência de palavras ou frases específicas em um vasto *corpus* de livros digitalizados pelo Google. Os seguintes parâmetros foram utilizados na ferramenta:

- Palavras-chave: *Particle swarm optimization*, *algorithm trading* e *heuristic optimization*
- Período: 1980 à 2019

A figura 4 ilustra o crescimento da relevância de três áreas relacionadas ao tema deste trabalho. Observa-se que o interesse pelo PSO começou a crescer significativamente por volta dos anos 2000, período próximo à sua criação. Esse aumento de relevância também coincide com a ascensão do tema *heuristic optimization*, indicando que o uso do PSO contribuiu para fortalecer a importância dessa abordagem de otimização. Por fim, destaca-se o crescimento recente do tema *algorithm trading*, que ganhou maior visibilidade nos últimos anos.

Figura 4 – Gráfico Ngram



Fonte: GOOGLE BOOKS, 2024.

3.2 Técnicas para definição de *Stop-loss* e *Take-profit*

A gestão baseada em objetivos de perdas e ganhos, é utilizada no mercado financeiro para um melhor gerenciamento de riscos. Nesse sentido é possível que uma operação de compra ou venda seja encerrada ao fechar posição ao atingir um ponto de TP ou um ponto de SL. Segundo CAL Nametala (2017) a utilização de pontos de *stop* individualizados e otimizados para cada série de cada ativo é importante pois as variações dos preços são muito específicas à cada ação. Isso é particularmente nítido quando se observa a distribuição dos retornos de cada ativo, dessa forma ao realizar um estudo sobre otimização de pontos de saída, chegou na proporção de 3:1, onde para TP se tem o valor de 45% de valorização do ativo e para SL contabilizou-se 15% na desvalorização.

Essa proporção de 3:1 também é respaldada por outros estudos na literatura. Em estudos como Ciniro A. L. Nametala *et al.* (2023) e Noertjahyana *et al.* (2020), os autores corroboram a eficácia dessa relação, aplicando-a no contextos de mercado. Esses estudos reforçam a ideia de que uma gestão de riscos bem estruturada, utilizando a relação de 3:1 para definir pontos de SL e TP, pode ser uma abordagem eficaz para maximizar lucros e minimizar perdas em operações financeiras.

3.3 Trabalhos relacionados

Alguns dos métodos utilizados envolvem a utilização de técnicas de *machine learning* para a definição de pontos de saída de operações, e estes métodos estão sendo explorados no mercado financeiro. Segundo Mazen (2023), os algoritmos de aprendizado supervisionado, como o *K-Nearest Neighbour* (KNN), Suporte Vetorial (SVM), Floresta Aleatória, Redes Neurais e Árvores de Decisão, podem prever tendências do mercado de ouro com alta precisão. Esses algoritmos foram aplicados para prever pontos de SL e TP, obtendo-se uma acurácia de até 99% com redes neurais. Esse modelo adaptativo permite ajustar automaticamente os pontos de saída com base na direção do mercado, oferecendo uma estratégia de negociação mais dinâmica e eficaz.

Outra abordagem também utilizada, é demonstrada em Vezeris, Kyrgos e Schinas (2018) que, determina que com indicadores técnicos como o *Average True Range* (ATR), é possível estabelecer sinais de SL e TP baseados em tendências de mercado, proporcionando uma abordagem adaptativa que ajusta a quantidade da menor unidade de variação do preço de uma moeda e suas posições conforme a evolução do mercado.

Além dos métodos mencionados, Chen *et al.* (2018) propõem uma abordagem baseada em algoritmos genéticos para a otimização de um portfólio de estratégias de negociação em grupo (GTSP) e seus pontos de SL e TP. Esta abordagem, denominada GTSP-SLTP, utiliza um algoritmo genético de agrupamento (GGA) para codificar e otimizar os pontos de SL e TP em cromossomos. Cada cromossomo representa uma combinação de estratégias de negociação, agrupamentos e pesos de capital, onde os pontos de SL e TP são ajustados para maximizar os lucros e minimizar os riscos. Os resultados experimentais mostram que esta técnica pode efetivamente encontrar um portfólio otimizado e seus pontos de saída, oferecendo uma ferramenta robusta para a gestão de risco e retorno em mercados financeiros voláteis.

Em Sivri *et al.* (2023), é discutido sobre um sistema inteligente para a determinação dinâmica dos limites de SL e TP utilizando dados históricos de preços de ações da IBM e análise de desvio padrão. O objetivo principal é minimizar perdas e maximizar lucros para traders e investidores. O estudo emprega técnicas de inteligência artificial, como algoritmos de aprendizado de máquina, para analisar os dados históricos do mercado de ações e determinar separadamente os níveis de TP/SL para posições de compra e venda. A eficácia da abordagem é avaliada comparando os retornos diários com os retornos dos níveis TP/SL utilizando a métrica *Sharpe Ratio*. Os resultados sugerem que a abordagem proposta pode melhorar a precisão das estratégias de negociação automatizada, indicando que os níveis de TP/SL determinados dinamicamente podem ser mais eficazes do que os retornos de fechamento do dia.

