



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:
Limitações e possibilidades**

XXXI SIMPEP
www.simpep.feb.unesp.br

OTIMIZAÇÃO DE DECISÕES NO MERCADO DE CRIPTOMOEDAS: APLICAÇÃO DE ALGORITMOS EVOLUTIVOS E ANÁLISE TÉCNICA DA VOLATILIDADE

LAÍS GONÇALVES VIANA – lais.viana@ufv.br
UNIVERSIDADE FEDERAL DE VIÇOSA – UFV – CAMPUS RIO PARANAÍBA

HELEN VITALINE DE CASTRO SANTOS - helen.castro@ufv.br
UNIVERSIDADE FEDERAL DE VIÇOSA – UFV – CAMPUS RIO PARANAÍBA

THIAGO HENRIQUE NOGUEIRA - thiagoh.nogueira@ufv.br
UNIVERSIDADE FEDERAL DE VIÇOSA – UFV – CAMPUS RIO PARANAÍBA

LARISSA SOUSA CAMPOS - larissa.sousa@ufv.br
UNIVERSIDADE FEDERAL DE VIÇOSA – UFV – CAMPUS RIO PARANAÍBA

RAIANE RIBEIRO MACHADO GOMES - raianemachado@gmail.com
UNIVERSIDADE FEDERAL DE VIÇOSA – UFV – CAMPUS RIO PARANAÍBA

ÁREA: 3. PESQUISA OPERACIONAL

SUBÁREA: 3.1 - MODELAGEM, SIMULAÇÃO E OTIMIZAÇÃO

RESUMO: ESTE ARTIGO EXPLORA A OTIMIZAÇÃO DE DECISÕES NO MERCADO DE CRIPTOMOEDAS POR MEIO DE TRADING ALGORÍTMICO, UTILIZANDO TÉCNICAS META-HEURÍSTICAS. A VOLATILIDADE DAS CRIPTOMOEDAS, INFLUENCIADA POR FATORES COMO FALTA DE REGULAMENTAÇÃO, ESPECULAÇÃO E OFERTA E DEMANDA, APRESENTA DESAFIOS ÚNICOS. TÉCNICAS DE OTIMIZAÇÃO EVOLUCIONÁRIA, COMO ALGORITMOS GENÉTICOS, MOSTRAM-SE PROMISSORAS NESSE CONTEXTO. MODELOS GARCH FORAM EMPREGADOS PARA MODELAR A VOLATILIDADE DAS CRIPTOMOEDAS, ENQUANTO A ANÁLISE TÉCNICA, COM INDICADORES COMO O RSI, DESEMPENHA UM PAPEL CRUCIAL NA PREVISÃO DE PREÇOS. O DESENVOLVIMENTO DO MODELO DE TRADING ALGORÍTMICO UTILIZOU DADOS HISTÓRICOS E FUTUROS DA CORRETORA BINANCE, APLICANDO O ALGORITMO BRKGA PARA GERAR SOLUÇÕES OTIMIZADAS E O MÉTODO GARCH PARA ANALISAR A VOLATILIDADE. A COMBINAÇÃO DE ALGORITMOS GENÉTICOS, MODELOS GARCH E INDICADORES TÉCNICOS PERMITIU UMA ANÁLISE ABRANGENTE E OTIMIZADA PARA A TOMADA DE DECISÕES NO MERCADO DE CRIPTOMOEDAS, CONTRIBUINDO PARA O SUCESSO NESSE AMBIENTE VOLÁTIL E COMPLEXO.

PALAVRAS-CHAVES: ALGORITMOS EVOLUTIVOS; CRIPTOMOEDAS; VOLATILIDADE.

1. INTRODUÇÃO

O mercado financeiro está em constante crescimento e mudança devido à globalização e aos altos investimentos realizados (PILBEAM, 2018). Segundo o autor, a busca por modelos de previsão de preços é um desafio significativo nesse mercado (HENRIQUE et al., 2019). Para os autores isso ocorre porque os ativos financeiros não seguem uma relação linear e são simultaneamente dinâmicos e caóticos, tornando-os difíceis de serem previstos.

Com a evolução do mercado financeiro, a gestão financeira tornou-se um tema de importância global, abrangendo tanto o âmbito político quanto o individual e social (MOSTEANU et al, 2020). De acordo com os autores, é necessário adaptar a gestão financeira à era digital, utilizando ferramentas inovadoras para redução de riscos e de custos. Nessa era digital, as criptomoedas têm sido cada vez mais incluídas nas carteiras de investimentos, como os primeiros ativos digitais puros, ainda em processo de compreensão. (FANG et al., 2022).

As criptomoedas, finanças digitais e inteligência artificial têm um papel crescente no mercado financeiro. São moedas digitais virtuais que se baseiam em técnicas criptografadas, derivadas da palavra grega "*Kryptos*", que significa oculto (MOSTEANU et al, 2020). O surgimento e popularização do *bitcoin* em 2009 impulsionaram o interesse pelas criptomoedas (MEREDIZ-SOLÀ et al, 2019). Segundo os autores, o *bitcoin* utiliza a tecnologia *blockchain*, um livro razão que simplifica o registro e o controle de ativos.

