

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO
FACULDADE DE GESTÃO E NEGÓCIOS

KAMYR GOMES DE SOUZA

RESISTÊNCIAS, LIMITES E POTENCIAL DOS CRIPTOATIVOS EM PORTFÓLIOS DE
INVESTIMENTOS: A REGIONALIDADE IMPORTA?

UBERLÂNDIA
2023

Kamyr Gomes de Souza

**Resistências, Limites e Potencial dos Criptoativos em Portfólios de Investimentos: A
Regionalidade importa?**

Projeto de Tese apresentado ao Programa de Pós-Graduação em Administração da Faculdade de Gestão e Negócios da Universidade Federal de Uberlândia requisito parcial para conclusão do Curso de Doutorado em Administração.

Orientador: Flávio Luiz de Moraes Barboza

Coorientador: José Augusto Fiorucci

Uberlândia
2023

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

S729r
2023 Souza, Kamyrr Gomes de, 1988-
Resistências, limites e potencial dos criptoativos em portfólios de investimentos [recurso eletrônico] : a regionalidade importa? / Kamyrr Gomes de Souza. - 2023.

Orientador: Flávio Luiz de Moraes Barboza.

Coorientador: José Augusto Fiorucci.

Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de Pós-graduação em Administração.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.te.2024.5080>

Inclui bibliografia.

Inclui ilustrações.

1. Administração. I. Barboza, Flávio Luiz de Moraes, 1980-, (Orient.). II. Fiorucci, José Augusto, 1986-, (Coorient.). III. Universidade Federal de Uberlândia. Programa de Pós-graduação em Administração. IV. Título.

CDU: 658

André Carlos Francisco
Bibliotecário Documentalista - CRB-6/3408

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA****Coordenação do Programa de Pós-Graduação em Administração**

Av. João Naves de Ávila, 2121, Bloco 5M, Sala 109 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902

Telefone: (34) 3239-4525 - www.fagen.ufu.br - ppgaadm@fagen.ufu.br

**ATA DE DEFESA - PÓS-GRADUAÇÃO**

Programa de Pós-Graduação em:	Administração				
Defesa de:	Tese de Doutorado Acadêmico, número 13, PPGADM				
Data:	01 de dezembro de 2023	Hora de início:	09:00	Hora de encerramento:	11:00
Matrícula do Discente:	11923ADM006				
Nome do Discente:	Kamyr Gomes de Souza				
Título do Trabalho:	Resistências, Limites e Potencial dos Criptoativos em Portfólios de Investimentos: A Regionalidade importa?				
Área de concentração:	Regionalidade e Gestão				
Linha de pesquisa:	Gestão Organizacional e Regionalidade				
Projeto de Pesquisa de vinculação:					

Reuniu-se na webconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Administração, assim composta: Prof. Dr. Antonio Sergio Torres Penedo (PPGAdm/UFU), Profª Drª. Luciana Carvalho (PPGAdm/UFU), Prof. Dr. Geraldo Nunes Silva (PPGMAT/UNESP), Prof. Dr. Eli Hadad Junior (PPGA/UPM) e Prof. Dr. Flavio Luiz de Moraes Barboza (PPGAdm/UFU), orientador da candidata.

Iniciando os trabalhos o presidente da mesa, Prof. Dr. Flavio Luiz de Moraes Barboza, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu à Discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir a candidata. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando a candidata:

Aprovada

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Flávio Luiz de Moraes Barboza, Professor(a) do Magistério Superior**, em 01/12/2023, às 11:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Antônio Sérgio Torres Penedo, Professor(a) do Magistério Superior**, em 01/12/2023, às 11:16, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luciana Carvalho, Professor(a) do Magistério Superior**, em 01/12/2023, às 11:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **GERALDO NUNES SILVA, Usuário Externo**, em 01/12/2023, às 15:24, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Eli Hadad Junior, Usuário Externo**, em 14/12/2023, às 09:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4995094** e o código CRC **C4043565**.

*Este trabalho é dedicado ao Killian,
o filho de minha maturidade,
por cujo nascimento esta pós-graduação esperou.*

Agradecimentos

Neste caminho desafiador e enriquecedor que foi a elaboração desta tese, muitas foram as mãos estendidas, os corações abertos e as mentes brilhantes que me acompanharam. Com imensa gratidão, dedico estas palavras a cada um deles.

Primeiramente, expresso minha profunda gratidão ao meu orientador, Flávio Barboza, cuja orientação e apoio foram decisivos para virar a chave do "impossível" para o "possível" nos momentos mais críticos. Sua disponibilidade, empenho, humildade e sabedoria simples transformaram desafios complexos em soluções viáveis. Mais que tudo, sou grata pelo seu exemplo, que me inspira a cada dia.

Um agradecimento especial ao meu coorientador, José Augusto Fiorucci, por sua disponibilidade nas longas reuniões online que tanto contribuíram para o avanço deste trabalho, além de ter compartilhado recursos valiosos para a execução da pesquisa.

À professora Kárem Cristina, referência na academia e em Finanças, minha primeira orientadora no PPGA, agradeço por ter acreditado no meu potencial e me incentivado a alçar os voos mais altos. Suas orientações foram valiosas, mesmo que eu não tenha conseguido aproveitar tanto quanto gostaria na época por estar em um outro momento.

Aos membros da banca de qualificação e defesa, em especial ao professor Penedo, agradeço pelas críticas e contribuições fundamentais para o resultado final deste trabalho.

À professora Carla, sou grata pelas avaliações e sugestões de aprimoramento que enriqueceram significativamente meu ensaio teórico.

Aos meus colegas, Thayla e Duterval, agradeço por terem me distinguido com sua amizade e companheirismo, trazendo um novo significado às viagens, aos encontros presenciais, ao espaço de convivência e ao próprio processo de doutoramento. Com Thayla, compartilhei noites em claro, desafios em comum, a recém-maternidade afinidades e um afeto fraternal. Com Duterval, exemplo vivo de fé, resiliência e sabedoria, aprendi sobre o respeito, os valores intrínsecos, a amizade não intrusiva e liderança. Em sua pessoa, estendo meu agradecimento a todos os nossos parceiros e colegas da TrendPrix, *startup* que foi parte crucial do meu processo de doutoramento e, porque não dizer, do fortalecimento do meu propósito de pesquisar nessa área.

Um reconhecimento especial à Juliana, nossa fada-madrinha na secretaria do PPGA, que nos auxiliou em todos os aspectos burocráticos e práticos, sempre com uma palavra amiga e uma porta aberta para estudantes sem sala.

À professora Cíntia, que desde os tempos de graduação me apresentou ao fascinante campo das Teorias em Administração, expandindo minha visão para horizontes antes indecifráveis. E ao professor Valdir, cujos ensinamentos foram cruciais para minha formação como pesquisadora.

À minha chefe Rosana e a todos os colegas do ICENP, agradeço por sua paciência, compreensão e solidariedade durante esse longo período.

A minha família, um pilar de força e amor: meus filhos, Dion e Killian, que orvalharam de felicidade e trouxeram cor aos dias plúmbeos e motivação de seguir adiante e vencer essa etapa; e ao meu marido, Samuel, por sua presença, dedicação e amor manifestado em cada gesto diário, cuidando de nossa família e oferecendo o suporte indispensável para a conclusão desta jornada.

Ao meu Pai, Olival (*in memoriam*), a a minha mãe, Neyde Maria, agradeço pela minha vida, pelos ensinamentos e experiências que me ajudaram a construir quem sou hoje.

Ao meu irmãos Flander e Adler (*in memoriam*), agradeço pela oportunidade de ter convivido consigo e aprender sobre o amor fraternal. Onde estiverem, envio a minha saudade e Paz!

À minha irmã Laener, agradeço por me receber no seio de sua família e ser a amiga de todas as horas.

Aos meus sogros, Sérgio e Cândida Marta, e aos tios Osvaldo e Marilda, sou grata por seu acolhimento e apoio incondicional.

A cada um de vocês, minha gratidão e o júbilo pelos laços que se formaram – iniciaram ou consolidaram!

*O homem criativo não é um homem comum ao qual se acrescentou algo.
Criativo é o homem comum do qual nada se tirou.*
(Abraham Maslow)

Resumo

Contextualização: A tecnologia Blockchain e as criptomoedas descortinaram um universo de possibilidades nos mais distintos campos de atuação, incluindo o das Finanças, com aplicação em serviços de pagamentos, empréstimos, captação e transferência de recursos, além de ampliarem as opções de investimento de investidores individuais e institucionais ao serem reconhecidas como uma nova classe de ativos. No contexto de investimentos, a gestão de portfólios de criptomoedas tem como desafio sua elevada volatilidade intrínseca, exigindo abordagens inovadoras de gestão de risco. O emprego de modelos autoregressivos, com foco na previsão de volatilidade futura, e de modelos de aprendizado de máquina com redes neurais profundas mostra potencial para revolucionar a abordagem de investimentos em criptoativos, permitindo uma adaptação mais dinâmica e estratégica às rápidas mudanças do mercado para estratégias de investimento mais informadas e robustas.

Objetivo: Investigar o potencial e a efetividade de estratégias avançadas de gestão de portfólios compostos por criptomoedas e suas implicações em nível regional.

Método: O primeiro estudo faz uma revisão sistemática de literatura com foco em gestão de risco, utilização em portfólios e eficiência de mercado. A seguir, o segundo estudo estima a volatilidade futura de um portfólio de criptomoedas usando DCC-GARCH e testa a estratégia automatizada de negociação *Reaction Trend System* – RTS de Fiorucci, Silva, e Barboza (2022a) para um conjunto de criptomoedas previamente selecionadas que atendam aos critérios requeridos pelos modelos de estimação. Para avaliar a eficácia da estratégia, esta foi comparada com a estratégia passiva *buy and hold* para o mesmo conjunto de criptomoedas. Finalmente, o terceiro estudo utiliza uma abordagem de aprendizado por reforço profundo para a seleção e otimização dinâmica de portfólios. Foram testados os algoritmos *Proximal Policy Optimization*, *Deep Deterministic Policy Gradient* e *Soft Actor-Critic* SAC em criptomoedas com dados disponíveis.

Resultados: No artigo 1, a revisão sistemática de literatura identificou lacunas significativas na literatura sobre a gestão de risco e eficiência de mercado das criptomoedas, destacando a necessidade de abordagens inovadoras para a seleção e otimização de portfólios. A partir do teste de estratégias automatizadas em criptomoedas, o artigo 2 demonstrou que a estratégia baseada no *Reaction Trend System* (RTS) aliada à previsão de volatilidade futura DCC-GARCH foi eficaz para criptomoedas, superando estratégias passivas e abordagens tradicionais em termos de retorno ajustado ao risco. No entanto, a estratégia requer ajustes cuidadosos para cada ativo devido à sua sensibilidade às configurações. Finalmente, no artigo 3, os modelos de DRL, especialmente *Soft Actor-Critic* (SAC) e *Deep Deterministic Policy Gradient* (DDPG), apresentaram potencial para otimizar gestão de portfólios de criptomoedas e melhorar os retornos em comparação com estratégias clássicas, especialmente em portfólios compostos por ativos menores ou menos líquidos. Esses resultados fortalecem a tese de que as criptomoedas, quando geridas com técnicas avançadas de modelagem e

aprendizado de máquina, podem compor portfólios de investimento eficientes, contribuindo para a inovação na gestão de ativos financeiros.

Aderência da pesquisa com a área de concentração do PPGAdm (Regionalidade e Gestão) e com a linha de pesquisa: A pesquisa aborda o tema das criptomoedas, que são ativos digitais globais. No entanto, a adoção, regulamentação e impacto das criptomoedas podem variar significativamente de uma região para outra. Ao estudar as criptomoedas, a pesquisa pode contribuir para uma melhor compreensão de como esses ativos digitais estão sendo adotados e gerenciados em diferentes regiões. Além disso, a pesquisa envolve o uso de técnicas avançadas de *Machine Learning* para otimizar carteiras de investimento em criptomoedas. Isso se alinha diretamente com o tema da gestão, pois envolve a tomada de decisões estratégicas sobre como alocar recursos em um portfólio de investimentos. A pesquisa pode ter implicações para as organizações em termos de como elas gerenciam seus investimentos em criptomoedas, levando em consideração fatores regionais específicos, como regulamentações locais e condições de mercado. Portanto, embora a pesquisa seja altamente técnica e focada em um tipo específico de ativo digital, ela se encaixa bem na área de concentração do PPGAdm e na linha de pesquisa “Gestão Organizacional e Regionalidade”.

Impacto e caráter inovador na produção intelectual: A pesquisa contribui para a literatura existente sobre otimização de carteiras de investimento e *Machine Learning*, introduzindo o uso de *Deep Reinforcement Learning* (DRL) na gestão de carteiras de criptomoedas. Isso representa uma abordagem inovadora que pode abrir novas possibilidades para a pesquisa futura. Além disso, a pesquisa também destaca a importância de considerar os custos de transação, o que pode ter implicações significativas para a eficácia dos modelos de DRL.

Impacto econômico, social e regional: A pesquisa tem o potencial de influenciar a forma como as organizações e os indivíduos gerenciam seus investimentos em criptomoedas. Isso pode ter implicações econômicas significativas, dado o crescimento rápido e a volatilidade do mercado de criptomoedas. Além disso, ao considerar as diferenças regionais na adoção e regulamentação das criptomoedas, a pesquisa também pode contribuir para uma melhor compreensão dos impactos sociais e regionais desses ativos digitais. Por exemplo, em regiões onde as criptomoedas são amplamente adotadas, os *insights* da pesquisa podem ser particularmente relevantes.

Implicações regionais: A expectativa é que os resultados promovam melhoria de eficiência tanto na estimativa da volatilidade como na gestão de carteiras formadas por criptomoedas.