A utilização de modelos LSTM (*Long Short-Term Memory*) para a definição de pontos de TP e SL tem se mostrado uma abordagem promissora no contexto de negociações financeiras. Wu *et al.* (2020) aplica a arquitetura LSTM para prever a probabilidade de lucro das estratégias de futuros e, em seguida, converter esses pontos de TP e SL para operações de opções. O objetivo é melhorar a precisão e a lucratividade das estratégias de negociação, abordando as limitações das estratégias tradicionais de futuros, como a dificuldade em determinar o tamanho ideal das posições devido à necessidade de margem e à volatilidade do mercado. O estudo utiliza uma rede neural LSTM para prever a probabilidade de lucro das estratégias de futuros e, em seguida, converte os pontos diários de TP e SL para operações de opções com base no valor delta das opções. A nova estratégia de opções resultante é aplicada ao critério de Kelly para calcular a fração ideal de negociação, permitindo um controle mais preciso do tamanho das posições. Os resultados demonstram que a negociação de opções pode alcançar uma fração mais próxima da ideal, conforme calculado pelo critério de Kelly, em comparação com a negociação de futuros, aumentando assim a lucratividade total da estratégia.

3.3.1 Diferencial da abordagem apresentada

Em comparação com os trabalhos relacionados destacados na tabela (1), o diferencial deste reside na aplicação do algoritmo PSO para a definição de pontos fixos de SL e TP no mercado financeiro. Enquanto Mazen (2023) e Wu *et al.* (2020) focam em técnicas de aprendizado de máquina e redes neurais para previsão de tendências e ajustes de posições, e Chen *et al.* (2018) utilizam algoritmos genéticos para otimização de portfólios, a abordagem desse trabalho visa integrar a otimização por enxame de partículas para definir os pontos de saída com base no cruzamento de médias móveis no histórico de negociação do WINFUT. Desta forma este trabalho oferecerá uma alternativa frente às metodologias já exploradas.

Referência	Técnica Utilizada	Objetivo	Resultados
Mazen (2023)	Algoritmos de aprendizado supervisionado (KNN, SVM, Floresta Aleatória, Redes Neurais, Árvores de Decisão)	Plano de negociação adaptativo no mercado de ouro	Obteve-se um modelo adaptativo que permite ajustar automaticamente os pontos de saída com base na direção do mercado
Vezeris, Kyrgos e Schinas (2018)	Indicadores técnicos (ATR)	Estabelecimento de sinais de SL e TP baseados em tendências de mercado	Determina que com o ATR, é possível estabelecer sinais de stop-loss e take-profit baseados em tendências de mercado
Chen et al. (2018)	Algoritmo de agrupamento genético (GGA)	Otimizar um portfólio de estratégias de negociação em grupo (GTSP) utilizando pontos de <i>stop-loss</i> e <i>take-profit</i>	Demonstração que a abordagem proposta supera a anterior que não considerava os pontos de <i>take-profit</i> e <i>stop-loss</i>
Sivri et al. (2023)	<i>Random Forest, Extreme Gradient Boosting</i> e <i>Light Gradient Boosting</i>	Determinação dinâmica dos limites de <i>stop-loss</i> e <i>take-profit</i>	Melhoria da métrica SP em relação ao método que calcula a diferença entre o preço de abertura e fechamento
Wu et al. (2020)	Modelos LSTM	Definição de pontos de <i>take-profit</i> e <i>stop-loss</i> em negociações de futuros e conversão para para operações de opções	Através do critério de Kelly a estratégia abordada se mostrou viável devido ao aumento da lucratividade total
Este trabalho	<i>Particle Swarm Optimization</i> (PSO) e simulação de compras de ação utilizando cruzamento de médias móveis	Otimizar os pontos de saída nas negociações do minicontrato futuro do índice Bovespa	Obteve-se pontos de saída que performaram melhor que os definidos pela estratégia convencional

Tabela 1 – Comparação das técnicas e resultados de trabalhos relacionados.