Problemas de otimização combinatória (OC) são desafiadores e comuns em várias áreas e envolvem a minimização ou maximização de uma função sujeita a restrições (MAURI, 2008). Enquanto soluções eficientes existem para alguns problemas, outros exigem abordagens simplificadas, heurísticas, metaheurísticas e decomposição do problema original (REKIEK et al., 2006). As metaheurísticas são uma opção flexível e inteligente, elas exploram estrategicamente o espaço de soluções, encontrando múltiplos ótimos locais (ARROYO, 2022).

O uso de algoritmos combinados a modelos matemáticos tem se popularizado para automatizar operações nos mercados financeiros (GSELL, 2008). Segundo Basedkidou (2017) no mercado cambial e de cripto ativos, conhecido como *algorithmic trading*, essa abordagem é comum. O uso de métodos metaheurísticos nesse contexto é promissor devido à alta volatilidade dos cripto ativos, permitindo explorar seu comportamento de forma mais precisa. (SILVA, 2022).

Este trabalho tem como objetivo desenvolver um modelo de *algorithmic trading* utilizando metaheurística para otimizar as decisões no mercado cripto. O estudo aborda a importância do tema, fornece embasamento teórico, descreve a estrutura do modelo e método utilizado, além de discutir os resultados obtidos. A complexidade do trabalho envolve a aplicação de métodos metaheurísticos para obter resultados nos mercados cripto, explorando a alta volatilidade e buscando estratégias otimizadas para a tomada de decisões. Esse problema é classificado como *NP-hard*, conforme Nogueira et al. (2006).

2. REFERENCIAL TEÓRICO

2.1 Variação de preços de criptomoedas

O estudo de Yermack (2015) destaca o interesse crescente de pesquisadores e investidores na volatilidade e oscilação de preços no mercado das criptomoedas. Segundo o autor, esse mercado é conhecido por sua instabilidade, influenciada por diversos fatores. Nesse contexto, torna-se essencial compreender como a volatilidade afeta os investimentos em criptomoedas e quais são os principais motivos para as flutuações nos preços (KATSIAMPA, 2019).

Segundo Katsiampa (2019) a falta de regulamentação governamental e a incerteza futura das criptomoedas contribuem para sua volatilidade e o mercado é jovem, o que faz com

que careça de estruturas de controle, presentes em outros mercados. A especulação intensifica as oscilações extremas de preços, aumentando o risco (POUTZIOURIS et al, 2020). Para os autores, a falta de regulamentação adequada e a especulação permitem manipulações por parte dos investidores, exacerbando a volatilidade.

A percepção do público sobre as criptomoedas, impulsionada pela atenção da mídia e postagens nas redes sociais, pode também afetar os preços (URGUHART, 2018). A oferta e a demanda também desempenham um papel importante, com a oferta limitada levando a aumentos significativos em períodos de alta demanda e a quedas nos preços em momentos de baixa demanda (DYHRBERG, 2016).

A competição entre diferentes criptomoedas afeta os preços, pois os investidores realocam fundos em busca de melhores oportunidades (DYHRBERG, 2016). Além disso, segundo Bouri et al., (2019), a tecnologia subjacente das criptomoedas, como a segurança do blockchain, influencia a confiança dos investidores e os preços das criptomoedas. Para os autores, o contínuo desenvolvimento tecnológico pode trazer mudanças significativas na utilização das criptomoedas e impactar os preços a longo prazo.

2.2 Otimização evolucionária no mercado de criptomoedas

A otimização evolucionária utiliza metaheurísticas que imitam a evolução natural (BLUM, 2012), com algoritmos de busca baseados em uma população e envolvendo aleatoriedade e seleção. Esses métodos são relevantes para a otimização do mercado de criptomoedas, devido à volatilidade, perdas e mudanças de valor, exigindo análises de dependências e técnicas para lidar com interações aleatórias (MBA et al, 2018).

Os algoritmos genéticos são métodos de otimização inspirados na biologia, eficazes na análise e resolução de problemas com alta aleatoriedade e fator de seleção (KRAMER, 2017). No mercado de investimentos, Oydele et al. (2023) examinaram o desempenho de um algoritmo genético baseado em Deep Learning (DL) em comparação com outros métodos. Segundo os autores, o modelo DL demonstrou resultados com menor erro percentual e maior confiabilidade.

Mba et al. (2018) realizaram uma análise de duas abordagens evolucionárias, o *GARCH-DE* e o *GARCH-DE-t-cópula*, com foco no crescimento de portfólios de cripto ativos. Comparando essas abordagens com um benchmark, o método com t-cópula mostrou maior capacidade de controle de risco para ativos voláteis. Em geral, a abordagem *GARCH* é importante para analisar a volatilidade e prever a dependência do tempo em relação ao retorno de um ativo (BAUWENS et al, 2006).

2.3 Indicadores de Análise Técnica

A análise técnica visa prever variações futuras em investimentos e especulações, com base no histórico passado, diferentemente da análise fundamentalista (EDWARDS, 2018). Ilham et al., (2022) enfocam a importância do mercado de criptomoedas e estudam a viabilidade da análise técnica para a previsão de preços nesse mercado. Os autores buscam demonstrar a possibilidade de obter lucros por meio da análise de preços e variações anteriores.

É possível encontrar vários indicadores de análise técnica no estudo que foi utilizado como base, de acordo com Silva, Ochi e Coelho (2022) os indicadores são utilizados para quantificar informações sobre o comportamento dos ativos no mercado. Os autores trazem entre os mais importantes e utilizados, o *RSI* (Relative Strength Index), o *SMA* (Simple Moving Average), o *EMA* (Exponential Moving Average) e o *MACD* (Moving Average Convergence Divergence).