Objetivos de Desenvolvimento Sustentável atendidos na pesquisa: Considerando a Agenda 2030 da ONU, os Objetivos de Desenvolvimento Sustentável (ODS) e as metas atendidas pela pesquisa, a presente tese alinha-se com vários ODS, incluindo principalmente o 8, 9 e 10. ODS 8 (Trabalho decente e crescimento econômico) – Ao investigar a utilização de tecnologias avançadas para a gestão de risco e otimização de portfólios de investimento em criptomoedas, a pesquisa pode promover crescimento econômico sustentável e oferecer formas mais eficientes de investimento no mercado financeiro. ODS 9 (Indústria, inovação e infraestrutura) – por meio do desenvolvimento

de tecnologias avançadas e ferramentas automatizadas para a gestão de portfólios de criptomoedas, a pesquisa fomenta a inovação no setor financeiro, incentivando práticas de investimento mais eficientes e sustentáveis. ODS 10 (Redução das desigualdades) – ao democratizar o acesso esclarecido a metodologias inovadoras de gestão de portfólios de investimentos em criptoativos, contribui para a redução das desigualdades de acesso ao mercado financeiro.

Palavras-chaves: Criptomoedas. Portfólios. Gestão de Risco. Volatilidade. DCC-GARCH. *Deep Learning*.

Lista de ilustrações

Figura 1 – Etapas da metodologia Methodi Ordinatio. Fonte: Pagani et al. (2017).	52
Figura 2 – Volume de artigos por ano	57
Figura 3 – Relevância dos periódicos do portfólio bibliográfico, por volume de artigos e por ano.	57
Figura 4 – Desempenho dos Ativos Individuais a partir de um Investimento Inicial de \$1000	87
Figura 5 – Desempenho histórico das estratégias	88
Figura 6 – Evolução dos retornos das criptomoedas da amostra	108
Figura 7 – All CC and All CC-tc	110
Figura 8 – Large MC and Large MC-tc	112
Figura 9 – Small MC and Small MC-tc	114
Figura 10 – Low-liquid and Low-liquid-tc	117

Lista de tabelas

Tabela 1 – Termos-chave para pesquisa	53
Tabela 2 – Critérios de inclusão e exclusão para aplicação dos testes de relevância	53
Tabela 3 – Resultados da busca	54
Tabela 4 – Sistema de classificação e códigos utilizados	55
Tabela 5 – Resumo de resultados por classificação e categoria de estudo	58
Tabela 6 – Classificação dos artigos com foco na eficiência de mercado.	59
Tabela 7 – Classificação dos artigos com foco em gestão de risco.	60
Tabela 8 – Classificação dos artigos com foco na seleção de portfólios	61
Tabela 9 – Classificação dos artigos com foco na otimização de portfólios	62
Tabela 10 – Avaliação dos estudos presentes no revisão em três dimensões: foco, ferramentas metodológicas utilizadas e economia da região estudada	64
Tabela 11 – Desempenho de Negociações usando a estratégia RTS-Garch por Ativo, com bandas C_Trend = 0,90 e C_Reaction = 0,50. Parâmetros: Operar Reaction (True), Uso de BOS (False), Mover Stop Reaction (True), Mover Stop Contrário (True), Mover Take Profit Reaction (False)	84
Tabela 12 – Desempenho de Negociações usando a estratégia RTS-Garch por Ativo, com bandas C_Trend = 0,90 e C_Reaction = 0,50. Configurações: Operar Reaction (True), Uso de BOS (False), Mover Stop Reaction (True), Mover Stop Contrário (True), Mover Take Profit Reaction (True)	84
Tabela 13 – Valores finais dos ativos por estratégia	87
Tabela 14 – Métricas de desempenho das estratégias / carteiras	88
Tabela 15 – Comparação de Algoritmos de Aprendizado por Reforço.	100
Tabela 16 – Criptomoedas da amostra, com Market Cap Ranking (Rnk), Score de Desenvolvimento (Dev), Score de liquidez (Liq), e data de início (Start)	102
Tabela 17 – Estatísticas Descritivas dos Retornos das Criptomoedas	107
Tabela 18 – Performance dos portfólios contendo as 27 criptomoedas da amostra (grupo all_CC.)	109
Tabela 19 – Pesos dos portfólios contendo as 27 criptomoedas da amostra (grupo all_CC.)	111
Tabela 20 – Estatísticas Z-score do teste LW comparando os Índices Sharpe em carteiras com custos de transação (acima da diagonal) e carteiras sem custos (abaixo da diagonal) para o portfólio all_CC.	111
Tabela 21 – Performance dos portfólios contendo as criptomoedas acima da média de Market Cap da amostra (grupo MC-large).	113
Tabela 22 – Pesos dos portfólios contendo as criptomoedas da amostra (grupo MC-large.)	113

Tabela 23 – Performance dos portfólios contendo as criptomoedas abaixo da média de Market Cap da amostra (Grupo MC-small)	115
Tabela 24 – Pesos dos portfólios contendo as criptomoedas da amostra (grupo MC-small.) .	115
Tabela 25 – Estatísticas Z-score do teste LW comparando os Índices Sharpe em carteiras com custos de transação (acima da diagonal) e carteiras sem custos (abaixo da diagonal) em portfólios separados por Market Cap.	116
Tabela 26 – Performance dos portfólios contendo as criptomoedas abaixo da média de Volume da amostra (Grupo VOL_low_liquidCC)	116
Tabela 27 – Pesos dos portfólios contendo as criptomoedas da amostra (grupo low_liquidCC.)	118
Tabela 28 – Estatísticas Z-score do teste LW comparando os Índices Sharpe em carteiras com custos de transação (acima da diagonal) e carteiras sem custos (abaixo da diagonal) para o portfólio low_liquidCC.	118

Lista de abreviaturas e siglas

AMH	Adaptive Market Hypothesis (Hipótese de Mercado Adaptativo)
CVaR	Conditional Value-at-Risk
DDPG	Deep Deterministic Policy Gradient
DRL	Deep Reinforcement Learning
EMH	Efficient Market Hypothesis (Hipótese de Mercado Eficiente)
ES	Expected Shortfall
EVT	Teoria do Valor Extremo
FMH	Fractal Market Hypothesis (Hipótese de MercadoS Fractais)
HMM	Hidden Markov Model
MTP	Moderna Teoria de Portfólio
MV	Modelo de Média-variância
PCA	Principal component analysis (Análise de Componentes Principais)
PPO	Proximal Policy Optimization
RL	Reinforcement Learning
VaR	Value-at-Risk

Sumário

1	INTRODUÇÃO GERAL	27
1.1	Contextualização do tema de pesquisa	27
1.2	Objetivos e problemas de pesquisa	28
1.3	Relevância do estudo	28
1.3.1	<i>Contribuição teórica</i>	28
1.3.2	<i>Contribuição prática/empírica</i>	29
1.3.3	<i>Contribuição social</i>	29
1.3.4	<i>Contribuição regional</i>	30
1.4	Estrutura do trabalho	30
2	UMA ESTRUTURA TEÓRICA ABRANGENTE PARA TRATAR DE PORT- FÓLIOS DE CRIPTOATIVOS	33
2.1	Fundamentos da Teoria de Carteiras	33
2.1.1	<i>Teoria Moderna de Carteiras de Markowitz</i>	33
2.1.2	<i>Hipóteses de Mercados Eficientes, Adaptativos e Fractais</i>	34
2.1.3	<i>Teoria do trade-off Risco-Retorno</i>	36
2.1.4	<i>Teoria dos Limites à Arbitragem</i>	37
2.2	Gestão de Risco no contexto dos criptoativos	37
2.2.1	<i>Teoria do Valor Extremo (EVT)</i>	38
2.2.2	<i>Teoria dos Prospectos Cumulativos (CPT)</i>	39
2.2.3	<i>Teoria do Investimento Racional</i>	39
2.2.4	<i>Métricas de Risco</i>	40
2.2.5	<i>Modelagem e Previsão de Volatilidade</i>	41
2.3	Gestão de Carteiras de Criptoativos	43
2.3.1	<i>Estratégias de Negociação de Criptoativos</i>	43
2.3.2	<i>Seleção e Classificação de Criptoativos</i>	44
2.3.3	<i>Otimização de Carteira, Backtesting e Rebalanceamento</i>	45
3	GESTÃO DE PORTFÓLIOS DE CRIPTOATIVOS: UMA REVISÃO SIS- TEMÁTICA DA LITERATURA	49
3.1	Introdução	49
3.2	Procedimentos para a Revisão Sistemática de Literatura	51
3.2.1	<i>Delimitações da pesquisa e procedimentos de seleção do portfólio</i>	52

3.2.2	<i>Coleta e filtragem da base de dados</i>	53
3.3	Análise da Literatura	56
4	DESEMPENHO DE UM SISTEMA DE NEGOCIAÇÃO AUTOMATIZADO PARA CRIPTOMOEDAS: COMPARANDO ESTRATÉGIAS COM O USO DE ESTIMADOR AUTOREGRESSIVO DE VOLATILIDADE	71
4.1	Introdução	71
4.2	Referencial teórico	73
4.2.1	<i>Teoria de carteiras e gestão de risco no campo dos criptoativos</i>	73
4.2.2	<i>Estado da arte sobre o gerenciamento de portfólios de criptomoedas</i>	76
4.3	Procedimentos metodológicos	77
4.3.1	<i>Amostra da pesquisa e dados coletados</i>	78
4.3.2	<i>DCC-GARCH</i>	78
4.3.3	<i>Estratégias de gerenciamento do investimento</i>	80
4.3.4	<i>Softwares e pacotes utilizados</i>	82
4.3.5	<i>Análise de performance</i>	83
4.4	Resultados	83
4.4.1	<i>A estratégia</i>	83
4.4.2	<i>A carteira</i>	86
4.5	Conclusões	89
5	UMA ABORDAGEM DE APRENDIZADO PROFUNDO PARA A SELEÇÃO E OTIMIZAÇÃO DINÂMICA DE PORTFÓLIOS	95
5.1	Introdução	95
5.1.1	<i>Contextualização</i>	95
5.1.2	<i>Problema de Pesquisa e Objetivos</i>	96
5.1.3	<i>Justificativa e Contribuições</i>	97
5.2	Revisão teórica	99
5.3	Procedimentos Metodológicos	101
5.3.1	<i>Dados e Seleção de Criptoativos</i>	101
5.3.2	<i>Implementação dos Modelos DRL</i>	103
5.4	Resultados	106
5.4.1	<i>Desempenho dos modelos para o conjunto completo - All CC</i>	108
5.4.2	<i>MC-large</i>	112
5.4.3	<i>MC-small</i>	113
5.4.4	<i>Vol-low-liquid</i>	115
5.5	Discussão e Conclusões	117

6	CONCLUSÕES GERAIS	123
	Referências	125

APÊNDICES	141
------------------	------------

APÊNDICE A – RESULTADO FINAL DA SELEÇÃO DE ARTIGOS APÓS A APLICAÇÃO DA ETAPA 7 DA METHODI ORDINATIO	143
--	------------

Introdução Geral

1 Introdução Geral

1.1 Contextualização do tema de pesquisa

O *boom* do mercado de criptomoedas gerou euforia, intensa especulação no mercado financeiro, e muito interesse na academia (Raimundo Junior, 2022). As criptomoedas se tornaram um fenômeno global nos setores financeiros, como um dos instrumentos financeiros mais negociados em todo o mundo (Chowdhury, Rahman, Rahman, & Mahdy, 2020).

Assim, as criptomoedas têm ganhado destaque no campo das Finanças como uma nova classe de ativos, conforme evidenciado por vários estudos (Fang et al., 2022; W. Liu, Liang, & Cui, 2020; Bedi & Nashier, 2020). Elas têm atraído a atenção de investidores por diversas razões, incluindo seu potencial para diversificação de carteira de investimentos (X. Huang et al., 2022; Akhtaruzzaman, Sensoy, & Corbet, 2020; Charfeddine, Benlagha, & Maouchi, 2020), sua capacidade de atuar como instrumento de *hedge* (Dyhrberg, 2016; Selmi, Mensi, Hammoudeh, & Bouoiyour, 2018; Aysan, Demir, Gozgor, & Lau, 2019; Naeem, Farid, Balli, & Hussain Shahzad, 2020; Al-Yahyaee, Mensi, Al-Jarrah, Hamdi, & Kang, 2019) e, principalmente, pelos expressivos retornos no curto prazo que podem ser alcançados por sua natureza volátil (Fang et al., 2022) e não regulamentada (Khan & Augustine, 2019). A primeira delas, o Bitcoin, acrescenta a estas uma característica deflacionária por possuir uma oferta limitada e demanda com tendência crescente devido ao efeito de rede (Menger, 1892; Yoo, Bae, Park, & Yang, 2019).

Desde o surgimento do Bitcoin, as criptomoedas cresceram significativamente, não apenas em termos de capitalização, com seu valor de mercado ultrapassando o pico de superior a US\$ 1 trilhão em 2021, em um mercado global avaliado em aproximadamente US\$ 2,6 trilhões no mesmo período, segundo Maghsoodi (2023). A quantidade desse ativos é outro aspecto impressionante, tendo atingido o patamar de 23 mil criptoativos, como divulgado constantemente (e atualizado em tempo real) pela plataforma CoinMarketCap (CoinMarketCap, 2023). Para se ter uma ideia, há 5 anos existiam 2 mil ativos com valor de mercado em torno de US\$ 130 bilhões (Omane-Adjepong & Alagidede, 2020), demonstrando um crescimento significativo em todos os quesitos. A liquidez desse mercado é outro destaque. Seu recorde ocorreu em 28 de fevereiro de 2021, com um volume diário de quase US\$ 141 bilhões, ante US\$ 14 bilhões no último dia de 2018.

Constata-se um movimento imparável e disruptivo, que veio para mudar o mundo financeiro como hoje é concebido, manifestando-se, inclusive, uma tendência de que os ativos tradicionais passem também pelo processo de tokenização, modernizando-os à realidade da WEB-3.

Consequentemente, esse mercado mostra-se uma arena propícia para vários agentes, pois oferece diversas oportunidades (Lorenzo & Arroyo, 2022). Por outro lado, as criptomoedas não são apenas um dos campos mais complicados e obscuros entre os instrumentos financeiros, mas

também considerada um problema desconcertante nas Finanças devido à sua alta volatilidade (Chowdhury et al., 2020).