4 METODOLOGIA

Na primeira seção é apresentado o método de extração do histórico de negociações do ativo, o qual retorna informações sobre o preço do ativo a cada segundo, seguido dos procedimentos para tratar os dados obtidos, incluindo a interpolação de segundos faltantes. Em seguida, é descrita a fase de entrada do algoritmo PSO, detalhando a abordagem baseada em médias móveis utilizada para simular os pontos de compra. Também é explicado como o PSO foi aplicado para determinar os pontos de saída no histórico de negociações, com a descrição da implementação e dos parâmetros configurados. Por fim, aborda-se a metodologia para análise e comparação dos resultados obtidos. Todas as etapas de tratamento, padronização dos dados, geração de pontos de compra e aplicação do PSO foram realizadas utilizando a linguagem de programação Python no ambiente do Google Colab.

4.1 Extração e tratamento de dados

Para a realização deste trabalho, o histórico de negociação foi extraído da plataforma *home broker Metatrader5*. Utilizou-se um *script* desenvolvido na linguagem de programação MetaQuotes Language (MQL), que gerou um arquivo no formato .csv contendo o valor do índice Bovespa a cada segundo, do dia 15-03-2024, dia o qual foi utilizado para a aplicação do PSO e definição dos pontos de saída, e dos dias 18-03-2024 à 21-03-2024 para comparar a diferença no possível retorno utilizando a estratégia com o PSO e a estratégia que utiliza a relação 3:1.

Durante o tratamento dos dados, foi realizada uma padronização do *dataset* para garantir a consistência. Foi extraído um total de 151472 dados. O horário de início foi definido como 09:06:00 e o de término como 17:31:00. Além disso, foi identificada a presença de 1716 duplicatas no *dataset*, ou seja, registros repetidos, os quais foram removidos para evitar distorções nos resultados, fazendo que o número de registros fosse reduzido para 149756.

Outra etapa do tratamento de dados foi a verificação de lacunas temporais, ou seja, segundos faltantes na extração do histórico, pois durante a extração em tempo real do histórico pode ocorrer inconsistências que gerem essas lacunas. Contabilizando todos os segundos de 09:06:00 à 17:31:00 em 5 dias de extração, seria obtido 151505 dados, dessa forma, nota-se que houveram aproximadamente 1.15% de dados faltantes. Para resolver essa questão, foi aplicado a interpolação dos dados utilizando o método linear, preenchendo assim as lacunas e garantindo a continuidade do *dataset*.

A interpolação linear é caracterizada por atribuir o valor ao dado faltante realizando a média entre o dado seguinte e o dado anterior, onde na aplicação em

questão, a interpolação é feita atribuindo o valor ao segundo faltante x através da realização da média entre os valores nos dois segundos mais próximos, o valor segundo anterior $x - 1$ e o valor do segundo seguinte $x + 1$.

4.2 Fase de entrada do PSO

Com os dados já tratados foi possível realizar as simulações de compra utilizando as médias móveis. A partir das simulações de compra dos dados extraídos no dia 15-03-2024, foi aplicado o PSO de forma a definir o TP e SL que possibilitariam um maior retorno na data em questão. A estratégia utilizada para a simulação de compra foi uma variação da técnica abordada em Papailias e Thomakos (2015), que descreve uma estratégia através da emissão de um sinal de compra quando uma média móvel mais rápida cruza acima de uma média móvel mais lenta e a emissão de sinais de venda quando ocorrer o oposto, a estratégia utilizada neste trabalho considera apenas a emissão do sinal de compra, desconsiderando o sinal de venda.

Para a aplicação do PSO, primeiramente é definido uma função, que percorre os dados tratados anteriormente, contendo os preços, e gera duas médias móveis de diferentes períodos, uma de 9 e outra de 21. Logo em seguida os dados são percorridos novamente, porém comparando as duas médias móveis geradas para cada segundo. Quando a média móvel de curto prazo (mm9) cruza acima da média móvel de longo prazo (mm21), é registrado o sinal de compra para o segundo correspondente, indicando o cruzamento. Por fim, os dados são exportados para um arquivo .csv, contendo os preços e os sinais de compra, facilitando a análise subsequente.

4.3 Aplicação do PSO

Para realizar a aplicação do PSO, primeiramente foi preciso implementar uma função capaz de calcular o retorno das operações de compra utilizando o TP e SL como parâmetros na função. A função deve ser capaz de simular uma compra ao encontrar o sinal de compra no ponto c e simular uma venda ao atingir o TP ou o SL no ponto v , e dessa forma calcular qual foi o retorno obtido nessa compra através da subtração entre o valor do ativo no ponto v e o valor do ativo no ponto c . Ao percorrer todo o histórico de negociações a função retornará o somatório de todos os retornos de cada ponto de compra.

A abordagem de SL e TP deste trabalho utiliza a variação do preço de compra em pontos, onde a variação de cada ponto indica uma variação de 5 reais no preço do ativo.

O próximo passo será implementar a função objetivo que irá utilizar a função de cálculo de retorno das operações. A função objetivo calcula o retorno para os

pontos de SL e TP definidos por cada possível partícula do PSO.