O Relative Strength Index tem como objetivo medir a tendência no preço do ativo, ou seja, a partir de análises, esse indicador evidencia áreas onde o ativo está sobrevendido (barato) ou sobrecomprado (caro) (ANDERSON, 2015). Segundo Adrian (2011), o dilema dos

investidores é escolher a ação certa no momento certo, muito devido a volatilidade desses ativos, então, apesar de ser pouco utilizado pelos investidores, o *RSI* acaba sendo uma ferramenta fundamental para entender essa movimentação das criptomoedas.

2.4 Dados Históricos e futuros

A análise de dados históricos e futuros é promissora para compreender o comportamento das criptomoedas no mercado financeiro, e a análise técnica é usada para interpretar esse comportamento (FURLAN et al., 2022). Dois métodos amplamente utilizados nessa análise são o *BRKGA* (Biased Random-Key Genetic Algorithm) e o *GARCH* (Generalized Autoregressive Conditional Heteroskedasticity). O *BRKGA* é uma metodologia de otimização que usa seleção natural para codificar soluções e alcançar soluções ótimas (PAVAN et al., 2021).

Enquanto isso, o método *GARCH* é voltado para modelagem que busca interpretar a volatilidade das criptomoedas (PIZZETTI, 2019). Para De Castro et al. (2021), os modelos *GARCH* podem capturar a persistência da volatilidade, quer dizer, as tendências que irão acontecer após os períodos de alta e baixa volatilidade. Sendo assim, esses modelos são usados para identificar os padrões de comportamento nos movimentos de preços por meio dos dados históricos e futuros.

A comparação de estratégias utilizando benchmarks, como o *RSI* (Relative Strength Index) ou Índice de Força Relativa, é um processo importante na compreensão de dados históricos e futuros (SANTOS, 2018). O *RSI* é um indicador de análise técnica utilizado para avaliar o momentum de um ativo, fornecendo informações valiosas sobre o mercado (FURLAN et al., 2022). A utilização do *RSI* como referência ajuda a avaliar a eficácia das estratégias de análise técnica, especialmente nos modelos *BRKGA* e *GARCH*.

2.5 Premissas e métodos que serão utilizados

As premissas do presente trabalho serão baseadas em valores reais e voláteis, com auxílio de dados da corretora de criptomoedas *Binance*. Segundo Alexander et al. (2022), os dados da corretora funcionam como uma forma eficiente de analisar a dinâmica de volatilidade dos ativos, sempre levando em consideração dados históricos e futuros. A partir disso será aplicado, assim como no trabalho base, o *BRKGA* (Algoritmo Genético de Chaves Aleatórias Enviesadas), que de acordo com Silva, Ochi e Coelho (2022) pré-define componentes de geração de novos indivíduos, além disso traz uma estrutura padronizada para representar a solução.

Prosseguindo com o desenvolvimento da solução será aplicado, baseado no trabalho de Mba et al. (2018), o método de evolução *GARCH* para estudar a volatilidade desses dados coletados e gerados a partir do algoritmo genético. Por fim, com a comparação com benchmark e a solução encontrada será possível, a partir de taxas e com avaliação pessimista dos preços, estudar o *RSI* que segundo Adrian (2011) poderá ser utilizado como forma de separar os ativos em possíveis baratos e possíveis caros, chegando à conclusões sobre a volatilidade e o sistema de variação das criptomoedas.

3. METODOLOGIA

A pesquisa sobre o mercado de criptomoedas tem se mostrado cada vez mais relevante, dada a crescente adoção e a volatilidade desse mercado (ELBAHRAWY, 2017). O projeto atual envolve a implementação de um modelo que utiliza o algoritmo genético *BRKGA* para prever os preços do Bitcoin, enquanto estuda a volatilidade do mercado de criptomoedas através do método de análise temporal *GARCH* e o indicador de análise técnica *RSI*. Com isso, a fim de

compreender e analisar a dinâmica desse ambiente, é necessário estabelecer procedimentos metodológicos adequados.

O presente trabalho utiliza uma abordagem quantitativa de dados, combinando coleta e análise estatística (ANDERSON et al., 2018). Essa abordagem tem como objetivo quantificar fenômenos por meio de dados numéricos. No mercado de criptomoedas, ela é frequentemente aplicada para avaliar a volatilidade dos preços, identificar tendências, analisar correlações e modelar os movimentos do mercado (KARAKOSTAS et al., 2019). Segundo os autores, essa abordagem possibilita uma análise objetiva e baseada em evidências estatísticas, proporcionando uma compreensão mais precisa e mensurável do mercado.

A coleta de dados em pesquisas sobre o mercado de criptomoedas requer uma abordagem sistemática e abrangente, utilizando fontes como *exchanges*, fornecedores de dados de mercado e plataformas de análise (SCHAUPP et al., 2018). Neste trabalho, a coleta de dados se baseia em dados históricos, considerados essenciais para a análise do mercado de criptomoedas (YIYING et al, 2019). Esses dados históricos abrangem informações como preços, volumes de negociação, capitalização de mercado e outras métricas relevantes. Eles são utilizados para identificar padrões passados, criar modelos de previsão e realizar análises retrospectivas. O trabalho em questão utiliza dados históricos do preço do *bitcoin* nos anos de 2021 e 2022, obtidos da empresa *Binance*.