Esta tese traz como objeto de pesquisa as criptomoedas e ativos tokenizados no campo das Finanças, mas particularmente como instrumentos de investimento. Nesse sentido, a tese a ser defendida no presente estudo é que os criptoativos são um instrumento viável para compor portfólios de investimento eficientes, segundo a Teoria Moderna do Portfólio, tanto de investidores individuais quanto institucionais.

1.2 Objetivos e problemas de pesquisa

O problema a ser tratado nos estudos a seguir é o seguinte: Qual o potencial, a efetividade e as implicações regionais de estratégias avançadas de gestão de portfólios de investimento compostos por criptomoedas?

A partir dele, o objetivo geral desta tese foi delimitado como: Investigar o potencial e a efetividade de estratégias avançadas de gestão de portfólios compostos por criptomoedas e suas implicações em nível regional.

E os objetivos específicos a serem refinados para a elaboração desta tese são os seguintes: (1) Reunir e sistematizar as pesquisas mais relevantes da área de Finanças já publicadas sobre criptomoedas com foco em gestão de risco, utilização em portfólios e eficiência de mercado. (2) Modelar a volatilidade das criptomoedas e testar uma estratégia automatizada para um portfólio de criptomoedas. (3) Verificar a efetividade e o desempenho de abordagens de *Deep Reinforcement Learning* em portfólios de investimento composto por criptomoedas.

Cada objetivo específico será contemplado em um dos próximos capítulos da tese.

1.3 Relevância do estudo

Este trabalho pretende contribuir para a literatura sobre criptoativos de diversas maneiras.

1.3.1 Contribuição teórica

Como contribuição teórica, o presente estudo pretende avançar na aplicação da teoria de portfólios em mercados de alta volatilidade a partir da implementação de um estimador de volatilidade futura para substituir a média-variância clássica de Markovitz, aplicando e testando o modelo desenvolvido por Fiorucci, Silva, e Barboza (2022b) em um mercado diferente e ainda pouco conhecido, como o das criptomoedas.

1.3.2 Contribuição prática/empírica

Para a prática, o estudo contribuirá ao promover um sistema automatizado e multi-objetivos de seleção, otimização e rebalanceamento de carteiras de criptomoedas, além de agregar um algoritmo aprimorado de alto desempenho como estimador de volatilidade futura, mais adequado para tratar o problema do que um indicador que apenas espelha uma performance já ocorrida (Burggraf, 2021). Além disso, Kyriazis (2021b) ressalta que momentos de incerteza na política comercial aumentam a demanda e favorecem os investimentos em ativos de risco, a fim de melhorar a relação risco-retorno nas carteiras.

A contribuição prática/empírica deste estudo reside na aplicação de metodologias avançadas para o desenvolvimento de um estimador de volatilidade futura no contexto de criptomoedas. Esse estimador pode oferecer perspectivas valiosas para investidores e gestores de fundos, ao proporcionar uma compreensão mais precisa da volatilidade dos ativos digitais e permitir uma alocação mais eficiente dos recursos em seus portfólios. Com a utilização dessas técnicas inovadoras, o estudo busca melhorar a qualidade das decisões de investimento e, consequentemente, o desempenho das carteiras de criptomoedas.

Além disso, esta pesquisa também pretende contribuir para o campo prático ao propor a implementação de uma ferramenta automatizada para otimização de carteiras de criptomoedas. Essa ferramenta, baseada em algoritmos de *deep learning* e conceitos de *robot advisors*, facilitará o processo de investimento, permitindo que os usuários selecionem o nível de risco desejado e obtenham recomendações personalizadas para a composição de suas carteiras. A disponibilidade de uma ferramenta como essa pode simplificar a entrada de novos investidores no mercado de criptoativos, ao mesmo tempo em que oferece aos gestores de fundos e profissionais do setor uma solução eficiente e inovadora para otimizar a gestão de portfólios de criptomoedas.

1.3.3 Contribuição social

A contribuição social deste estudo reside, em primeiro lugar, na promoção da democratização e acesso a novas modalidades de investimento, como as criptomoedas. Ao propor um modelo otimizado de gestão de portfólios de criptomoedas, esta pesquisa contribuirá para tornar os investimentos em ativos digitais mais seguros e atraentes para um público mais amplo. A ampliação do leque de opções de investimento disponíveis pode levar a uma maior inclusão financeira, permitindo que mais indivíduos e instituições participem do mercado financeiro e diversifiquem suas carteiras a partir um ajuste de risco adequado para essa classe de ativos.

Para além de empresas e gestores de fundo de investimento, este estudo pode auxiliar também pequenos investidores que busquem se proteger da inflação e da perda de poder aquisitivo de seu patrimônio por meio do investimento em ativos deflacionários e/ou de crescimento. Além disso, a ferramenta algorítmica produto desta pesquisa será disponibilizada publicamente, trazendo

praticidade e condições mais adequadas para pequenos investidores terem a chance de lograr êxito em estratégias ativas de gestão.

1.3.4 Contribuição regional

Tal proposta, ao sistematizar e testar um protocolo aprimorado para a seleção e gestão de portfólios de criptomoedas, poderá contribuir regionalmente para que os gestores e investidores institucionais da nossa região obtenham resultados superiores ao lidar com uma classe de ativos voláteis capaz de melhorar o índice de Sharpe de suas carteiras (Susilo, Wahyudi, Pangestuti, Nugroho, & Robiyanto, 2020).

A contribuição regional deste estudo se justifica para a mesorregião do Triângulo Mineiro e Alto Paranaíba pelo próprio pioneirismo dessa região brasileira, que apresenta crescimento econômico consistente e por onde circula dinheiro de todas as partes do Brasil. O país tem vivenciado um aumento significativo no volume de investimentos em geral, e notadamente em interesse por investimentos alternativos como as criptomoedas. Nesse cenário, é plausível supor que esta tendência também se manifeste nesse território e que haja uma crescente demanda por serviços de investimento na região, particularmente por fundos de investimentos sofisticados e alternativos.

Assim, o desenvolvimento de um modelo otimizado de gestão de portfólios de criptomoe-
das, adotando metodologias GARCH avançadas e inteligência artificial, como proposto no presente estudo, pode proporcionar aos gestores de fundos de investimento locais um diferencial significativo na montagem de portfólios otimizados de criptomoedas, além de aprimorar a rentabilidade e reduzir os riscos inerentes aos investimentos em ativos digitais.

A ausência de fundos quantitativos na região do Triângulo Mineiro e Alto Paranaíba representa uma lacuna a ser preenchida, tendo em vista que tais fundos têm ganhado espaço em outras partes do mundo. A inclusão de um fundo quantitativo, que empregue as metodologias avançadas propostas nesta tese, representaria uma oportunidade única para a região, conjugando o pioneirismo econômico com a inovação no campo das Finanças. Dessa forma, a presente pesquisa pode contribuir significativamente para o desenvolvimento e diversificação dos serviços financeiros oferecidos na mesorregião, potencializando o crescimento econômico e a atração de investimentos, e pode representar uma oportunidade de inovação e pioneirismo para a área.

1.4 Estrutura do trabalho

Este trabalho está organizado da seguinte forma. O capítulo 2 traz um apanhado das teorias e conceitos abordados nesta tese. O capítulo 3 compreende o primeiro artigo da tese, no qual é apresentada uma revisão sistemática da literatura acerca das características financeiras das criptomoedas que fundamentam sua inserção em portfólios de investimentos. O capítulo 4 corresponde ao segundo artigo da tese, que testa uma estratégia automatizada para negociação de criptoativos

usando estimação de sua volatilidade esperada. O capítulo 5, referente ao terceiro artigo desta tese, utiliza uma abordagem de aprendizado profundo para a otimização dinâmica de portfólios. Finalmente, o capítulo 6 dará lugar às conclusões gerais desta tese.

2 Uma Estrutura Teórica Abrangente para tratar de Portfólios de Criptoativos

A natureza volátil e os riscos associados aos criptoativos tornam essencial o desenvolvimento de estratégias de gestão de carteira eficazes e abordagens teóricas sólidas. Nesta seção, serão relacionados os principais conceitos e teorias relacionados à gestão de carteiras no contexto dos criptoativos, a partir de revisão e adaptação dos fundamentos da teoria de carteiras para o universo dos criptoativos; descrição dos métodos de gestão de risco e avaliação de desempenho aplicáveis a carteiras de criptoativos; estratégias de negociação e seleção de criptoativos; e abordagens para otimização de carteiras.

2.1 Fundamentos da Teoria de Carteiras

2.1.1 Teoria Moderna de Carteiras de Markowitz

Uma carteira (ou portfólio) de investimentos pode ser caracterizada por posições em um certo número de ativos constituintes, expressos em uma moeda base (Jorion, 2011). A área de gerenciamento de portfólios é um dos domínios mais amplamente estudados na tomada de decisões financeiras, e está envolvida no projeto e gerenciamento de investimentos financeiros, geralmente constituídos por ativos do mercado de ações, bem como fundos, investimentos de renda fixa, moedas e commodities (Andriosopoulos, Doumpos, Pardalos, & Zopounidis, 2019).

A Teoria Moderna de Carteiras de Markowitz introduziu o conceito de fronteira eficiente, que representa o conjunto de carteiras que oferecem a combinação ótima de risco e retorno (Markowitz, 1952). A fronteira eficiente é uma ferramenta valiosa para a construção de carteiras de criptoativos, pois ajuda os investidores a identificar combinações de ativos que maximizam o retorno esperado para um determinado nível de risco, ou minimizam o risco para um retorno esperado específico. No entanto, a aplicação da fronteira eficiente no mercado de criptoativos pode ser desafiadora devido à volatilidade e correlações dinâmicas entre os ativos.

A Teoria Moderna de Carteiras de Markowitz enfatiza a importância da diversificação na gestão de riscos e na otimização da relação risco-retorno. Ao combinar criptoativos com diferentes características de risco e retorno, os investidores podem reduzir a volatilidade total da carteira e melhorar o desempenho ajustado ao risco. No entanto, a natureza emergente e a falta de histórico de preços de muitos criptoativos tornam a avaliação da relação risco-retorno mais complexa do que em outros mercados financeiros (Omane-Adjepong & Alagidede, 2020; G. M. Caporale & Zekokh, 2019).

A diversificação entre as criptomoedas é amplamente aceita na literatura como uma estratégia que pode melhorar significativamente os resultados dos investidores (W. Liu, 2019). Contudo,

existem limites para o benefício da diversificação dentro do mercado de criptomoedas, devido a quebras estruturais e ao fenômeno do "spillover" de volatilidade (Canh, Wongchoti, Thanh, & Thong, 2019). O *spillover* é um termo econômico que se refere à transferência de impacto de um mercado ou setor para outro. No contexto das criptomoedas, o *spillover* de volatilidade implica que uma alteração significativa na volatilidade de uma criptomoeda pode afetar a volatilidade de outras criptomoedas, limitando assim os benefícios da diversificação. Por outro lado, há relatos de transmissão unidirecional de volatilidade entre algumas criptomoedas, como por exemplo do Bitcoin para o Ethereum, com resposta atrasada, o que permite a obtenção de retornos anormais, já que os choques de volatilidade precisam de tempo para serem totalmente precificados (Beneki, Koulis, Kyriazis, & Papadamou, 2019).

De um modo geral, Wajdi, Nadia, e Ines (2020) recomendam carteiras diversificadas de criptomoedas, orientam os investidores a construir suas carteiras pela avaliação dos co-movimentos entre os ativos e, além disso, a ajustar os portfólios com frequência de acordo com o tipo de criptomoeda e as condições do mercado.

Embora a Teoria Moderna de Carteiras de Markowitz tenha sido revolucionária e continue sendo uma abordagem influente na construção de carteiras, ela enfrenta críticas e limitações, especialmente no contexto dos criptoativos. A teoria pressupõe que os investidores sejam avessos ao risco e que os retornos dos ativos sigam uma distribuição normal, o que nem sempre se aplica aos criptoativos devido à sua volatilidade e distribuição assimétrica de retornos. Além disso, a teoria não leva em conta a liquidez, os custos de transação e as restrições regulatórias que são particularmente relevantes no mercado de criptoativos. Essas questões e críticas devem ser examinadas ao aplicar a Teoria Moderna de Carteiras de Markowitz na construção de carteiras de criptoativos.

2.1.2 Hipóteses de Mercados Eficientes, Adaptativos e Fractais

A Hipótese do Mercado Eficiente (EMH) é um conceito fundamental na teoria financeira que afirma que os preços dos ativos refletem todas as informações disponíveis, tornando impossível obter retornos anormais de forma consistente por meio da negociação baseada em informações públicas. A EMH implica que os investidores não podem superar o mercado em média, pois todas as oportunidades de lucro são rapidamente aproveitadas (Fama, 1970). No entanto, os criptoativos apresentam um ambiente de mercado único, levantando questões sobre a aplicabilidade da EMH nesse contexto.

A Hipótese do Mercado Eficiente (EMH) afirma que os mercados financeiros são “informacionalmente eficientes”, de modo que não é possível obter retornos consistentemente superiores aos retornos médios do mercado, ajustados ao risco, com base nas informações disponíveis no momento do investimento (Khadjeh Nassirtoussi, Aghabozorgi, Ying Wah, & Ngo, 2014). A EMH, no entanto, não é absoluta e foi revisada por Fama (1970) para incluir três níveis de eficiência:

forte, semi-forte e fraco. A eficiência do mercado está correlacionada com a disponibilidade de informações e um mercado é considerado “fortemente eficiente” apenas quando todas as informações estão completamente disponíveis, o que raramente ocorre na realidade (Khadjeh Nassirtoussi et al., 2014). Estudos sobre a eficiência de criptomoedas, como Bitcoin e Ethereum, revelam que esses mercados apresentam ineficiências (Aslan & Sensoy, 2020; Y. Liu, Li, Nekhili, & Sultan, 2023; Lorenzo & Arroyo, 2023), oferecendo oportunidades de investimento para gerenciamento de carteiras com retornos superiores aos do mercado (Lorenzo & Arroyo, 2023).