A função objetivo, que busca maximizar o lucro das operações de compra e venda com base nos parâmetros *Take-Profit* (TP) e *Stop-Loss* (SL), pode ser expressa como:

$$f(x) = \sum_{i=1}^n (\text{retorno}_i), \quad (4.1)$$

onde $x = (TP, SL)$ representa os valores de TP e SL otimizados para cada partícula do PSO, e o retorno de cada operação i da abordagem utilizada, é dado por:

$$\text{retorno}_i = \begin{cases} p_v - p_c, & \text{se } p_v \geq p_c + (5 \cdot TP) \text{ ou } p_v \leq p_c + (5 \cdot SL), \\ 0, & \text{caso contrário.} \end{cases} \quad (4.2)$$

Onde:

- p_c é o preço de compra no ponto de sinal c ,
- p_v é o preço de venda no ponto v ,
- n é o número total de operações realizadas.

Com essas funções já implementadas, foi possível realizar a aplicação do PSO para o problema em questão. Na implementação realizada, foi utilizado o *GlobalBestPSO* da biblioteca *pyswarms* (MIRANDA, 2018). Esta função define os parâmetros ótimos da função objetivo de maneira a minimizar o valor retornado. Como o objetivo em questão foi definir os pontos de saída para aumentar o retorno, então foi necessário fazer uma alteração na função objetivo de forma que o retorno seja multiplicado por -1. Desta forma, a função PSO utilizada irá definir os pontos de saída que maximizem o retorno.

Para aplicar a função *GlobalBestPSO* é necessário definir os parâmetros coeficiente de aceleração cognitiva $c1$, coeficiente de aceleração social $c2$, fator de inércia w , limites inferiores, limites superiores, número de partículas, número de dimensões e números de iterações. Estes parâmetros afetam a maneira com que os valores ótimos são encontrados na função objetivo. Enquanto os limites influenciam nos valores máximos e mínimos que as partículas podem retornar, os valores $c1$, $c2$ e w , influenciam na dinâmica de movimentação das partículas, determinando o equilíbrio entre a exploração do espaço de busca e a exploração local em torno das melhores soluções encontradas. A dimensão altera a quantidade de valores que cada partícula retorna. Os seguinte parâmetros foram utilizados na aplicação do PSO:

- $c1$: 0.5
- $c2$: 0.3
- w : 0.9

- Número de dimensões: 2
- Limites inferiores: [1, 1]
- Limites superiores: [25, 25]
- Número de partículas: 30
- Número de iterações: 100

O número de partículas (30) e o número de iterações (100) foi escolhido levando em consideração o tempo de execução e a eficiência da busca. Já os parâmetros c_1 , c_2 e w foram definidos com base em outras implementações do PSO. Os limites estabelecidos foram definidos considerando uma variação mínima de 5 reais e uma variação máxima próxima de 125 reais. Esses limites foram definidos de forma a simular um ambiente que busca obter ao menos um lucro mínimo, sem arriscar tanto a ponto de perder uma quantia significativa em uma única negociação.

4.4 Análise e comparação entre abordagens

Após a aplicação do PSO, os pontos de saída foram definidos, a partir desses, será feita uma análise do retorno que teria sido obtido nos 4 dias de operação seguintes ao dia em que o PSO foi aplicado. Nessa análise, será considerado as abordagens apresentadas a seguir:

A abordagem do trabalho consiste em definir os pontos de saída com base em variações no preço de compra por meio da aplicação do algoritmo PSO, em que cada ponto corresponde a uma variação de 5 reais, que é a variação mínima do preço de um ativo na B3. Em contrapartida, a abordagem comumente utilizada considera a proporção de 3:1, respaldada por estudos presentes na literatura. Nessa abordagem, os valores de TP e SL foram definidos de forma próxima aos valores obtidos pelo PSO, mas ajustados para respeitar a relação de 3:1.

Após a apresentação dos retornos, será mostrado em gráfico, as operações que teriam sido realizadas por cada abordagem nos 4 dias de operações seguintes ao dia em que foi aplicado o PSO, utilizando os mesmos pontos de saída.

5 RESULTADOS

Este capítulo está dividido em duas seções. Na primeira seção é apresentado sobre os pontos de saída obtidos com a aplicação do PSO no histórico de negociações do dia 15-03-2024. Na segunda seção está o comparativo entre as operações que seriam efetuadas em cada abordagem no período dos dias 18, 19, 20 e 21 de março de 2024.

5.1 Pontos de saída obtidos

Com a aplicação da técnica de compra baseada em cruzamento de médias móveis, foram obtidos 55 sinais de compra. Com a aplicação do PSO foi possível obter pontos de saída das operações de compra que maximizassem o lucro a ser obtido. A seguir é apresentado os pontos de saída obtidos com aplicação do PSO e os que foram utilizados na abordagem que considera a relação 3:1.