IMAGEM 1: Exemplo de premissas

date (mm-aaaa), price (US\$)

01-2021, 33.108,10	01-2022, 38.498,60
02-2021, 45.164,00	02-2022, 43.188,20
03-2021, 58.763,70	03-2022, 45.525,00
04-2021, 57.720,30	04-2022, 37.650,00
05-2021, 37.298,60	05-2022, 31.793,40
06-2021, 35.026,90	06-2022, 19.926,60
07-2021, 41.553,70	07-2022, 23.303,40
08-2021, 47.130,40	08-2022, 20.043,90
09-2021, 43.823,30	09-2022, 19.423,00
10-2021, 61309,60	10-2022, 20.496,30
11-2021, 56.882,90	11-2022, 17.163,90
12-2021, 46.219,50	12-2022, 16.537,40

Fonte: site *Binance* (2023)

Este trabalho utiliza as *exchanges* e a análise técnica como procedimentos técnicos no mercado de criptomoedas. As corretoras permitem transações em criptomoedas e oferecem diferentes opções de negociação, enquanto a análise técnica estuda gráficos de preços e indicadores para prever movimentos futuros (CHU, 2018). A escolha dessas abordagens visa explorar a volatilidade e a incerteza inerentes ao mercado, assim como compreender como afetam a tomada de decisões. Ao implementar algoritmos metaheurísticos, o estudo busca fornecer *insights* sobre esse ambiente desafiador. Em suma, as *exchanges* e a análise técnica são ferramentas cruciais para compreender e lidar com a complexidade do mercado de criptomoedas (ILHAM et al., 2022).

O modelo matemático para análise do mercado de criptomoedas pode abordar diferentes aspectos, como previsão de preços, alocação de portfólio ou análise de risco (SHAH et al., 2021). Diante disso, este trabalho traz um exemplo de modelo de previsão de preços usando uma abordagem de média móvel exponencial (EMA):

Parâmetros:

- T: Conjunto de períodos de tempo

- $P(t)$: Preço da criptomoeda no período t
- α : Fator de suavização exponencial

Modelo (Encontrar a previsão de preço $F(t+1)$ para o próximo período $t+1$ usando a EMA):

$$F(t+1) = \alpha * P(t) + (1 - \alpha) * F(t) \quad (1)$$

Restrição:

$$t \in T \Rightarrow t \leq t_{\text{end}} \ \&\& \ t \geq t_{\text{start}} \quad (2)$$

Onde t_{end} é o instante de tempo mais recente que queremos considerar e t_{start} é o instante de tempo que está t anos antes do t_{end} .

Este modelo usa uma abordagem de suavização exponencial que, segundo Furlan et al. (2022), tem a função de calcular a previsão do preço da criptomoeda para o próximo período. O valor ' α ' controla o peso da observação atual ($P(t)$) em relação à previsão anterior ($F(t)$) e de acordo com o autor quanto maior o valor de α , maior será o impacto da observação atual na previsão.

Portanto, a literatura traz que um modelo matemático por si só pode não ser suficiente para capturar toda a dinâmica do mercado. Dessa forma, neste trabalho foram utilizados o Algoritmo evolutivo *BRKGA* para pré-definir os movimentos do mercado e o método *GARCH* para analisar a variação da volatilidade em relação ao tempo usando sempre a análise quantitativa e fontes de dados para análise técnica mais completa.

O algoritmo *BRKGA* segue uma sequência específica para aprimorar as soluções ao longo das gerações. A população inicial é gerada aleatoriamente e o *fitness* de cada indivíduo é calculado. A população é ordenada com base nessa informação, estabelecendo a geração inicial com soluções conhecidas. As soluções são aprimoradas para a próxima geração através da adição de mutantes selecionados aleatoriamente e da cópia das melhores soluções. Novos indivíduos são gerados por meio da reprodução, combinando os genes dos pais. O *fitness* é recalculado, a população é ordenada e o processo é repetido por um número pré-determinado de gerações, visando melhorar as soluções ao longo do tempo. O algoritmo *BRKGA* realiza um processo iterativo de geração, seleção, reprodução e aprimoramento das soluções para obter soluções de maior qualidade (SILVA, 2022).

À vista disso, o pseudocódigo em *Phyton* para implementação do algoritmo *BRKGA* é demonstrado abaixo:

Algoritmo 1: *BRKGA*

Passo 1: Definição de Parâmetros

- ``num_individuals``: Define o número de indivíduos na população;
- ``num_genes``: Define o número de genes em cada indivíduo, que é igual ao tamanho dos dados históricos;
- ``num_parents``: Define o número de pais selecionados em cada geração;
- ``num_offsprings``: Define o número de descendentes gerados em cada geração;
- ``num_generations``: Define o número de gerações a serem executadas;
- ``mutation_rate``: Define a taxa de mutação dos genes;

Passo 2: Geração da População Inicial

- ``generate_population()``: Gera a população inicial com ``num_individuals`` indivíduos, onde cada indivíduo é representado por uma lista de genes aleatórios;

Passo 3: Avaliação da Aptidão

- ``evaluate()``: Calcula a aptidão de um indivíduo somando seus genes;
- A aptidão de cada indivíduo na população é calculada e armazenada;

Passo 4: Iterações do Algoritmo Genético

- Repete o processo até atingir o critério de parada (número de gerações):
 - 4.1: Seleção dos Pais