Embora a EMH sugira que os preços devem seguir um passeio aleatório, estudos recentes mostram que a eficiência do mercado varia entre diferentes ativos e mercados (Aslan & Sensoy, 2020; Y. Liu et al., 2023). A maioria dos estudos fornece evidências de ineficiência nos mercados de criptomoedas (Aslan & Sensoy, 2020). Tais ineficiências permitem que algoritmos de aprendizado de máquina explorem oportunidades de investimento e gerem retornos superiores (Lorenzo & Arroyo, 2023). No entanto, os resultados dos testes de EMH podem ser inconsistentes, pois os preços devem seguir um passeio aleatório para que a análise funcione (Chaudhari & Crane, 2020). Além disso, os resultados mostram que as reações excessivas nos preços das criptomoedas não oferecem oportunidades de lucro disponíveis, possivelmente devido aos custos de transação, o que não pode ser considerado como evidência da EMH (Fang et al., 2022). Essas descobertas indicam que as criptomoedas se comportam mais como ativos convencionais e não são fracamente eficientes, já que variáveis, incluindo retornos anteriores, podem prever retornos futuros (Y. Liu et al., 2023).

Em contraste com a EMH, a Hipótese do Mercado Adaptativo (AMH) reconhece que os mercados podem não ser totalmente eficientes e que os investidores podem aprender e adaptar-se ao longo do tempo. A AMH surgiu como uma contrapartida à Hipótese do Mercado Eficiente (EMH) em uma tentativa de conciliar a EMH com a teoria de finanças comportamentais (Khadjeh Nassirtoussi et al., 2014). A AMH sugere que os mercados evoluem e se adaptam devido a eventos e mudanças estruturais, e a eficiência do mercado varia em graus diferentes em momentos distintos (Nkrumah-Boadu, Owusu Junior, Adam, & Asafo-Adjei, 2022). A pesquisa de Khuntia e Pattanayak (2018) fornece evidências de mercado adaptativo e eficiência evolutiva no mercado de Bitcoin, corroborando as reivindicações da AMH (Fang et al., 2022).

A AMH também é aplicada no estudo da interdependência entre criptomoedas e outros ativos, como ouro e ações (Nkrumah-Boadu et al., 2022). A técnica *biwavelet* é empregada em estudos que consideram a AMH e a Hipótese do Mercado Heterogêneo (HMH) (Nkrumah-Boadu et al., 2022). Essa abordagem ajuda a minimizar o ruído nos resultados e permite analisar as relações de liderança e defasagem entre os ativos em diferentes momentos e frequências (Nkrumah-Boadu et al., 2022). Ao examinar essas interdependências, os pesquisadores podem avaliar as propriedades de refúgio seguro, *hedge* ou diversificação dos ativos em questão. Além disso, a eficiência informacional do mercado de Bitcoin mostrou melhorias significativas desde 2014, apoiando a aplicabilidade da AMH (Bedi & Nashier, 2020).

A Hipótese do Mercado Fractal (FMH) oferece uma perspectiva alternativa à EMH e a AMH para compreender e modelar a dinâmica dos mercados de criptomoedas. A FMH propõe que os mercados financeiros apresentam características fractais e de memória de longo prazo, o que resulta em uma eficiência de mercado variável no tempo (Fang et al., 2022; Kristjanpoller, Fernandes, & Tabak, 2022). Estudos mostram que a FMH se aplica aos mercados de criptomoedas, onde a ineficiência do mercado é variável no tempo e as correlações assimétricas são mais persistentes para pequenas flutuações do que para grandes flutuações (Cao & Ling, 2022; Kristjanpoller et al., 2022). Os resultados desses estudos rejeitam a forma fraca da Hipótese do Mercado Eficiente (EMH) e sugerem que a dinâmica dos pares de criptomoedas analisados está mais alinhada com a FMH (Kristjanpoller et al., 2022). Além disso, a eficiência do mercado e o ranking das criptomoe- das variam dependendo da denominação em dólares americanos ou Bitcoin (Kristoufek & Vosvrda, 2019).

2.1.3 Teoria do *trade-off* Risco-Retorno

A Teoria do Risco-Retorno é um princípio fundamental Teoria Moderna na gestão de investimentos que estabelece a relação entre o risco e o retorno esperado de um ativo financeiro (Markowitz, 1952; Sharpe, 1966). De acordo com essa teoria, os investidores exigem um retorno maior para assumir um risco maior, implicando que ativos mais arriscados devem oferecer retornos potencialmente mais elevados para compensar o risco adicional. A relação risco-retorno é essencial para a tomada de decisões de investimento e a construção de carteiras eficientes, pois ajuda os investidores a entender como os diferentes ativos contribuem para o risco e retorno geral da carteira.

A teoria do *trade-off* entre risco e retorno sugere que os investidores esperam retornos mais elevados em troca de assumir riscos mais elevados (Bedi & Nashier, 2020). Essa teoria é fundamental para a compreensão das relações entre risco e retorno nos mercados financeiros e tem implicações significativas para a precificação de ativos e estratégias de investimento (Bouri, Gupta, & Roubaud, 2019). No contexto do mercado de criptomoedas, estudos demonstraram que existe uma relação positiva entre o risco de queda e os retornos futuros das criptomoedas, embora não haja uma relação intertemporal significativa entre os dois (Zhang, Li, Xiong, & Wang, 2021). Além disso, a teoria do *trade-off* entre risco e retorno pode ser aplicada ao estudo de fenômenos comportamentais no mercado de criptomoedas, como o efeito manada, que afeta o *trade-off* entre risco e retorno e tem implicações para a precificação de ativos (Bouri, Gupta, & Roubaud, 2019). Ao analisar a *trade-off* entre risco e retorno no mercado de criptomoedas, os pesquisadores têm utilizado medidas tradicionais de risco, como o Índice de Sharpe, bem como medidas que levam em conta a distribuição assimétrica dos retornos, como o *Modified Value at Risk* (MCVaR) (Bedi & Nashier, 2020).

Ao avaliar o risco e o retorno dos criptoativos em relação aos ativos tradicionais, os investidores podem tomar decisões mais informadas sobre a inclusão desses ativos em suas carteiras e otimizar a relação risco-retorno para alcançar seus objetivos de investimento (Zhang et al., 2021).

2.1.4 Teoria dos Limites à Arbitragem

A Teoria dos Limites à Arbitragem refere-se ao conceito de que existem restrições e limitações na prática da arbitragem que podem impedir a correção de desequilíbrios de preços e a eficiência dos mercados. A arbitragem envolve a exploração de diferenças de preços de um mesmo ativo em diferentes mercados ou a exploração de relações de preços entre ativos relacionados. No entanto, a presença de custos de transação, restrições regulatórias e riscos específicos do ativo pode dificultar a capacidade dos investidores de aproveitar oportunidades de arbitragem e eliminar as ineficiências do mercado (Chen, Lepori, Tai, & Sung, 2022).

A teoria dos limites à arbitragem é uma explicação alternativa para a relação entre risco e retorno em mercados financeiros, incluindo o mercado de criptomoedas (Zhang et al., 2021). Essa teoria sugere que ativos com maior risco de queda, que geralmente são menores, mais voláteis e ilíquidos, são mais difíceis de arbitrar devido aos custos envolvidos. Ao realizar uma análise de portfólio bivariada independente baseada em um índice sintético de arbitragem e valor em risco, Zhang (2021) descobriu que a relação positiva entre risco de queda e retornos futuros é mais acentuada entre criptomoedas com maiores custos de arbitragem, confirmando o papel dos limites à arbitragem em explicar parte de suas descobertas. No entanto, apesar desta evidência, a teoria dos limites à arbitragem não foi suficiente para explicar todos os resultados, já que a relação positiva entre risco de queda e retornos em criptomoedas persistiu mesmo após a aplicação de diferentes filtros de tamanho e liquidez. Portanto, a teoria dos limites à arbitragem complementa, mas não substitui, a teoria do *trade-off* entre risco e retorno no contexto do mercado de criptomoedas.

No contexto dos criptoativos, a Teoria dos Limites à Arbitragem é particularmente relevante devido à natureza fragmentada e descentralizada desse mercado. Existem muitas *exchanges* e plataformas de negociação de criptoativos, o que pode levar a diferenças de preços significativas entre elas. Além disso, os custos de transação, a volatilidade dos preços e as restrições regulatórias podem criar barreiras à arbitragem e impedir a convergência dos preços. Compreender os limites à arbitragem no mercado de criptoativos ajuda a explicar as ineficiências de mercado e fornece *insights* sobre as oportunidades e riscos associados às estratégias de negociação e arbitragem (Zhang et al., 2021; Chen et al., 2022).

2.2 Gestão de Risco no contexto dos criptoativos

A gestão de riscos é um processo essencial tanto para investidores, fundos de *hedge*, *traders* e formadores de mercado, e tem como ponto-chave a estimativa de medidas de risco adequadas que

possam melhorar as decisões de investimento e estratégias de negociação. A gestão de risco e a avaliação de desempenho são componentes fundamentais na administração eficiente de qualquer carteira de investimentos, incluindo carteiras de criptoativos.

Dada a volatilidade e o comportamento de risco singular desses ativos, é crucial para os investidores aplicar metodologias e técnicas que permitam quantificar e gerenciar os riscos associados, além de avaliar o desempenho das suas carteiras em relação a métricas e *benchmarks* apropriados. A alta volatilidade das criptomoedas as torna um investimento realmente arriscado e, conseqüentemente, a estimativa de medidas de risco adequadas é extremamente necessária (Trucíos, Tiwari, & Alqahtani, 2020).

Nesta seção, serão discutidas teorias e abordagens relevantes para a gestão de risco e avaliação de desempenho em carteiras de criptoativos, incluindo a Teoria do Valor Extremo, a Teoria dos Prospectos Cumulativos, a Teoria do Investimento Racional e diversas medidas de risco e métodos de modelagem de volatilidade.

2.2.1 Teoria do Valor Extremo (EVT)

A Teoria do Valor Extremo (EVT) é uma abordagem estatística que se concentra na modelagem e na análise de eventos extremos, como quedas acentuadas no valor de ativos financeiros ou grandes flutuações no mercado. Essa teoria é especialmente útil no contexto de criptoativos, que são conhecidos por sua volatilidade e comportamento de risco distinto em comparação com ativos tradicionais. A EVT permite a quantificação do risco associado a eventos raros e extremos, fornecendo informações valiosas sobre o comportamento das carteiras de criptoativos em cenários adversos (Pradhan, Mittal, & Tiwari, 2021; Bruhn & Ernst, 2022).

A aplicação da EVT no gerenciamento de risco em carteiras de criptoativos envolve a utilização de técnicas estatísticas para estimar a probabilidade e a magnitude de perdas extremas. Uma abordagem comum é o uso de distribuições estatísticas de cauda pesada, como a distribuição de valores extremos generalizada (GEV) ou a distribuição de Pareto, que são capazes de modelar eventos extremos com maior precisão do que as distribuições normais. Ao incorporar a EVT na gestão de risco de carteiras de criptoativos, os investidores podem obter uma compreensão mais aprofundada do risco de eventos extremos e tomar decisões de investimento mais informadas.

Por ser usada para modelar o comportamento extremo de cauda dos retornos do mercado de criptomoedas, Vários estudos aplicaram a EVT para estudar as características de risco das criptomoedas e descobriram que elas apresentam comportamento de cauda gorda com características de risco mais elevadas do que outras classes de ativos (Bruhn & Ernst, 2022).

Gkillas e Katsiampa (2018) usaram a TVE para estimar o Valor em Risco (VaR) e a Perda Esperada (ES) como medidas de risco de cauda para cinco criptomoedas e descobriram que os investidores estão expostos a altos riscos. Fakhfekh e Jeribi (2020) investigaram a melhor estratégia

de cobertura de portfólio para um portfólio composto por um conjunto de cinco criptomoedas e vários ativos financeiros tradicionais e descobriram que a adição de uma posição muito pequena em ativos digitais a um portfólio diversificado reduz significativamente seu risco geral e pode oferecer oportunidades de diversificação de portfólio. X. Huang et al. (2022) examinaram o desempenho de nove categorias de ativos de criptomoeda e concluíram que a maioria das categorias fornece benefícios de diversificação, dependendo da aversão ao risco do investidor.

2.2.2 Teoria dos Prospectos Cumulativos (CPT)

A Teoria dos Prospectos Cumulativos (CPT) é uma extensão da Teoria dos Prospectos original, proposta por Tversky e Kahneman, que busca explicar como as pessoas tomam decisões em situações de incerteza. A CPT leva em consideração o impacto das probabilidades e dos resultados nas escolhas dos indivíduos, destacando que os seres humanos geralmente são avessos ao risco em situações de ganhos e propensos ao risco em situações de perdas. Essa teoria é relevante no contexto dos criptoativos, pois ajuda a entender o comportamento dos investidores e como eles avaliam os riscos e retornos desses ativos financeiros emergentes (Contreras-Valdez, Núñez, & Perales, 2022; Omane-Adjepong, Ababio, & Alagidede, 2019).

Na gestão de carteiras de criptoativos, a CPT pode fornecer informações importantes sobre as preferências e o comportamento dos investidores, o que pode ser usado para adaptar estratégias de negociação e gerenciamento de risco (Ababio, 2020). Por exemplo, um investidor que segue a CPT pode ser mais propenso a vender criptoativos após um ganho e manter ou comprar após uma perda. Compreender essas tendências comportamentais pode ajudar a criar abordagens de investimento mais eficazes e a mitigar os efeitos das decisões irracionais na gestão de carteiras de criptoativos. A partir de uma abordagem comportamental, (Ababio, Mba, & Koumba, 2020) incorporam a possibilidade de utilizar a CPT, que incorpora ao problema original de otimização de Markowitz alguns vieses na tomada de decisão dos agentes, como aceitar riscos extras para obter um lucro maior em seus investimentos.

2.2.3 Teoria do Investimento Racional

A Teoria do Investimento Racional é uma abordagem baseada na ideia de que os investidores tomam decisões racionais e informadas ao avaliar os riscos e retornos dos ativos financeiros. Essa teoria pressupõe que os investidores buscam maximizar seus retornos ajustados ao risco, considerando as informações disponíveis e as expectativas futuras. No contexto dos criptoativos, a Teoria do Investimento Racional sugere que os investidores devem analisar cuidadosamente os fundamentos e as perspectivas de cada criptoativo antes de tomar uma decisão de investimento.