- Abordagem PSO:
 - Unidade: Variação em pontos em relação ao preço de compra
 - *Take Profit* (TP): 2.0882
 - *Stop Loss* (SL): 13.0824
- Abordagem 3:1:
 - Unidade: Variação em pontos em relação ao preço de compra
 - *Take Profit* (TP): 6
 - *Stop Loss* (SL): 2

5.2 Comparação entre abordagens

Após realizar a simulação de compra utilizando a técnica de cruzamento de médias móveis, juntamente com os pontos de saída definidos em cada abordagem, obteve-se a variação do retorno. O retorno por dia é demonstrado na tabela (2) e o retorno acumulativo por dia é demonstrado na tabela (3).

Como visto nas tabelas, a abordagem que faz uso do PSO resultou em um retorno total positivo, o que indica uma boa performance nos resultados obtidos. Em contraste, a abordagem que adota uma relação de 3:1 entre TP e SL, revelou um desempenho significativamente inferior, resultando em 3 dias com retornos negativos e apenas um dia com retorno positivo, finalizando com um retorno negativo de R\$3981,66 reais. Esse resultado destaca uma discrepância importante em relação a abordagem que utiliza os pontos definidos pelo PSO e sugere que a configuração da

Tabela 2 – Retorno por dia

Data	Abordagem PSO (R\$)	Abordagem 3:1 (R\$)
18-03-2024	4785,83	-781,66
19-03-2024	2215,00	-725,00
20-03-2024	3240,00	345,00
21-03-2024	-457,50	-2820,00

Fonte: Elaborado pelo Autor, 2024.

Tabela 3 – Retorno acumulativo por dia


Data	Abordagem PSO (R\$)	Abordagem 3:1 (R\$)
18-03-2024	4785,83	-781,66
19-03-2024	7000,83	-1506,66
20-03-2024	10240,83	-1161,66
21-03-2024	9783,33	-3981,66

Fonte: Elaborado pelo Autor, 2024.

relação de 3:1 impacta negativamente os resultados quando a estratégia adotada para compra é a de médias móveis.

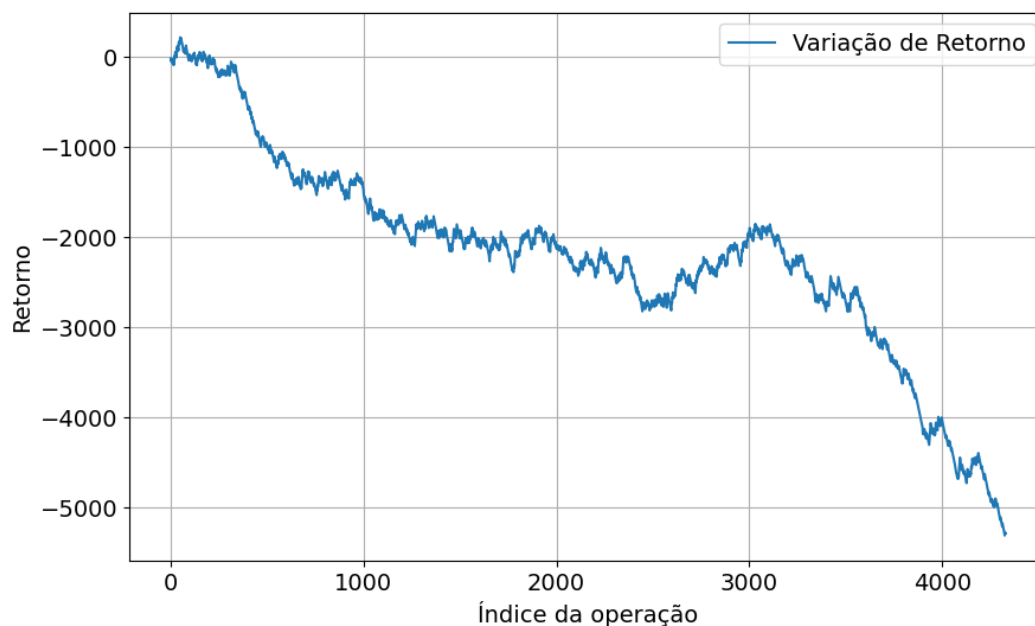
Nos gráficos a seguir, é apresentado o retorno acumulativo por operação, eles ilustram que variação dos retornos apresentam um padrão semelhante para as abordagens que fazem uso dos pontos de saída definidos pelo PSO, sugerindo que ambas têm um comportamento análogo em termos de desempenho.

Figura 5 – Variação do retorno - Abordagem PSO



Fonte: Elaborado pelo Autor, 2024.