- Os pais são selecionados com base na aptidão de cada indivíduo na população. A probabilidade de seleção é proporcional à aptidão;
- 4.2: Recombinação (*Crossover*)
 - Os pais selecionados são combinados para gerar os descendentes (*offsprings*). O crossover é realizado em cada gene dos pais para produzir os genes dos descendentes;
- 4.3: Mutação
 - Cada gene dos descendentes tem uma chance de sofrer mutação, onde é substituído por um valor aleatório;
 - Os *offsprings* são adicionados à população junto com os pais;
 - Os passos 4.1 a 4.3 são repetidos para gerar novas gerações;

Passo 5: Avaliação Final da População

- A aptidão de cada indivíduo na população final é calculada novamente;

Passo 6: Resultado Final

- O indivíduo com a maior aptidão na população final é considerado a melhor solução encontrada;
- O resultado é exibido para cada período no histórico de dados, mostrando o período, o preço real e a solução correspondente.

Em resumo, o código implementa o algoritmo genético *BRKGA* para prever os preços do *Bitcoin*. Ele gera uma população inicial de previsões de preços, combina e modifica os indivíduos ao longo de várias iterações. O objetivo é encontrar a melhor previsão possível, minimizando a diferença entre as previsões e os preços reais. O elitismo mantém os melhores indivíduos e influencia as gerações futuras. Os parâmetros foram definidos antes da execução. Ao executar o código, são exibidos os resultados para cada período no histórico de dados.

Quanto ao método *GARCH*, foi aplicado em *Python* usando bibliotecas específicas para estimar a volatilidade das criptomoedas em relação ao tempo. Inicialmente são importadas as informações de valores e mutação de indivíduos retirados do método *BRKGA* e carregadas informações de tempo e preço da criptomoeda. A partir desses dados são realizados cálculos logarítmicos para entender a forma de variação de determinado valor em determinado tempo variável. Com isso, o modelo *GARCH* é ajustado na forma *GARCH* (1,1), dado como:

Equação Geral do modelo *GARCH* (1,1):

$$F(t+1) = \alpha * P(t) + (1 - \alpha) * F(t) \quad (3)$$

onde:

- $F(t+1)$ é a previsão para o próximo período de tempo $(t+1)$;
- α é o fator de suavização exponencial, que controla a influência do valor atual $(P(t))$ em relação à previsão anterior $(F(t))$;
- $P(t)$ é o preço real da criptomoeda no período de tempo t ;
- $F(t)$ é a previsão atualizada para o período de tempo t .

Com base nos dados do modelo, o código imprime as estimativas e plota a volatilidade estimada para um intervalo de tempo específico. O processo segue os seguintes passos:

1. A primeira etapa é definir as variáveis necessárias para o modelo *GARCH*, como a média (μ) e a variância (σ^2) da série de preços;

2. Em seguida, é aplicada a restrição *GARCH* para atualizar a variância σ^2 usando o modelo *GARCH*. Essa restrição é aplicada para cada período de tempo t no conjunto T , desde que t esteja dentro do intervalo especificado por t_{start} e t_{end} ;

3. A equação do modelo *GARCH* é utilizada na restrição *GARCH* para calcular a variância σ^2 para o próximo período $t+1$. A equação leva em consideração o preço atual $P(t)$, a média μ e a variância anterior $\sigma^2(t)$. O fator de suavização exponencial (α) é utilizado na equação, onde $(1-\alpha)$ representa a parcela de persistência da variância anterior;

4. Durante a otimização, o *solver* busca encontrar os valores ótimos para as variáveis de decisão, incluindo μ e σ^2 . Esses valores minimizam a função objetivo *Error* e satisfazem as restrições definidas.

Em resumo, o modelo *GARCH* adicionado ao código permite atualizar a variância *sigma_squared* ao longo do tempo, capturando a volatilidade e a persistência na série de preços. A equação do modelo *GARCH* é aplicada para estimar a volatilidade futura com base nas informações atuais e anteriores. Na seção de resultados, serão discutidos e analisados os efeitos da aleatoriedade na volatilidade das criptomoedas, incluindo uma análise do índice *RSI* (Relative Strength Index) e como ele funciona em relação às estimativas geradas pelo método *GARCH* temporal.

4. RESULTADOS

Como ponto de partida para aplicação dos modelos desenvolvidos, foram utilizados os dados fornecidos pelo site *Binance*, para que pudessem ser realizadas as previsões usando duas abordagens diferentes: o algoritmo *BRKGA* e o modelo *GARCH*. Para implementar esses métodos, foi usado o ambiente *JupyterLab online* e a linguagem de programação *Python*.

Sendo assim, o primeiro passo foi executar o método *BRKGA*, onde o código implementado faz uso de um algoritmo genético para otimizar uma função de avaliação com base em dados históricos, buscando encontrar a melhor solução possível para o problema em questão (PAVAN et al., 2021). O resultado retornado pelo programa do método é mostrado na Tabela 1 abaixo.