Ao aplicar a Teoria do Investimento Racional na gestão de carteiras de criptoativos, os investidores devem buscar diversificar suas carteiras, considerando a relação risco-retorno dos dife-

rentes criptoativos. Além disso, os investidores devem levar em consideração os desenvolvimentos regulatórios, a aceitação do mercado e a evolução da tecnologia por trás dos criptoativos. Ao adotar uma abordagem racional e fundamentada, os investidores podem tomar decisões de investimento mais informadas e melhorar o desempenho de suas carteiras de criptoativos a longo prazo (Abdul-Rahim, Khalid, Karim, & Rashid, 2022).

2.2.4 Métricas de Risco

A volatilidade é uma medida estatística que quantifica a variação dos preços de um ativo financeiro ao longo do tempo. Essencialmente, ela é a raiz quadrada da variância condicional dos retornos de um ativo, refletindo o nível de incerteza ou o risco associado aos movimentos de preço no curto prazo. A volatilidade pode ser mensurada de maneira rudimentar utilizando-se o desvio padrão dos retornos diários de um ativo.

Ao se tratar do risco de uma carteira de ativos, diversas abordagens podem ser utilizadas. O desvio-padrão e a matriz de variância-covariância são métodos comuns, mas existem outros, como o Value at Risk (VaR) e o Conditional Value at Risk (CVaR) ou Expected Shortfall (ES). É importante notar que VaR, CVaR e ES não são medidas de volatilidade per se, mas sim, técnicas para estimar o risco de uma carteira, que podem ser construídas a partir da combinação dos riscos dos títulos subjacentes (Jorion, 2011).

O VaR é uma medida de risco amplamente utilizada que estima a perda máxima esperada em um portfólio de investimentos em um determinado período e com um nível de confiança específico. O VaR pode ser calculado usando diferentes métodos, como a abordagem histórica, a abordagem paramétrica e a simulação de Monte Carlo. O VaR fornece informações importantes sobre o risco de perdas extremas em carteiras de criptoativos, auxiliando os investidores na avaliação e no gerenciamento dos riscos associados.

O VaR também é usualmente definido como a perda mínima dos piores α ou piores prejuízos que um investidor pode esperar perder em um período específico de tempo. Assim, o VaR é definido como um valor negativo (perda), embora uma parte da literatura financeira o defina como um valor positivo (Fantazzini & Zimin, 2020).

Já o CVaR, conhecido também como ES, é uma medida de risco que estima a perda média esperada em um portfólio de investimentos, condicionada a ocorrência de eventos extremos, superando o VaR (Jorion, 2011). O CVaR considera os eventos mais extremos e as perdas associadas a eles, fornecendo uma avaliação mais abrangente do risco em situações adversas. Essa medida é especialmente relevante para carteiras de criptoativos, dado o seu potencial de experimentar perdas extremas e rápidas (Pradhan et al., 2021; T. Cui, Ding, Jin, & Zhang, 2023).

O *drawdown* é uma medida de risco que quantifica a perda máxima acumulada em um portfólio de investimentos desde um pico até um mínimo subsequente. O *drawdown* é útil para

avaliar a resiliência de uma carteira de criptoativos em face de eventos de mercado adversos e pode ajudar os investidores a entender a profundidade e a duração das perdas potenciais. A análise do *drawdown* permite que os investidores ajustem suas estratégias de gerenciamento de risco e tomem decisões mais informadas sobre a alocação de ativos em suas carteiras de criptoativos (Nakano & Takahashi, 2020; Bedi & Nashier, 2020).

Em se tratando do quesito “risco”, a volatilidade é particularmente relevante no contexto dos criptoativos, devido às frequentes e significativas flutuações de preço que esses ativos apresentam. O mercado de criptomoedas é caracterizado por uma volatilidade alta até mesmo em comparação com outros mercados voláteis como ações e commodities. Apesar disso, a literatura reconhece que há uma relação negativa entre a volatilidade implícita do Bitcoin e a dos Estados Unidos da América (Bouri, Molnár, Azzi, Roubaud, & Hagfors, 2017), que as criptomoedas são pouco relacionadas com outros ativos (Bouri, Lucey, & Roubaud, 2019), apesar de altamente correlacionadas entre si (Katsiampa, 2019), e que a relação retorno-volatilidade do Bitcoin é negativa, inexistindo o *trade-off* risco-retorno para esta criptomoeda (Ahmed, 2020).

Outras ferramentas gerenciam o risco individual de cada ativo, como as técnicas de *stop-loss*, que podem ajudar no gerenciamento do risco de investimento em criptoativos e são capazes de reduzir quase pela metade a volatilidade dos retornos com alguma redução dos retornos. Białkowski (2020) alerta que a taxa de sobrevivência de posições longas em criptomoedas com regras de *stop-loss* em vigor não excede 35%.

2.2.5 Modelagem e Previsão de Volatilidade

Para controlar o risco relacionado à volatilidade dos ativos, há várias alternativas, desde a adequada diversificação, a *Tactical asset allocation* (TAA), que sobrepondera ativos menos voláteis e subpondera os mais voláteis, regras de *stop loss*, até técnicas avançadas de previsão de volatilidade como modelos autoregressivos e *machine learning*.

A modelagem e previsão de volatilidade são aspectos cruciais na gestão de riscos e na tomada de decisões de investimento, especialmente no mercado de criptoativos, caracterizado por sua volatilidade intrínseca. Os modelos *Generalized Autoregressive Conditional Heteroskedasticity* (Bollerslev, 1986), comumente denominados GARCH, são uma classe amplamente utilizada de modelos econômicos que permitem capturar a volatilidade condicional e a heteroscedasticidade nos retornos dos ativos financeiros.

Ao aplicar modelos GARCH no contexto de criptoativos, os investidores podem obter uma compreensão mais precisa da dinâmica de volatilidade e prever as variações futuras de preços, melhorando assim a gestão de riscos e a eficiência de suas estratégias de negociação. Segundo Kyriazis (2021a), modelos GARCH sofisticados explicam melhor as flutuações na volatilidade das criptomoedas. Para esses ativos, notoriamente voláteis, Mba, Pindza, e Koumba (2018) constataram

que o GARCH-DE-t-copula mostrou capacidade de controle de risco, confirmando a capacidade do t-copula de capturar a estrutura de dependência na cauda gorda.

Assumindo que as criptomoedas possuem caudas pesadas (Zhang, Wang, Li, & Shen, 2018) e à esquerda (Feng, Wang, & Zhang, 2018), a distribuição normal dos retornos não é mais adequada para descrever esta classe de ativos (Szczygielski, Karathanasopoulos, & Zaremba, 2019). Assim, assume-se que a estimação GARCH multivariada é mais adequada de que os modelos padrão, que podem gerar previsões incorretas (G. Caporale & Plastun, 2019), sendo sempre superados por modelos GARCH de caudas pesadas (Troster, Tiwari, Shahbaz, & Macedo, 2019) no contexto das criptomoedas.

Assumindo que as criptomoedas apresentam distribuições de retorno com caudas pesadas e assimetria à esquerda (Zhang et al., 2018; Feng et al., 2018), a adoção da distribuição normal padrão para modelar tais retornos é inadequada (Szczygielski et al., 2019). Em resposta, modelos GARCH que levam em consideração estas características mostram-se mais apropriados, oferecendo previsões mais precisas em comparação com os modelos padrão (G. Caporale & Plastun, 2019; Troster et al., 2019), enquanto os modelos GARCH multivariados permitem capturar as interdependências de volatilidade no mercado de criptomoedas, além de acomodar as propriedades de distribuição de caudas pesadas dos seus retornos.

Panagiotis, Efthymios, Anastasios-Taxiarchis, e Athanasios (2020) alertam que a volatilidade entre as moedas digitais nem sempre é bem descrita pela mesma especificação, mas varia de acordo com a moeda. A Correlação Condicional Dinâmica (DCC) de (Engle, 2002) é usada para determinar as correlações variáveis no tempo e tem apresentado resultados bem ajustados em carteiras incluindo criptomoedas (Madhavan & Sreejith, 2022; Smales, 2021; Akhtaruzzaman et al., 2020).

Além dos modelos GARCH, existem várias outras abordagens de modelagem e previsão de volatilidade que podem ser aplicadas no mercado de criptoativos. Por exemplo, os modelos de volatilidade estocástica, que consideram a volatilidade como um processo estocástico, podem fornecer uma representação mais flexível da dinâmica de volatilidade. Além disso, técnicas de aprendizado de máquina e inteligência artificial, como redes neurais e algoritmos de aprendizado profundo, têm sido cada vez mais empregadas na previsão de volatilidade de criptoativos, com resultados promissores. A escolha do modelo ou abordagem adequada depende das características específicas dos dados e das necessidades dos investidores em termos de gerenciamento de risco e tomada de decisão.

2.3 Gestão de Carteiras de Criptoativos

2.3.1 Estratégias de Negociação de Criptoativos

As estratégias de negociação de criptoativos podem ser divididas em duas categorias principais: passivas e ativas. As estratégias passivas, como a alocação de índices e a compra e manutenção (conhecidas pelo termo “*buy-and-hold*”), focam na diversificação e no investimento a longo prazo, buscando acompanhar o desempenho geral do mercado de criptoativos. Essas estratégias geralmente envolvem menores custos de transação e uma abordagem mais simples na gestão da carteira.

Por outro lado, as estratégias ativas, como a análise técnica, a negociação algorítmica e a arbitragem, buscam superar o mercado através da identificação e exploração de oportunidades de negociação específicas. As estratégias ativas geralmente envolvem maior frequência de negociação, maior complexidade e custos de transação mais elevados, mas também têm o potencial de gerar retornos superiores ajustados ao risco.

No contexto da análise técnica, a atratividade da criptomoeda pode ser avaliada a partir de sua tendência de preço, ou seja, a direção do movimento do preço. As tendências podem ser ascendentes, descendentes e laterais (quando não há movimento de preço pronunciado e a linha de tendência está se movendo dentro de uma faixa sem inclinação) (Saksonova & Kuzmina-Merlino, 2019).

Nesse sentido, a maioria dos sistemas de negociação desenvolvidos a partir de indicadores técnicos são projetados para operar em mercados de tendência ou não, mas raramente são úteis para ambos os mercados. Wilder (1978) trouxe um avanço nesse sentido ao criar o *Reaction Trend System* (RTS), que permite operações em ambos os mercados (Fiorucci et al., 2022a).

Já tratando da proporção entre ativos voláteis e títulos de renda fixa ou caixa em portfólios praticada no mercado para a alocação é tradicionalmente 60/40 ou mesmo 70/30. Mesmo assim, portfólios baseados na alocação 60/40 permanecem voláteis e dominados pelo risco de ações (Bender, Briand, Nielsen, & Stefek, 2010). Para esta pesquisa, será prevista a manutenção de caixa de oportunidade de até 40% da carteira.

Ao implementar estratégias de negociação de criptoativos, os investidores devem estar cientes dos fatores de risco e desafios específicos deste mercado. A volatilidade dos preços, a falta de liquidez em alguns ativos, os riscos de segurança e a regulamentação em constante evolução são fatores que podem afetar o desempenho das estratégias de negociação e a rentabilidade dos investimentos. Além disso, a escolha da plataforma de negociação, a gestão de riscos e a seleção de criptoativos também desempenham papéis cruciais no sucesso das estratégias de negociação.

2.3.2 Seleção e Classificação de Criptoativos

A seleção de criptoativos é um processo fundamental na construção de carteiras e na implementação de estratégias de investimento. Os investidores devem considerar uma série de fatores ao selecionar criptoativos, incluindo a capitalização de mercado, a liquidez, o desempenho histórico, a volatilidade e as correlações com outros ativos. Além disso, aspectos fundamentais, como a tecnologia subjacente, a equipe de desenvolvimento, a governança e a adoção do projeto, também devem ser levados em consideração. A seleção criteriosa de criptoativos pode ajudar a diversificar a carteira e melhorar seu desempenho ajustado ao risco, ao mesmo tempo em que minimiza a exposição a ativos de baixa qualidade e risco excessivo.

Segundo Saksonova e Kuzmina-Merlino (2019), a seleção de uma carteira de criptomoedas deve considerar (a) os objetivos do investidor; (b) a relação entre risco e lucratividade; a ausência de correlação entre os ativos; (c) a diversificação para minimizar o risco não sistemático; (d) a liquidez das mesmas, ou seja, podem ser trocadas livremente por uma moeda fiduciária; (e) o reequilíbrio regular da carteira.

Uma vez que os criptoativos selecionados, é importante classificá-los de acordo com suas características e propriedades específicas. A classificação pode ser baseada em diversos critérios, como categoria (por exemplo, moedas, *tokens* de utilidade, *tokens* de governança), uso (meio de troca, reserva de valor, protocolo de aplicação), indústria (*fintech*, saúde, energia) ou perfil de risco. A classificação de criptoativos facilita a compreensão das diferentes fontes de risco e retorno na carteira e permite uma alocação de ativos mais eficiente e diversificada. Além disso, a classificação de criptoativos pode ser útil na identificação de tendências e padrões de mercado e na avaliação do desempenho relativo de diferentes ativos e segmentos do mercado de criptoativos.

Pensando na otimização e na sistematização desse processos de classificação e seleção de criptoativos, deveras complexo dada a diversidade de classificações relevantes e a quantidade de novas criptomoedas e *tokens* que tem sido criadas e curto espaço de tempo, os investidores podem recorrer a abordagens de clusterização e técnicas avançadas de análise de dados, como a Análise de Componentes Principais (PCA) e as técnicas de aprendizado de máquina. A clusterização permite agrupar criptoativos com características semelhantes, facilitando a diversificação e a alocação de ativos.

A PCA, por sua vez, é uma técnica de redução de dimensionalidade que pode ajudar a identificar os fatores subjacentes que explicam a maior parte da variação nos preços dos criptoativos, possibilitando uma melhor compreensão das fontes de risco e retorno (Aras, 2021; James, 2022; Nakano & Takahashi, 2020; Petukhina, Trimborn, Härdle, & Elendner, 2021). Entretanto, Bae e Kim (2022) deixou de incluir PCA em seu experimento porque os componentes principais que explicam grande parte da variância em criptomoedas são altamente correlacionados com as moedas mais voláteis desde 2018.