Figura 6 – Variação do retorno - Abordagem 3:1



Fonte: Elaborado pelo Autor, 2024.

Ao calcular a diferença total entre as abordagens, observa-se que o retorno acumulativo final da abordagem PSO foi de R\$9783,33, enquanto a abordagem 3:1 apresentou um saldo final de -R\$3981,66, resultando em uma diferença total de R\$13.764,99 a favor da abordagem PSO. Esse resultado demonstra de forma clara e objetiva que a aplicação do PSO para definição dos pontos de saída proporciona um desempenho substancialmente superior. A abordagem PSO não apenas evitou os prejuízos observados na abordagem 3:1, mas também maximizou consistentemente os lucros, consolidando-se como a melhor escolha no contexto analisado.

6 CONCLUSÃO

Durante este trabalho foi feita a aplicação do PSO para definição dos pontos de TP e SL em negociações envolvendo o minicontrato futuro do índice Bovespa. Para realizar tal trabalho, foi extraído um *dataset* contendo o histórico de negociações, nos dias 15, 18, 19, 20 e 21 de março de 2024. Após a extração, etapas como tratamento e padronização de dados foram realizadas, de forma a contribuir para a consistência e a continuidade dos dados.

Com os dados já tratados, foi feita uma simulação de compra no *dataset*, considerando a estratégia de cruzamento de médias móveis. Com isso, foi estipulada uma função objetivo que calcula o lucro a ser obtido na simulação de compra baseado nos pontos de saída. Tendo essa função objetivo implementada, foi aplicado o algoritmo de otimização meta-heurístico PSO à simulação de compra no dia 15 utilizando a função objetivo, de forma a definir os pontos ótimos de TP e SL para maximizar o lucro. A partir dessa aplicação foram feitas análises e comparações entre duas abordagens de pontos de saída.

Através das análises ficou demonstrado que o método proposto neste trabalho mostrou ser eficaz na identificação de pontos estratégicos de TP e SL, pois a abordagem que faz uso do PSO mostrou ser robusta e consistente, de forma a demonstrar obtenção de lucro em 3 dias de negociação. Em contrapartida a abordagem que considera a relação 3:1 observada em trabalhos acadêmicos e em plataformas de negociação, apresentou resultados inferiores nos dias analisados. Esses resultados indicam que a escolha adequada dos parâmetros de TP e SL é crucial para a maximização dos lucros em operações de mercado e que o método aplicado para a definição desses pontos é válido e eficaz.

Com base nos resultados obtidos e nas análises realizadas, um próximo passo pode ser considerado para aprimorar a avaliação da estratégia de negociação e validar as conclusões. Este passo se baseia em utilizar uma plataforma de negociação para realizar operações fictícias com o WINFUT, fazendo uso da estratégia de cruzamento de médias móveis para compra do ativo, e o uso dos pontos de saída definidos com a aplicação do PSO.

REFERÊNCIAS

- ASSAF NETO, A. **Mercado Financeiro**. São Paulo, Brasil: Atlas, 2014.
- B3 S.A. - BRASIL BOLSA, B. **Histórico**. 2020. Disponível em: <https://ri.b3.com.br/pt-br/b3/historico/>. Acesso em: 18/03/2024.
- CAVALCANTE, F.; MISUMI, J. Y.; RUDGE, L. F. **Mercado de Capitais, o que é e como funciona. 7ª edição**. Rio de Janeiro: Editora Campus/Elsevier, 2009.
- CHEN, C.-H. *et al.* A Sophisticated Optimization Algorithm for Obtaining a Group Trading Strategy Portfolio and Its Stop-Loss and Take-Profit Points. In: 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC). 2018. p. 3417–3420. DOI: 10.1109/SMC.2018.00579.
- CORREA, E. S.; FREITAS, A. A.; JOHNSON, C. G. A new discrete particle swarm algorithm applied to attribute selection in a bioinformatics data set. In: KEIJZER, M. (Ed.). **GECCO 2006: GENETIC AND EVOLUTIONARY COMPUTATION CONFERENCE, VOL 1 AND 2**. 2006. ACM SIGEVO, p. 35+. 8th Annual Genetic and Evolutionary Computation Conference, Seattle, WA, JUL 08-12, 2006. ISBN 978-1-59593-186-3.
- ERWIN, K.; ENGELBRECHT, A. Multi-Guide Set-Based Particle Swarm Optimization for Multi-Objective Portfolio Optimization. **ALGORITHMS**, v. 16, n. 2, 2023. DOI: 10.3390/a16020062.
- GOOGLE BOOKS. **Google Books Ngram Viewer**. Acesso em: 22 jul. 2024. 2024. Disponível em: <https://books.google.com/ngrams>.
- HENDERSHOTT, T.; RIORDAN, R. Algorithmic trading and information. **Journal of Financial and Quantitative Analysis (JFQA)**, 2012.
- HULL, J. C. **Opções, futuros e outros derivativos**. Bookman Editora, 2016.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: PROCEEDINGS of ICNN'95 - International Conference on Neural Networks. 1995. v. 4, p. 1942–1948 vol.4. DOI: 10.1109/ICNN.1995.488968.
- EL-KHODARY, I. A. A decision support system for technical analysis of financial markets based on the moving average crossover. **World Applied Sciences Journal**, v. 6, n. 11, p. 1457–1472, 2009.
- MAZEN, T. S. Gold Exchange Traded Funds (ETFs), Take Profit / Stop Loss Prediction using Machine Learning. **Journal of Business and Management Studies**, Al-Kindi Center for Research e Development, v. 5, n. 4, p. 6–17, 2023. DOI: 10.32996/jbms.2023.5.4.2. Disponível em: <https://al-kindipublisher.com/index.php/jbms/article/view/5538>.
- MIN, B. H.; BORCH, C. Systemic failures and organizational risk management in algorithmic trading: Normal accidents and high reliability in financial markets. **Social Studies of Science**, v. 52, n. 2, p. 277–302, 2022. PMID: 34612758. DOI: 10.1177/03063127211048515. Disponível em: <https://doi.org/10.1177/03063127211048515>.