TABELA 1: Resultado *BRKGA*

Período	Preço (US\$)	Solução
1	\$ 33.108,10	0,643803691086050
2	\$ 45.164,00	0,725190820608987
3	\$ 58.763,70	0,570948638427281
4	\$ 57.720,30	0,524487269104545
5	\$ 37.298,60	0,619142890484522
6	\$ 35.026,90	0,547823661759864
7	\$ 41.553,70	0,414080253060329
8	\$ 47.130,40	0,491160641134250
9	\$ 43.823,30	0,520732427985926
10	\$ 61.309,60	0,466539651767383
11	\$ 56.882,90	0,817564979783655
12	\$ 46.219,50	0,449217124745498
13	\$ 38.498,60	0,439216234138859
14	\$ 43.188,20	0,456658795944579
15	\$ 45.525,00	0,499180335079808
16	\$ 37.650,00	0,417828694630972
17	\$ 31.793,40	0,476317525957501
18	\$ 19.926,60	0,407152555954839
19	\$ 23.303,40	0,563265011947750
20	\$ 20.043,90	0,621121369731255
21	\$ 19.423,00	0,464060619036510
22	\$ 20.496,30	0,351130715141355
23	\$ 17.163,90	0,925172966179773
24	\$ 16.537,40	0,424712740793446

Fonte: autores (2024)

Como resultado, a solução representa a aptidão das soluções encontradas pelo algoritmo genético para prever o preço do *Bitcoin* em cada período. No período 01/2021 o preço é US\$33.108,10 e a solução encontrada pelo algoritmo foi 0.643803691086050. Essa solução representa a aptidão da solução encontrada pelo algoritmo, onde valores mais altos indicam uma melhor solução em termos de maximização da função de avaliação, ou seja, valores mais altos possuem uma maior probabilidade de serem selecionados para reprodução e recombinação para geração de novas soluções, uma vez que um maior valor favorece o investimento.

Para o período 02/2021, o preço é US\$45.164,00 e a solução correspondente encontrada pelo algoritmo foi 0.725190820608987. Esse valor indica que o algoritmo encontrou uma solução com maior aptidão nesse período em comparação com o período anterior. Sendo assim,

os resultados seguem o mesmo padrão para os períodos subsequentes. Para cada período, é fornecido o preço do *Bitcoin* e a solução correspondente encontrada pelo algoritmo. Por isso, valores mais altos de solução indicam uma melhor capacidade do algoritmo em prever o preço com base nos dados históricos disponíveis.

Os resultados obtidos pelo *BRKGA* servirão de base de comparação com as previsões que serão geradas pelo método *GARCH*, onde busca-se capturar a volatilidade e a heteroscedância dos dados financeiros. O *GARCH* é amplamente utilizado para modelar e prever a variância condicional em séries temporais financeiras, sendo especialmente adequado para capturar mudanças na volatilidade ao longo do tempo (PIZZETTI, 2019). A solução mostra os resultados da previsão para cada período de tempo dentro do intervalo especificado, como mostra a Tabela 2.

TABELA 2: Resultado *GARCH*

Período	Preço (US\$)	Previsão (US\$)
1	\$33.108,10	\$ 33.108,10
2	\$45.164,00	\$ 39.136,05
3	\$58.763,70	\$ 48.949,88
4	\$57.720,30	\$ 53.335,09
5	\$37.298,60	\$ 45.316,84
6	\$35.026,90	\$ 40.171,87
7	\$41.553,70	\$ 40.862,79
8	\$47.130,40	\$ 43.996,59
9	\$43.823,30	\$ 43.909,95
10	\$61.309,60	\$ 52.609,77
11	\$56.882,90	\$ 54.746,34
12	\$46.219,50	\$ 50.482,92
13	\$38.498,60	\$ 44.490,76
14	\$43.188,20	\$ 43.839,48
15	\$45.525,00	\$ 44.682,24
16	\$37.650,00	\$ 41.166,12
17	\$31.793,40	\$ 36.479,76
18	\$19.926,60	\$ 28.203,18
19	\$23.303,40	\$ 25.753,29
20	\$20.043,90	\$ 22.898,59
21	\$19.423,00	\$ 21.160,80
22	\$20.496,30	\$ 20.828,55
23	\$17.163,90	\$ 18.996,22
24	\$16.537,40	\$ 17.766,81

Fonte: autores (2024)

Cada linha apresenta o período, o preço real da criptomoeda e a previsão correspondente calculada pelo método de suavização exponencial. Observando as previsões, é possível notar que o método demonstra assertividade tanto nas fases de alta quanto nas fases de queda, seguindo os padrões de variação dos preços. Além disso, percebe-se que a previsão para o primeiro período coincide com o preço real da criptomoeda, já que é o valor inicial utilizado para iniciar a previsão. À medida que os períodos avançam, a previsão começa a refletir uma combinação do preço atual da criptomoeda e da previsão anterior, ponderada pelo fator de suavização exponencial.

Ademais, é importante ressaltar que a precisão das previsões depende do valor do fator de suavização exponencial (α) e da capacidade do método em capturar as tendências e padrões presentes nos dados históricos. Neste caso, o valor de α foi definido como 0.5, o que implica um peso igual para o preço atual e a previsão anterior. Se o valor de α fosse maior, a previsão daria mais peso ao preço atual, tornando-a mais sensível às variações recentes. Por outro lado, se o valor de α fosse menor, a previsão seria mais suavizada e menos sensível às flutuações do mercado.