Além disso, o aprendizado de máquina, incluindo algoritmos de classificação e regressão, pode ser utilizado para prever o comportamento futuro dos criptoativos e otimizar a alocação de recursos com base em padrões e relações identificados nos dados históricos. Essas abordagens avançadas podem complementar as análises tradicionais e fornecer *insights* adicionais para a construção de carteiras de criptoativos mais eficientes e bem diversificadas.

2.3.3 Otimização de Carteira, *Backtesting* e Rebalanceamento

A otimização de carteira é um processo que visa maximizar o retorno esperado para um determinado nível de risco ou minimizar o risco para um retorno esperado específico. No contexto de criptoativos, a otimização de carteira pode envolver a aplicação de técnicas tradicionais, como a Teoria Moderna de Carteiras de Markowitz, ou abordagens mais avançadas baseadas em aprendizado de máquina e otimização heurística. A otimização de carteira permite que os investidores identifiquem a alocação de ativos ideal e melhorem o desempenho ajustado ao risco de suas carteiras, levando em consideração as características específicas e as dinâmicas de mercado dos criptoativos.

Nesse contexto, se tiver N ativos disponíveis para se investir, os pesos de cada ativo na carteira podem seguir uma alocação ‘ingênua’ $1/N$ (dentro da gestão passiva), ou serem otimizadas de acordo com diferentes critérios. W. Liu (2019) encontrou evidências robustas de que o modelo de utilidade máxima domina o utilitário fora da amostra, mas concluiu que nenhum dos modelos consegue vencer consistentemente o portfólio ingênuo $1/N$ no quesito índice de Sharpe. Enquanto isso, Brauneis e Mestel (2019) encontraram que o $1/N$ supera portfólios de média-variância em 75% das vezes.

DeMiguel, Garlappi, e Uppal (2009) corroboraram mostrando que o $1/N$ foi superior a 14 modelos diferentes de otimização de portfólio em vários mercados na configuração fora da amostra. Os autores concluíram que a janela de estimativa necessária para a estratégia de média-variância seja capaz de superar o *benchmark* $1/N$ é de cerca de 3.000 meses para uma carteira com 25 ativos e cerca de 6.000 meses para uma carteira com 50 ativos.

A prática do mercado de investimentos e fundos de pensões, entretanto, demanda usualmente algumas condições que as otimizações teóricas deixam de considerar, como a restrição de cardinalidade máxima (que restringe o número de ativos permitidos na carteira para reduzir o custo de gestão, limites de *buy-in* (que define um valor mínimo a ser investido para qualquer ativo a ser incluído no portfólio, a fim de reduzir os custos de transação) ou a regra 5–10–40 (que define um limite superior para cada ativo individual e também para a soma de todos os ‘pesos pesados’ da carteira), pois tais restrições tornam o espaço de pesquisa não convexo (Branke, Scheckenbach, Stein, Deb, & Schmeck, 2009).

A inserção de mais e mais ativos, sob o ponto de vista teórico da diversificação do portfólio, é uma boa solução para a minimização do risco. Observa-se, porém, que à medida que o número

de ativos na carteira aumenta, o risco diminui, mas o retorno esperado da carteira também diminui independentemente para cada medida de risco (Anagnostopoulos & Mamanis, 2010), indicando um melhor desempenho de carteiras com um menor número de ativos.

Corroborando tal observação, Mansini, Ogryczak, e Speranza (2015) apontam alguns fatores, como as imperfeições do mercado e os custos de transação envolvidos, que criam na prática um limite para a diversificação e, quando ultrapassado, faz com que a inclusão de mais ativos diminua ganhos no investimento. Observa-se, porém, que à medida que o número de ativos na carteira aumenta, o risco diminui, mas o retorno esperado da carteira também diminui independentemente para cada medida de risco (Mamanis, 2021).

Cesarone, Moretti, e Tardella (2016), em uma pesquisa que objetivou a minimização do risco sujeito à restrição de cardinalidade, identificaram que, geralmente, os portfólios com os menores riscos são compostos de poucos ativos. Ou seja, existiria uma ‘cardinalidade crítica’ (geralmente menor que 15) capaz de minimizar o risco e, a partir dela, aumentar a quantidade de ativos significaria aumentar o risco. Além disso, constataram que, quase sempre, existe um portfólio com 10 ou menos ativos tal que a diferença entre seu risco e o menor risco dentre todos os portfólios é menor que 1%. Por sua relevância, na presente pesquisa, será considerada a restrição da cardinalidade.

Aliado a esse ponto, há ainda a necessidade de verificar previamente a carteira em alguns pontos, com destaque para o *backtesting* e rebalanceamento. O *backtesting* é uma técnica essencial para avaliar a eficácia das estratégias de investimento e otimização de carteira no mercado de criptoativos (G. M. Caporale & Zekokh, 2019; Syuhada & Hakim, 2020). Consiste em aplicar a estratégia a um conjunto de dados históricos para verificar seu desempenho e robustez em diferentes cenários de mercado. O *backtesting* ajuda a identificar possíveis melhorias na estratégia e a ajustar a alocação de ativos e os parâmetros de negociação conforme necessário. O *backtesting* é uma técnica comum para comparar as previsões do VaR com a série realizada, utilizando diferentes métodos e funções de perda para avaliar a precisão das previsões do VaR (Fantazzini & Zimin, 2020).

O rebalanceamento, por outro lado, é o processo de ajustar periodicamente a alocação de ativos na carteira para manter a proporção desejada de risco e retorno. No mercado volátil e em rápida evolução de criptoativos, o rebalanceamento regular é fundamental para garantir que a carteira permaneça alinhada com os objetivos de investimento e as tolerâncias a risco do investidor, ao mesmo tempo em que aproveita as oportunidades emergentes e as mudanças nas condições de mercado (Burggraf, 2021; Petukhina et al., 2021).

Gestão de portfólio em criptomoedas: uma revisão sistemática da literatura

3 Gestão de Portfólios de Criptoativos: uma revisão sistemática da literatura

3.1 Introdução

Apesar de ser um tema recente, que despontou em 2008 e começou a ser estudado ativamente apenas a partir de 2013, mais de doze mil estudos já foram publicados com a temática criptomoedas e sua primeira e mais famosa representação, o Bitcoin, conforme busca realizada em títulos, resumos e palavras-chave na base Scopus em abril de 2023.

A literatura sobre criptomoedas e seu papel nos portfólios de investimento tem se expandido rapidamente nos últimos anos. Merediz-Solà e Bariviera (2019) forneceram um panorama do estado da arte do Bitcoin, excluindo a tecnologia *blockchain* e outras criptomoedas. Corbet, Lucey, Urquhart, e Yarovaya (2019) realizaram uma revisão mais ampla da literatura sobre criptomoedas, enquanto Klarin (2020) mapearam 192 tópicos específicos espalhados por quatro grupos principais identificados de estudos em criptomoedas.

Em um estudo mais recente, Almeida e Gonçalves (2022) exploraram a pesquisa publicada entre 2009 e 2021, resumindo as contribuições da literatura existente na análise da volatilidade e gestão de risco no investimento em criptomoedas. A pesquisa de Fang et al. (2022) fornece uma revisão abrangente de 146 trabalhos sobre diversos aspectos do comércio de criptomoedas, incluindo sistemas de negociação, bolhas e condições extremas, previsão de volatilidade e retorno, construção de portfólio de criptoativos, negociação técnica, entre outros.

A revisão sistemática da literatura realizada por Haq, Maneengam, Chupradit, Suksatan, e Huo (2021) examina o papel do mercado de criptomoedas como uma via de gestão de risco frente à incerteza da política econômica (EPU). Os resultados indicam padrões de conexão mistos entre criptomoedas e EPU nacionais, levando a uma capacidade de mitigação de riscos variável entre os países. A heterogeneidade nos padrões de correlação decorre das políticas e decisões tomadas pelas autoridades regulatórias de cada nação. A revisão também sugere direções para futuras pesquisas, considerando tópicos, frequência de dados e metodologias, beneficiando investidores, formuladores de políticas e gestores de fundos e portfólios.

Entretanto, ainda há uma carência de estudos mais específicos que auxiliem na identificação de *gaps* na pesquisa que trata de carteiras de investimento otimizadas incluindo criptomoedas. A gestão de portfólios de criptomoedas tem sido objeto de crescente interesse no campo acadêmico, dado o aumento do número de instituições financeiras que incluem criptoativos em seus portfólios (Fang et al., 2022). A natureza única e o comportamento das criptomoedas como classe de ativos ainda estão sendo compreendidos, tornando fundamental revisar e analisar as pesquisas existentes sobre a negociação de criptomoedas, incluindo estratégias de investimento e gerenciamento de risco, bem como as questões relacionadas às hipóteses de eficiência de mercado.

De acordo com Okoli, Duarte, e Mattar (2019), uma revisão sistemática torna-se pouco eficiente se a questão de pesquisa for muito vaga ou ampla, o que geraria centenas de estudos muito diferentes, mas também se a questão for muito limitada, o que produziria poucos estudos úteis. Assim, para direcionar uma revisão sistemática que oportunize a construção de um portfólio bibliográfico para tratar de criptomoedas como ativo de investimento, o problema que norteia a presente pesquisa é: **Como a literatura já constituída que trata de criptomoedas tem abordado sua inserção em portfólios de investimento, em particular, questões relacionadas sua eficiência de mercado, gestão de risco e seleção/otimização de carteiras?**

Assim, o objetivo geral desta sessão é, a partir da classificação e codificação dos artigos publicados, resumir e sistematizar as pesquisas da área de Finanças já publicadas sobre criptomoedas que tenham foco em sua utilização em portfólios de investimentos, incluindo sua gestão de risco, e eficiência de mercado. Além disso, foram delimitados os seguintes objetivos específicos: (a) Construir um portfólio bibliográfico para estudar as criptomoedas como ativo de investimento; (b) Analisar o progresso das discussões sobre os tópicos de pesquisa determinados; (c) Fazer recomendações de trabalhos futuros; (d) Verificar os métodos empregados para testar os tópicos de pesquisa determinados.

Esta pesquisa contribui para a literatura existente sobre criptomoedas em Finanças, ao apresentar um panorama da literatura sobre criptomoedas focado em três pilares essenciais para este campo. A seleção do portfólio bibliográfico, parte fundamental do trabalho acadêmico, de acordo com Medeiros, Vieira, Braviano, e Gonçalves (2015), demanda rigor metodológico para a busca, seleção e tratamento de dados, etapas para as quais a revisão sistemática e própria análise bibliométrica podem contribuir de forma efetiva. Ademais, as abordagens de análise sistemática fornecem uma compreensão mais abrangente do conhecimento em campo, enquanto seus resultados tem potencial para mudar as direções futuras da pesquisa ao descobrir lacunas na literatura, particularmente em novas áreas de pesquisa como as moedas virtuais, uma análise sistemática pode ser a ferramenta mais poderosa para conhecer o estado da arte e para identificar consensos e ambiguidades na disciplina emergente (Corbet et al., 2019).

Embora já existam algumas revisões de literatura nessa área de pesquisa, não foi encontrada análise comparativa alguma, nem mesmo que seja abrangente e dedicada aos múltiplos aspectos da gestão de portfólios compostos por criptoativos. Flori (2019) concentrou-se no uso de criptomoedas do ponto de vista financeiro, focando em três linhas de pesquisa: formação de preços, detecção de ineficiência do mercado e construção e diversificação de portfólios. Entretanto, embora o estudo tenha compilado bastante material sobre essas três vertentes, ele não esclarece quais procedimentos foram utilizados para a seleção das pesquisas analisadas, não chegando a tratar-se de uma revisão sistemática, além da simples descrição da literatura reunida.

Fang et al. (2022) realizaram uma revisão abrangente de 146 artigos sobre diversos aspectos do comércio de criptomoedas, analisando conjuntos de dados, tendências de pesquisa e distribuição

entre objetos de pesquisa e tecnologias. Por outro lado, Haq et al. (2021) examinaram a literatura sobre o mercado de criptomoedas como uma via de gerenciamento de risco em face da incerteza da política econômica, destacando padrões de correlação heterogêneos entre as criptomoedas e a incerteza das políticas econômicas nacionais.

A análise da volatilidade e do gerenciamento de risco no investimento em criptomoedas é um tema recorrente na literatura. Almeida e Gonçalves (2022) exploraram a pesquisa publicada entre 2009 e 2021, sintetizando as contribuições da literatura no tocante à análise da volatilidade e ao gerenciamento de risco em investimentos em criptomoedas. Os resultados indicam que os modelos que consideram o regime de mudança de Markov são os mais consensuais entre os autores, e as técnicas de aprendizado de máquina com melhor desempenho são modelos híbridos que consideram máquinas de vetores de suporte (SVM). Além disso, a previsibilidade da volatilidade, a redução de risco e o nível de especulação no mercado de criptomoedas são aprimorados pelos efeitos de alavancagem e pela persistência da volatilidade (Almeida & Gonçalves, 2022).

3.2 Procedimentos para a Revisão Sistemática de Literatura

Para direcionar as etapas de seleção e análise iniciais, utilizou-se o *Methodi Ordinatio* fim de sistematizar os procedimentos, por se tratar de uma metodologia de múltiplos critérios que facilita o processo de construção de um portfólio (Pagani, João Luiz Kovaleski, & Luis Mauricio Martins de Resende, 2017). Nesse sentido, Okoli et al. (2019) apontam como questão prática é se é possível justificar a quantidade de tempo, energia e até mesmo custo financeiro necessários para realizar a revisão sistemática, fatores parcialmente solucionados pelo *Methodi Ordinatio*. O grande diferencial desta metodologia é que a tarefa de classificação é realizada antes da análise sistemática, para que a importância do trabalho seja reconhecida nas fases iniciais do processo, poupando um maior desgaste ao analisar artigos de baixa relevância científica (Pagani, Kovaleski, & Resende, 2015).