MIRANDA, L. J. PySwarms: a research toolkit for Particle Swarm Optimization in Python. **Journal of Open Source Software**, v. 3, n. 21, p. 433, 2018.

MIRJALILI, S.; LEWIS, A. The Whale Optimization Algorithm. **Advances in Engineering Software**, v. 95, p. 51–67, 2016. ISSN 0965-9978. DOI: <https://doi.org/10.1016/j.advengsoft.2016.01.008>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0965997816300163>.

NAMETALA, C. Construção de um robô investidor baseado em redes neurais artificiais e preditores econométricos. **Mestrado em Engenharia Elétrica**, Universidade Federal de Minas Gerais, 2017.

NAMETALA, C. A. L. *et al.* Use of Econometric Predictors and Artificial Neural Networks for the Construction of Stock Market Investment Bots. English. **COMPUTATIONAL ECONOMICS**, SPRINGER, VAN GODEWIJCKSTRAAT 30, 3311 GZ DORDRECHT, NETHERLANDS, v. 61, n. 2, p. 743–773, 2023. ISSN 0927-7099. DOI: 10.1007/s10614-021-10228-0.

NAYAK, J. *et al.* 25 Years of Particle Swarm Optimization: Flourishing Voyage of Two Decades. **ARCHIVES OF COMPUTATIONAL METHODS IN ENGINEERING**, v. 30, n. 3, p. 1663–1725, 2023. ISSN 1134-3060. DOI: 10.1007/s11831-022-09849-x.

NOERTJAHYANA, A. *et al.* Stop hunt detection using indicators and expert advisors in the forex market. **Journal of Physics: Conference Series**, IOP Publishing, v. 1502, n. 1, p. 012054, 2020. DOI: 10.1088/1742-6596/1502/1/012054. Disponível em: <https://dx.doi.org/10.1088/1742-6596/1502/1/012054>.

NUNES, R. V.; COMPAGNORE, R. N.; SALES, G. A. W. Relação entre as variáveis Risco País, Índice Bovespa e Taxa de Câmbio no Mercado Brasileiro. **Práticas em Contabilidade e Gestão**, v. 8, n. 2, 2020.

PAKHUCHA, E. *et al.* Financial Risks in the Conditions of Unstable Market Economy. **European Journal of Sustainable Development**, v. 10, n. 1, p. 432, 2021. DOI: 10.14207/ejsd.2021.v10n1p432. Disponível em: <https://ecsdev.org/ojs/index.php/ejsd/article/view/1182>.

PAPAILIAS, F.; THOMAKOS, D. D. An improved moving average technical trading rule. **Physica A: Statistical Mechanics and its Applications**, v. 428, p. 458–469, 2015. ISSN 0378-4371. DOI: <https://doi.org/10.1016/j.physa.2015.01.088>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378437115001752>.

PERES, F.; CASTELLI, M. Combinatorial Optimization Problems and Metaheuristics: Review, Challenges, Design, and Development. **Applied Sciences**, v. 11, n. 14, 2021. ISSN 2076-3417. DOI: 10.3390/app11146449. Disponível em: <https://www.mdpi.com/2076-3417/11/14/6449>.

PORTNOY, K. High frequency trading and the stock market: a look at the effects of trade volume on stock price changes. **The Park Place Economist**, v. 19, n. 1, p. 35–47, 2011.