Em síntese, a previsão pode fornecer uma estimativa razoável do preço futuro com base nos dados históricos disponíveis. No entanto, é recomendável realizar uma análise mais aprofundada e considerar outros fatores relevantes antes de tomar decisões com base nessas previsões. À vista disso, também recorreremos ao indicador *RSI* (*Relative Strength Index*) para complementar a análise. O *RSI* é um indicador técnico amplamente utilizado na análise financeira para medir a força e a velocidade das mudanças nos preços dos ativos (SANTOS, 2018). O indicador *RSI* é dado pela equação:

$$RSI(\%) = \frac{|U|}{|U| + |D|} \quad (4)$$

U = soma dos períodos que apresentam crescimento referente ao período anterior

D = soma dos períodos que apresentam queda referente ao período anterior

A partir dos dados de previsão do método *GARCH*, foi possível calcular o indicador *RSI* com base nos seguintes dados:

TABELAS: Previsões com base no Método *GARCH*

Períodos em Queda (D)	Preço		Períodos em Crescimento (U):	Preço
5	\$ 45.316,84		2	\$ 39.136,05
6	\$ 40.171,87		3	\$ 48.949,88
9	\$ 43.909,00		4	\$ 53.335,09
12	\$ 50.482,91		7	\$ 40.862,79
13	\$ 44.490,76		8	\$ 43.996,59
14	\$ 43.839,48		10	\$ 52.609,77
16	\$ 41.166,12		11	\$ 54.746,34
17	\$ 36.479,76		15	\$ 44.682,24
18	\$ 28.203,18		U	\$ 378.318,73
19	\$ 25.753,29			
20	\$ 22.898,59			
21	\$ 21.160,80			
22	\$ 20.828,55			
23	\$ 18.996,22			
24	\$ 17.766,81			
1	\$ 33.108,10			
D	\$ 534.572,27			

Fonte: autores (2024)

A análise do *RSI* tem como objetivo medir a tendência do preço do ativo evidenciando onde o ativo é sobrevendido (o preço é barato) $RSI < 30\%$ e onde é sobrecomprado (o preço é caro) $RSI > 70\%$. No intervalo identificado foi possível observar um *RSI* de 41,44%, o que traz que o preço está tendendo a se manter barato, podendo variar para cima ou para baixo, observando o intervalo de 2 anos. Esse dado indica que analisando um período maior é possível

ver que a tendência é o preço do ativo se manter baixo, sendo interessante o investimento, pensando a longo prazo.

5. CONCLUSÃO

Este trabalho desenvolveu uma abordagem de modelagem para *algorithmic trading* no mercado de criptomoedas, utilizando técnicas de meta-heurística. Os métodos meta-heurísticos, como o algoritmo *BRKGA* e o modelo *GARCH*, foram implementados em *Python* no ambiente *JupyterLab*. Os resultados mostraram a eficiência dessas abordagens na previsão de preços de criptomoedas. O algoritmo *BRKGA* gerou soluções com alta aptidão, indicando sua capacidade de prever o preço do Bitcoin com base em dados históricos. O modelo *GARCH* capturou a volatilidade e a heterocedasticidade dos dados financeiros, fornecendo previsões que refletiam as tendências de preços. No entanto, é necessário realizar uma análise mais aprofundada e considerar outros fatores relevantes antes de tomar decisões de negociação. A utilização do indicador *RSI* também forneceu uma avaliação adicional da tendência do preço do ativo. Em um mercado volátil e complexo como o das criptomoedas, os métodos meta-heurísticos oferecem uma abordagem promissora para auxiliar nas decisões de negociação, identificação de oportunidades e desenvolvimento de estratégias otimizadas, fornecendo *insights* valiosos aos investidores e *traders* nesse ambiente em constante mudança.

REFERÊNCIAS

- ADRIAN, ran-Moroan. The relative strength index revisited. *African Journal of Business Management*, v. 5, n. 14, p. 5855-5862, 2011.
- ALEXANDER, Carol; HECK, Daniel F.; KAECK, Andreas. The role of binance in bitcoin volatility transmission. *Applied Mathematical Finance*, v. 29, n. 1, p. 1-32, 2022.
- ANDERSON, Bing; LI, Shuyun. Uma investigação do índice de força relativa. *Bancos e sistemas bancários*, n. 10, Iss. 1, pág. 92-96, 2015.
- ANDERSON, David R. et al. *An introduction to management science: quantitative approach*. Cengage learning, 2018.
- ARROYO, José Elias Cláudio et al. *Heurísticas e metaheurísticas para otimização combinatória multiobjetivo*. Campinas: UNICAMP, 2002.
- BASDEKIDOU, Vasiliki A. et al. The Momentum & Trend-Reversal as Temporal Market Anomalies. *International Journal of Economics and Finance*, v. 9, n. 5, p. 1-19, 2017.
- BAUWENS, Luc; LAURENT, Sébastien; ROMBOUTS, Jeroen VK. Multivariate GARCH models: a survey. *Journal of applied econometrics*, v. 21, n. 1, p. 79-109, 2006.
- BLUM, Christian et al. Evolutionary optimization. Variants of evolutionary algorithms for real-world applications, p. 1-29, 2012.
- BOURI, E.; MOLNAR, P.; AZZI, G. Cryptocurrencies as a financial asset: A systematic analysis. *International Review*, 2019.

CHU, Dennis. Corretoras de moeda virtual: regulando carteiras e trocas de criptomoedas. coluna L. Rev. , v. 118, pág. 2323, 2018.

DE CASTRO BARRAL, José Alex; DO NASCIMENTO CARVALHO, Brena; DA COSTA LOBATO, Tarcísio. As moedas virtuais: uma aplicação dos modelos GARCH para o bitcoin no mercado monetário. Revista de Administração e Negócios da Amazônia, v. 13, n. 3, p. 25-44, 2021.