A metodologia *Methodi Ordinatio* emprega uma equação para classificar artigos, o *Index Ordinatio* (InOrdinatio), que visa selecionar e classificar artigos de acordo com sua relevância científica, levando em consideração os principais fatores a serem considerados em um artigo científico: fator de impacto da revista em que o artigo foi publicado, número de citações e ano de publicação. A metodologia apresenta nove fases (Figura 1). As cinco primeiras fases da *Methodi Ordinatio* são uma adaptação da etapa ProKnow-C de seleção do portfólio bibliográfico bruto (Ensslin, Ensslin, Dutra, Nunes, & Reis, 2017; Ensslin, Ensslin, & Pinto, 2013), enquanto as últimas quatro fases substituem os critérios do ProKnow-C, que considera unicamente o número de citações dos artigos, por um modelo de avaliação multicritério (Campos, Pagani, Resende, & Pontes, 2018).

A estratégia metodológica baseia-se no desenvolvimento de uma metodologia para selecionar, coletar, classificar e ler sistematicamente artigos científicos publicados em periódicos, de




Figura 1 – Etapas da metodologia Methodi Ordinatio. Fonte: Pagani et al. (2017).

forma que três critérios para a classificação possam ser fornecidos: ano de publicação, número de citações e fator de impacto (Pagani et al., 2015, 2017).

3.2.1 Delimitações da pesquisa e procedimentos de seleção do portfólio

A primeira etapa da Methodi Ordinatio refere-se ao estabelecimento da intenção de pesquisa, que no presente caso é construir um portfólio bibliográfico a partir de artigos científicos sobre criptomoedas como ativo de investimento, no que se refere a gestão de risco, utilização em portfólios e eficiência de mercado (HME).

Foi realizada uma pesquisa preliminar com as palavras-chave nas bases de dados e a seguir foi definida uma combinação das palavras-chave e das bases de dados a serem utilizadas (Etapas 2 e 3). A partir da definição do problema, foram definidos os termos-chave nos quais foi baseada a montagem do descritor, divididos em três colunas separadas por áreas de interesse de pesquisa. À medida em que são acrescentadas colunas, mais afunilada fica a pesquisa, sendo recomendado o uso de no máximo três colunas de assunto (Medeiros et al., 2015).

Foi incluído o termo Bitcoin por ser o nome da criptomoeda mais conhecida e pesquisada. Assim, juntando os dois grupos por meio de termos booleanos, foi estabelecido o descritor de busca, conforme a Tabela 1. O (*) no termo *cryptocurrenc** foi utilizado para capturar variações como "*cryptocurrency*" ou "*cryptocurrencies*".

Este descritor foi aplicado desta mesma forma em todas as bases de dados selecionadas.

	Primeiro Grupo	Segundo Grupo	Terceiro Grupo
Palavras-chave	criptomoeda Bitcoin	portfólio	teoria seleção hipóteses de mercado gestão de risco
Descritor	("cryptocurrenc*"OR "Bitcoin") AND (portfolio) AND (theory OR selection OR "Market Hypothesis"OR "risk management"))		

Tabela 1 – Termos-chave para pesquisa

Estabeleceu-se as bases de dados Scopus e Web of Science por importância científica e abrangência, sendo as mais pertinentes para a coleta a fim de cobrir o maior número possível de publicações. Caso fossem encontrados artigos repetidos, eles seriam excluídos no decorrer do processo.

Critérios de inclusão	• artigos empíricos em inglês ou português que abordem portfólios de criptoativos • artigos empíricos que abordem gestão de risco no campo dos criptoativos, aplicada ou aplicável a portfólios • artigos empíricos que abordem aspectos relativos a eficiência de mercado no campo dos criptoativos, com implicações para portfólios
Critérios de exclusão	• sobre a tecnologia <i>blockchain</i>, mineração, segurança e protocolos criptográficos, sistemas digitais e novos desafios de gerenciamento financeiro • artigos em outros idiomas além do inglês e português • não conter criptomoedas ou Bitcoin no título • Survey (entrevista ou questionários com pessoas) • sobre as trocas de criptomoedas como instrumento de pagamento • apenas sobre previsão de preços, sem trazer contribuição no campo da gestão de portfólios • sobre o gerenciamento de riscos operacional e corporativos

Tabela 2 – Critérios de inclusão e exclusão para aplicação dos testes de relevância

Concernente aos critérios de inclusão e exclusão (Okoli et al., 2019; Siddaway, 2014), a Tabela 2 detalha os testes de relevância utilizados para a filtragem tanto na fase de triagem (leitura do título/resumo) quanto no estágio de elegibilidade potencial (texto completo). Esta pesquisa é delimitada para buscar apenas artigos científicos com o sistema *double review*, pois essas pesquisas geralmente passam por um processo de revisão por pares mais rigoroso (Caiado, de Freitas Dias, Mattos, Quelhas, & Leal Filho, 2017).

3.2.2 Coleta e filtragem da base de dados

A seguir, foi realizada a busca no dia 21 de janeiro de 2023, usando o descritor de busca aplicado aos campos título, resumo e palavras-chave de cada base de dados (Etapa 4), para todo o período disponível. De acordo com as especificidades de cada base, foram aplicados os filtros possíveis para já atender aos critérios de inclusão e exclusão definidos em Tabela 2.

Foram mantidos os artigos categorizados nas bases como sendo revisões, para posterior análise. Após todas as filtrações efetuadas, foi feito *download* de todas as referências em Bibtex,

importadas para o gerenciador de referências Zotero, onde foram removidas as duplicatas (artigos disponíveis em mais de uma base), resultando em 172 artigos.

Web of Science = 150 artigos	Base Scopus = 138 artigos
(-) Intersecção = 116 artigos	
União = 172 artigos	
(-) Não disponíveis = 20 artigos	
(-) Idioma russo = 1 artigo	
(-) Survey = 1 artigo	
(-) Artigos de revisão = 3 artigos	
(-) Idioma russo = 1 artigo	
(-) Não alinhados com a pesquisa = 62 artigos	
Base considerada para a análise sistemática = 84 artigos	
(-) Artigos com classificação Qualis abaixo de A4 = 8 artigos	
(-) Artigos sem classificação Qualis e sem Impact Factor = 4 artigos	
Base final = 71 artigos	

Tabela 3 – Resultados da busca

A seguir, cumprindo a Etapa 5 *Methodi Ordinatio*, foram lidos todos os títulos dos artigos dentro do ambiente do gerenciador de referências, já sendo eliminados os que não estavam alinhados ao tema da pesquisa, conforme os critérios descritos na Tabela 2. Quando o título não era suficientemente claro ou gerava dúvidas sobre sua adequação, o resumo também era lido antes de ser descartado.

Entrando na etapa 6 da *Methodi Ordinatio* (Identificação do fator de impacto, publicação e número de citações), as referências foram exportadas para o Excel com o auxílio do *software* JabRef. Como métrica para fator de impacto dos periódicos nos quais cada artigo foi publicado, utilizou-se o SJR, disponibilizado para *download* em planilha eletrônica pela SCImago. Foi agregada uma planilha contendo os nomes dos periódicos e seus respectivos fatores de impacto, e buscados por meio da função *PROCV*.

Para 17 artigos, não foi encontrada a correspondência, ou seja, os periódicos nos quais foram publicados não possuem fator de impacto. Nestes casos, é orientado pela literatura que estes artigos sejam sumariamente excluídos. Porém, tendo em vista que algum desses artigos possuía um número significativo de citações, e para não correr o risco de perder nenhuma referência importante, optou-se por atribuir o valor 0 na coluna fator de impacto para os mesmos.

Por outro lado, tendo em vista o primeiro objetivo específico desta pesquisa, que é construir um portfólio bibliográfico para embasamento de futuras pesquisas, considerando as especificidades da área de Administração, e considerando os critérios de qualidade científica em vigor no Brasil estabelecidos pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) por meio do sistema Qualis Periódicos (Capes, 2020; Capes, 2017), que afere a qualidade dos artigos e de outros tipos de produção a partir da análise qualitativa e multicritérios da qualidade dos veículos de divulgação, foi estabelecido como critério adicional ao *Methodi Ordinatio* o enquadramento do

periódico na listagem Qualis, com estrato igual ou superior a A4. O corte foi feito neste estrato por ser o critério usado pela maioria dos programas de pós-graduação em Administração para avaliar a produção de primeira linha, seguindo Sucupira, Saab, Demo, e Bermejo (2019) e Demo et al. (2015). Dessa forma, 8 artigos foram descartados por não constarem no Qualis Periódicos como veículos de produção de primeira linha (estrato $\leq$ a A4). Quatro artigos que ainda não constam na listagem do sistema Qualis e também não possuem Fator de Impacto foram excluídos.

Aplicou-se, a seguir, a fórmula *InOrdinatio* (Equação 3.1). Nesta pesquisa, foi atribuído para α valor 5, considerando que a atualidade dos artigos é bastante relevante para o tema (até porque o objeto de estudo é subproduto de uma tecnologia em rápida evolução), mas também que é de interesse capturar pesquisas pioneiras de impacto para o tema. Diferentemente da fórmula original, o fator de impacto não foi dividido por mil, tendo em vista que o SJR já é ponderado em uma escala discreta.

$$InOrdinatio = (IF/1000) + \alpha * [10 - (ResearchYear - PublishYear)] + (\sum Ci) \quad (3.1)$$

onde: *IF* é o fator de impacto, α é um fator de ponderação que varia de 1 a 10, a ser atribuído pelo pesquisador; *ResearchYear* é o ano em que a pesquisa foi desenvolvida; *PublishYear* é o ano em que o artigo foi publicado; e $\sum Ci$ é o número de vezes que o artigo foi citado.

Já na etapa 8 (localização dos trabalhos em formato integral), os artigos completos foram baixados e anexados aos metadados das referências dentro do ambiente Zotero. Finalmente, procedeu-se a leitura sistemática e análise da base definitiva de artigos (71 textos). As categorias e subcategorias criadas foram baseadas nos temas mais comuns dos artigos, conforme mostrado na Tabela 4.

Exceto quanto a Período de Análise e Custos de Transação, cujas categorias são mutuamente exclusivas, um artigo pôde ser incluído em mais de uma opção de cada categoria. Foco ou Assunto Principal foi a categoria mais subjetiva, levando em consideração para: (A) discutir a eficiência de mercado das criptomoedas, seja a partir da Hipótese do Mercado Eficiente (EMH) ou da Hipótese do Mercado Adaptativo (AMH); (B) discussões sobre risco e/ou volatilidade das criptomoedas e suas tratativas possíveis; (C) Abordar a seleção de portfólios incluindo criptomoedas; (D) abordar a otimização de portfólios.

Tabela 4 – Sistema de classificação e códigos utilizados

Categorias	Significado	Subcategorias e respectivos códigos
1	Foco ou Assunto Principal	A - Relacionado com a Eficiência de Mercado
		B - Relacionado à Gestão de Risco
		C - Relacionado à Seleção de Portfólios

(Continua na próxima página)

Tabela 4 Sistema de classificação e códigos utilizados. (Continuação)

Categorias	Significado	Subcategorias e respectivos códigos
		D - Relacionado à Otimização de Portfólios
2	Objeto de estudo	A - Criptomoedas B - Taxas de câmbio C - Commodities D - Índices/Ações
3	Economia da Região estudada	A - Developed B - Emerging C - Developing D - Not Mencioned
4	Período de Análise	A - Menor ou igual a 05 anos. B - Mais de 05 anos.
5	Ferramentas Metodológicas	A - Modelos autoregressivos B - Regressões C - Análise de Performance D - Medidas/ gestão de risco E - Aprendizado de Máquina e IA F - Outros
6	Custos de transação	A - Considerado. B - Não considerado. C - Não se aplica
7	Observações	A - Intradiárias B - Diárias C - Semanais D - Mensais

Fonte: Elaborado pelos autores.

Em objeto de estudo, foram considerados tanto o objeto principal quanto variáveis de controle, desde que se enquadrassem como ativos de investimento. Quanto à região, foi considerada a classificação econômica do país quando o artigo o menciona especificamente ou quando utiliza algum tipo de índice regional identificável. A variável Observações se refere à frequência dos dados utilizados para análise.

3.3 Análise da Literatura

Inicialmente, são apresentados alguns indicadores bibliométricos/descritivos do portfólio analisado. A Figura 2 mostra a quantidade de artigos dentre os compreendidos na amostra publicados por ano e respectivas citações. Observa-se que a maior parte das pesquisas selecionadas são

de 2020 e 2022, mas também inclui alguns artigos de 2018 e 2019 com impacto significativo na pesquisa da área (Begušić, Kostanjčar, Eugene Stanley, & Podobnik, 2018; Trimborn & Härdle, 2018; Bouri, Gupta, & Roubaud, 2019; G. M. Caporale & Zekokh, 2019).




Figura 2 – Volume de artigos por ano

A Figura 3 apresenta os periódicos nos quais os artigos considerados na pesquisa foram publicados, por volume de publicações e por ano. O *Finance Research Letters* destaca-se com o maior número de publicações em criptomoedas em praticamente todos os anos, seguido pelo *Research In International Business And Finance*. As demais publicações apresentam-se dispersas em mais de 40 periódicos.




Figura 3 – Relevância dos periódicos do portfólio bibliográfico, por volume de artigos e por ano.

A Tabela 5 resume os resultados da classificação e codificação dos artigos analisados. O principal foco dos estudos compreendeu a categoria D (otimização de portfólios), seguida das categorias C (seleção de portfólio) e B (gestão de risco). Quanto ao objeto de estudo, além dos criptoativos, vários estudos testaram portfólios que incluíam índices/ações (categoria D), *commodities* (categoria C) e taxas de câmbio (categoria B).

Tabela 5 – Resumo de resultados por classificação e categoria de estudo

	Categorias					
	A	B	C	D	E	F
Foco	6	22	31	34		
Objeto de estudo	71	7	10	19		
Economia da região estudada	18	7	1	50		
Período de análise	53	18				
Ferramentas metodológicas	24	14	27	25	11	9
Custos de transação	22	8	41			
Observações	9	55	8	3		

Fonte: Elaborado pelos autores.