PRADO, J. W. do *et al.* Decision making in the financial market: a comparison between Artificial Neural Networks and Neuro-Fuzzy Systems for predicting the Bovespa index. **REVISTA ENIAC PESQUISA**, v. 13, n. 1, p. 95–119, 2024. ISSN 2316-2341. DOI: 10.22567/rep.v13i1.952.

PUGH, J.; MARTINOLI, A.; ZHANG, Y. Particle swarm optimization for unsupervised robotic learning. English. In: IEEE. 2005 IEEE SWARM INTELLIGENCE SYMPOSIUM. 345 E 47TH ST, NEW YORK, NY 10017 USA: IEEE, 2005. p. 92–99. IEEE Swarm Intelligence Symposium, Pasadena, CA, JUN 08-10, 2005. ISBN 0-7803-8916-6.

SANTOS, D. R. *et al.* Escolha de carteira de investimento: aplicação no mercado financeiro brasileiro / Choice of investment portfolio: application in the brazilian financial Market. **Brazilian Applied Science Review**, v. 5, n. 1, p. 568–583, 2021. DOI: 10.34115/basrv5n1-036. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BA SR/article/view/25077>.

SHAMI, T. M. *et al.* Particle Swarm Optimization: A Comprehensive Survey. **IEEE ACCESS**, v. 10, p. 10031–10061, 2022. ISSN 2169-3536. DOI: 10.1109/ACCESS.2022.3142859.

SILVA, R. R. C. *et al.* A C4.5 Fuzzy Decision Tree Method for Multivariate Time Series Forecasting. In: IEEE COMPUTAT INTELLIGENCE SOC; IEEE. IEEE CIS INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS 2021 (FUZZ-IEEE). 2021. (IEEE International Conference on Fuzzy Systems). IEEE CIS International Conference on Fuzzy Systems (FUZZ-IEEE), ELECTR NETWORK, JUL 11-14, 2021. ISBN 978-1-6654-4407-1. DOI: 10.1109/FUZZ45933.2021.9494439.

SIVRI, M. S. *et al.* An Intelligent System for Determination of Stop – Loss and Take – Profit Limits: A Dynamic Decision Learning Approach. In: KAHRAMAN, C. *et al.* (Ed.). **Intelligent and Fuzzy Systems**. Cham: Springer Nature Switzerland, 2023. p. 617–624. ISBN 978-3-031-39777-6.

TANG, Y. *et al.* A survey on machine learning models for financial time series forecasting. **Neurocomputing**, v. 512, p. 363–380, 2022. ISSN 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2022.09.003>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S092523122201089X>.

VEZERIS, D.; KYRGOS, T.; SCHINAS, C. Take Profit and Stop Loss Trading Strategies Comparison in Combination with an MACD Trading System. **Journal of Risk and Financial Management**, v. 11, n. 3, 2018. ISSN 1911-8074. DOI: 10.3390/jrfm11030056. Disponível em: <https://www.mdpi.com/1911-8074/11/3/56>.

WARBURTON, A.; ZHANG, Z. A simple computational model for analyzing the properties of stop-loss, take-profit, and price breakout trading strategies. English. **COMPUTERS & OPERATIONS RESEARCH**, PERGAMON-ELSEVIER SCIENCE LTD, THE BOULEVARD, LANGFORD LANE, KIDLINGTON, OXFORD OX5 1GB, ENGLAND, v. 33, n. 1, p. 32–42, 2006. ISSN 0305-0548. DOI: 10.1016/j.cor.2004.06.001.

WILINSKI, A.; KOVALERCHUK, B. Visual knowledge discovery and machine learning for investment strategy. **Cognitive Systems Research**, v. 44, p. 100–114, 2017. ISSN 1389-0417. DOI: <https://doi.org/10.1016/j.cogsys.2017.04.004>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1389041717300359>.

WU, J. M.-T. *et al.* Convert index trading to option strategies via LSTM architecture. **NEURAL COMPUTING & APPLICATIONS**, 2020. ISSN 0941-0643. DOI: 10.1007/s00521-020-05377-6.

ZERVOUDAKIS, K.; TSAFARAKIS, S. A mayfly optimization algorithm. **Computers & Industrial Engineering**, v. 145, p. 106559, 2020. ISSN 0360-8352. DOI: 10.1016/j.cie.2020.106559. Disponível em: <https://www.sciencedirect.com/science/article/pii/S036083522030293X>.

ZYL, J.-P. van; ENGELBRECHT, A. P. Set-Based Particle Swarm Optimisation: A Review. **Mathematics**, v. 11, n. 13, 2023. ISSN 2227-7390. DOI: 10.3390/math11132980. Disponível em: <https://www.mdpi.com/2227-7390/11/13/2980>.