EDWARDS, Robert D.; MAGEE, John; BASSETTI, WH Charles. Technical analysis of stock trends. CRC press, 2018.

ELBAHRAWY, Abeer et al. Dinâmica evolutiva do mercado de criptomoedas. Ciência aberta da Royal Society , v. 4, n. 11, pág. 170623, 2017.

FANG, Fan et al. Cryptocurrency trading: a comprehensive survey. Financial Innovation, v. 8, n. 1, p. 1-59, 2022.

FURLAN, Mateus Felipe Larrosa; IGARASHI, Wagner; IGARASHI, Deisy Cristina Corrêa. SIMULAÇÃO DE DUAS TÉCNICAS DE PREDIÇÃO PARA NEGOCIAÇÃO DE CRIPTOMOEDAS. Revista ADMPG, v. 12, n. 1, 2022.

HENRIQUE, Bruno Miranda; SOBREIRO, Vinicius Amorim; KIMURA, Herbert. Literature review: Machine learning techniques applied to financial market prediction. Expert Systems with Applications, v. 124, p. 26-251, 2019.

KARAKOSTAS, Dimitris et al. Cryptocurrency egalitarianism: a quantitative approach. arXiv preprint arXiv:1907.02434, 2019.

KATSIAMPA, P. Volatility estimation for Bitcoin: A comparison of GARCH models. Economics Letters, v. 174, p. 110-114, 2019.

KRAMER, Oliver; KRAMER, Oliver. Genetic algorithms. Springer International Publishing, 2017.

MAURI, Geraldo Regis. Novas abordagens para representação e obtenção de limitantes e soluções para alguns problemas de otimização combinatória. São José dos Campos–SP, 2008.

MBA, Jules Clement; PINDZA, Edson; KOUMBA, Ur. A differential evolution copula-based approach for a multi-period cryptocurrency portfolio optimization. Financial Markets and Portfolio Management, v. 32, p. 399-418, 2018.

MEREDIZ-SOLÀ, Ignasi; BARIVIERA, Aurelio F. Uma análise bibliométrica da produção científica do bitcoin. Pesquisa em Negócios e Finanças Internacionais , v. 50, p. 294-305, 2019.

MOSTEANU, Narcisa Roxana; FACCIA, Alessio. Digital systems and new challenges of financial management–FinTech, XBRL, blockchain and cryptocurrencies. Quality-Access to Success Journal, v. 21, n. 174, p. 159-166, 2020.

NOGUEIRA, Rodrigo Tavares; DE PAULA JR, Geraldo Galdino; PÓVOA, Carlos Leonardo Ramos. Uma heurística GRASP para o problema do pequeno investidor. 2006.

OYEDELE, Azeez A. et al. Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction. *Expert Systems with Applications*, v. 213, p. 119233, 2023.

PAVAN, Gabriel et al. ALGORITMOS GENÉTICOS PARA OTIMIZAÇÃO DE PORTFÓLIO DE INVESTIMENTO. 2021.

PILBEAM, Keith. Finance and financial markets. Bloomsbury Publishing, 2018.

PIZZETTI, Félix Vendramini. A volatilidade das criptomoedas: um estudo com utilização de modelos GARCH. 2019.

POUTZIOURIS, P.; MICHAILIDIS, A.; VINOGRADOV, G. Blockchain and Cryptocurrency: Implications for the Global Entrepreneurial Ecosystem. *Small Business Economics*, v. 54, p. 1-18, 2020.

REKIEK, Brahim; DELCHAMBRE, Alain; SALEH, Hussain Aziz. Handicapped person transportation: An application of the grouping genetic algorithm. *Engineering Applications of Artificial Intelligence*, v. 19, n. 5, p. 511-520, 2006.

SANTOS, Álvaro Roberto Cavalcante. Estudo de viabilidade do RSI em transações automatizadas. 2018.

SCHAUPP, Ludwig Christian; FESTA, Mackenzie. Cryptocurrency adoption and the road to regulation. In: *Proceedings of the 19th Annual International Conference on Digital Government Research: Governance in the Data Age*. 2018. p. 1-9.

SHAH, Agam; CHAUHAN, Yagnesh; CHAUDHURY, Bhaskar. Construção baseada em análise de componentes principais e avaliação de índices de criptomoedas. *Sistemas Especialistas com Aplicações*, v. 163, p. 113796, 2021.

SILVA, Victor Ferreira Teixeira da; OCHI, Luiz Satoru; COELHO, Igor Machado. APLICAÇÃO DE ALGORITMOS DE OTIMIZAÇÃO EVOLUCIONÁRIA PARA TRADING DE CRIPTOMOEDAS. SBPO, 2022.

SILVA, Victor Ferreira Teixeira da. Trade Optimizer: operando no mercado de criptoativos com BRKGA, 2022.

URQUHART, A. The inefficiency of Bitcoin revisited: A dynamic approach. *Economics Letters*, v. 167, p. 18-22, 2018.

YERMACK, D. Is Bitcoin a Real Currency? An Economic Appraisal. NBER Working Paper, n. 19747, 2015. Disponível em: <https://www.nber.org/papers/w19747>. Acesso em: 02 maio 2023.

YIYING, Wang; YEZE, Zang. Cryptocurrency price analysis with artificial intelligence. In: *2019 5th International Conference on Information Management (ICIM)*. IEEE, 2019. p. 97-101.