Em relação à economia da região estudada, esta não foi especificada para a maioria dos artigos (70%), o que se explica pelo próprio caráter desse tipo de pesquisa e das características intrínsecas das criptomoedas, não limitadas a barreiras geopolíticas. Dentre os países desenvolvidos, presentes em 25% das pesquisas, os Estados Unidos foram o país mais contemplado, seguido por países europeus. Identificou-se que poucos estudos trataram de países emergentes (7 artigos). Quanto às economias em desenvolvimento, apenas o estudo de Nkrumah-Boadu et al. (2022) investigou os benefícios dos criptoativos em portfólios em mercados africanos.

Sobre o período de análise, 75% dos estudos analisou dados de menos de 5 anos, o que é bastante compreensível, tendo em vista que a maioria das altcoins (nomenclatura dada às moedas alternativas digitais que surgiram após o Bitcoin, muitas das quais visam melhorar ou diferenciar-se em termos de tecnologia, uso ou economia) foi lançada a poucos anos. Em relação às ferramentas metodológicas, as mais utilizadas foram análise de performance (38%), seguida de medidas de gestão de risco (35%) e modelos autorregressivos (34%). As ferramentas relacionadas a aprendizado de máquina ainda aparecem com pequena representatividade (15%), enquanto 13% dos procedimentos utilizados não puderam ser encaixados em nenhuma das subcategorias delimitadas, sendo descritos como "Outros". Os custos de transação compuseram a análise de 31% dos estudos, mas não foram mencionados em 58% dos estudos, enquanto 11%, apesar de reconhecerem seu impacto para as análises de investimento, declararam em seus procedimentos que os desconsiderariam.

As observações diárias são utilizadas em mais de 70% dos estudos, mas 13% testaram dados de alta frequência e 11% preferiram converter suas observações em dados semanais, para evitar possíveis vieses durante a semana (Börner, Hoffmann, Krettek, & Schmitz, 2022) e mitigar

qualquer inconsistência no tempo para calcular o preço de fechamento diário (Bae & Kim, 2022), ou para evitar o grande volume de negócios e maior custo de transação em frequências menores (Platanakis & Urquhart, 2019). E, apesar de dados mensais dificilmente serem capazes de fornecer observações suficientes para uma análise robusta, três artigos testaram observações mensais, como Bedi e Nashier (2020), que pesquisou a capacidade de diversificação do Bitcoin para um portfólio global.

Tabela 6 – Classificação dos artigos com foco na eficiência de mercado.

Estudos	1	2	3	4	5	6	7
Bouri, Gupta, e Roubaud (2019)	A	A	D	A	B	C	B
Begušić et al. (2018)	A, C	A	D	A, B	A, D	C	B
Aslan e Sensoy (2020)	A	A	D	B	B, F	C	A
Haryanto, Subroto, e Ulpah (2020)	A	A	D	A	B	C	B
Chu, Chan, e Zhang (2020)	A, D	A	D	A	C	B	A
Nkrumah-Boadu et al. (2022)	A, C	A, C, D	C	A	B, F	C	B

A literatura sobre criptomoedas tem abordado as hipóteses relacionadas à eficiência de mercado (Tabela 6) em diferentes contextos e cenários, considerando variáveis como incerteza na política econômica (Bouri, Gupta, & Roubaud, 2019), comportamento de rebanho (Bouri, Gupta, & Roubaud, 2019; Haryanto et al., 2020), efeito disposição (Haryanto et al., 2020) e estratégias de negociação (Chu et al., 2020).

Observa-se que essas discussões compõem em geral uma seara à parte em relação a gestão de portfólios propriamente dita. Entretanto, a análise das hipóteses de mercado permite identificar padrões e comportamentos anormais que afetam a dinâmica de preços e retornos das criptomoedas. Estudos que abordam a relação entre poderes de lei e escalonamento (Begušić et al., 2018) bem como a multifractalidade e a presença de memória longa (Aslan & Sensoy, 2020), são particularmente relevantes para entender o comportamento de retornos e volatilidade das criptomoedas.

Além destes, a utilização de técnicas de análise de tempo-frequência, como a coerência de wavelet (Nkrumah-Boadu et al., 2022), permite investigar as interações entre variáveis macroeconômicas e os preços das criptomoedas, possibilitando uma melhor compreensão das assimetrias e dinâmicas de mercado. A partir dessas análises, é possível identificar oportunidades e riscos associados aos investimentos em criptoativos, bem como avaliar a eficácia de diferentes estratégias de negociação, como estratégias de momento e estratégias passivas baseadas em médias móveis exponenciais (Chu et al., 2020).

Quanto à gestão de risco (Tabela 7), a literatura sobre criptomoedas tem explorado diversas abordagens, desde modelos GARCH (Trucíos et al., 2020; Fantazzini & Zimin, 2020), Markov-switching (G. M. Caporale & Zekokh, 2019) e técnicas de wavelet (Mensi et al., 2019; Omane-Adjepong et al., 2019), que permitem analisar a dinâmica da volatilidade e a efetividade da cobertura em diferentes frequências e horizontes temporais. Essas análises podem contribuir para a identificação de estratégias de gerenciamento de risco e alocação de recursos mais eficientes (Burggraf,

Tabela 7 – Classificação dos artigos com foco em gestão de risco.

Estudos	1	2	3	4	5	6	7
G. M. Caporale e Zekokh (2019)	B	A	D	B	A, D	C	B
Mensi, Rehman, Al-Yahyaee, Al-Jarrah, e Kang (2019)	B, C	A	D	A	F	B	B
Nguyen, Chevapatrakul, e Yao (2020)	B	A	D	A	B	A	B
Hsu, Sheu, e Yoon (2021)	B	A	D	A	A	B	B
Trucíos et al. (2020)	B	A	D	A	A, D	C	B
Zhang et al. (2021)	B, D	A	D	A	B, D	A	C
Chemkha, BenSaïda, e Ghorbel (2021)	B, C	A	A	B	A, B, D	A	B
T. Cui et al. (2023)	B	A	D	B	D, E	A	B
Kaya e Mostowfi (2022)	B, C, D	A	D	A	C	B	B
J. Cui e Maghyereh (2022)	B	A	D	A	A, B, D	C	A
Zitis, Contoyiannis, e Potirakis (2022)	B	A	D	A	F	C	A
Moreno, Antoli, e Quintana (2022)	B, C	A, C, D	A	A	C	A	B
Stolfi, Bernardi, e Vergni (2022)	B, C	A	D	B	A	C	B
Białkowski (2020)	B	A	D	B	D	C	B
Bae e Kim (2022)	B	A	D	A	D, E	C	B, C
Ozdurak, Umut, e Ozay (2022)	B, C	A, D	A	B	A, C	C	B
Burggraf (2021)	B, D	A	D	A	A, C, E	B	B, C, D
Mensi, Al-Yahyaee, Al-Jarrah, Vo, e Kang (2020)	B, C, D	A	D	A	A, D	C	A
Fantazzini e Zimin (2020)	B	A	D	A	A, D	C	B
Hordei, Patsai, Hurochkina, Ovdienko, e Mishchenko (2021)	B, D	A, B, C	D	A	C	C	B
Syuhada e Hakim (2020)	B	A	D	A	A, D	C	B
Omane-Adjepong et al. (2019)	B	A, B	A, B	A	C	C	B

2021; Omame-Adjepong et al., 2019), considerando a diversificação, os spillovers de volatilidade (Nguyen et al., 2020; Hsu et al., 2021; J. Cui & Maghyereh, 2022; Ozdurak et al., 2022) e a conexão entre criptomoedas e outros ativos, como moedas fiduciárias (Chemkha et al., 2021), taxas de juros (G. M. Caporale & Zekokh, 2019) e ouro (Hsu et al., 2021; J. Cui & Maghyereh, 2022).

Além disso, a aplicação de técnicas baseadas em teoria de valor extremo (Trucíos et al., 2020), copulas e medidas de risco, como o Value-at-Risk (VaR) (G. M. Caporale & Zekokh, 2019; Nguyen et al., 2020; Trucíos et al., 2020; Chemkha et al., 2021; Fantazzini & Zimin, 2020), permite avaliar a dependência e o risco de cauda entre criptoativos, subsidiando a tomada de decisão em relação à exposição a riscos e ao gerenciamento de portfólios.

Outras abordagens exploradas na literatura incluem a utilização de técnicas de aprendizado de máquina, teoria dos grafos (Burggraf, 2021), clusterização hierárquica e modelos de séries temporais, como o VAR-VECH-TARCH (Ozdurak et al., 2022), para analisar a relação entre criptomoedas e outros ativos e identificar padrões de comovimento e conexões em diferentes escalas temporais. Além disso, o uso de dados de alta frequência (J. Cui & Maghyereh, 2022; Zitis et al., 2022), medidas de liquidez (Moreno et al., 2022) e regras de stop-loss (Kaya & Mostowfi, 2022; Białkowski, 2020) pode auxiliar na compreensão dos mecanismos que afetam a volatilidade e os retornos das criptomoedas, bem como na avaliação da eficácia de diferentes estratégias de gerenci-

amento de risco e alocação de recursos.

A análise de momentos realizados de ordem superior (J. Cui & Maghyreh, 2022) e a identificação de anomalias (Bae & Kim, 2022) e flutuações críticas (Zitis et al., 2022) também são aspectos importantes para a previsão de crises e a gestão de riscos associados a investimentos em criptoativos. Desse modo, a literatura sobre criptomoedas e gestão de risco oferece uma base sólida para a seleção e otimização de portfólios de criptoativos, contribuindo para a minimização de riscos, que sob determinadas circunstâncias e condições de mercado pode ser mais relevante que a maximização de retornos, especialmente para investidores institucionais e fundos.

Tabela 8 – Classificação dos artigos com foco na seleção de portfólios

Estudos	1	2	3	4	5	6	7
Trimborn e Härdle (2018)	C	A	A, B	B	A, C, E	A	B
Stosic, Stosic, Ludermir, e Stosic (2018)	C	A	D	A	A	C	B
Trimborn e Li (2020)	C, D	A, C, D	A	A	C, D	C	B
Maghsoodi (2023)	C	A	D	B	A, E	C	B
Bedi e Nashier (2020)	C	A	A, B	B	D	A	D
Khaki, Prasad, Al-Mohamad, Bakry, e Vo (2023)	C	A, B, C, D	D	A	C, D	A	B
Ma, Ahmad, Liu, e Wang (2020)	C	A, B, C, D	A	A	C	B	B
Demiralay e Bayracı (2021)	C	A, D	A, B	A	A	C	B
James (2022)	C	A, D	D	A	F	C	B
Kosc, Sakowski, e Ślepaczuk (2019)	C	A	D	A	C	A	B
Aggarwal (2022)	C	A	D	A	A	C	B
Mba e Mwambetania Mwambi (2022)	C, D	A	D	A	A, B	C	B
Čuljak, Tomić, e Žiković (2022)	C, D	A	D	A	C, D	C	B
X. Huang et al. (2022)	C	A, D	A	A	B, C, E	A	C
Börner et al. (2022)	C	A	D	B	C, D, F, E	C	C
Tavares, Caldeira, e Raimundo Júnior (2022)	C, D	A, D	A	A	C	A	B
Contreras-Valdez et al. (2022)	C	A, B, C, D	A	B	A	C	C
Ren, Althof, e Härdle (2022)	C	A, D	D	A	B, D	A	B
Hashemkhani Zolfani, Mehtari Taheri, Gharahgozlou, e Farahani (2022)	C, D	A	D	B	A, B, E	B	B
Chaudhari e Crane (2020)	C	A	D	A	F	C	B
Portelinha (2021)	C, D	A, D	B	B	C	A	B
Bondar, Stovpova, Ostapiuk, Biriuk, e Tsiatkovska (2020)	C, D	A, B, C, D	A	A	C	C	B

No que se refere a seleção de portfólios (Tabela 8), uma vertente importante na literatura é a aplicação de teorias e modelos financeiros clássicos, como o modelo de Markowitz e a adequada diversificação (Ozdurak et al., 2022; Bondar et al., 2020; X. Huang et al., 2022), o timing de volatilidade (Tavares et al., 2022) e o uso de medidas de performance como o índice de Sharpe (Bondar et al., 2020). Essas abordagens permitem identificar combinações ótimas de ativos, levando em consideração fatores como correlação, risco e retorno. Além disso, a utilização de técnicas baseadas em análise de séries temporais, como os modelos VAR-VECH-TARCH (Ozdurak et al., 2022), e a análise de redes e estruturas comunitárias (Chaudhari & Crane, 2020) por meio da teoria das

Tabela 9 – Classificação dos artigos com foco na otimização de portfólios

Estudos	1	2	3	4	5	6	7
Brauneis e Mestel (2019)	D	A	D	A	C	A	B
Akhtaruzzaman et al. (2020)	D	A, C, D	A	B	A	C	B
Platanakis e Urquhart (2019)	D	A	D	A	C, D	A	C
Platanakis, Sutcliffe, e Urquhart (2018)	D	A	D	A	C	A	C
Kumah e Mensah (2022)	D	A, C	D	A	B, D, F	C	B
Petukhina et al. (2021)	D	A	D	A	C, D	A	B, C, D
Hatemi-J, Hajji, Bouri, e Gupta (2022)	D	A, B, D	A	B	C	C	B
Kurosaki e Kim (2022)	D	A	D	A	A, D	A	B
Babaei, Giudici, e Raffinetti (2022)	D	A	D	A	E	A	B
Lucarelli e Borrotti (2020)	D	A	D	A	E	A	A
Tomić, Žiković, e Jovanović (2022)	D	A	D	A	B, C, D	C	B
Mba e Mwambi (2020)	D	A	D	A	A	C	B
Pradhan et al. (2021)	D	A	D	A	D	C	B
Nakano e Takahashi (2020)	D	A	D	A	E	A	A, B
Castro, Tito, Brandão, e Gomes (2020)	D	A, D	A	A	C	C	B
Terentiev, Prosiankina-Zharova, Savastiyarov, Lakhno, e Kolmakova (2021)	D	A	D	A	F	C	A
Batista e Alves (2021)	D	A, D	B	B	C	C	B
Ababio et al. (2020)	D	A, D	A, B	A	C	C	B
Schellinger (2020)	D	A	D	A	C	B	B
Ha e Moon (2018)	D	A	D	A	E	A	A
Mba et al. (2018)	D	A	D	A	A, D	C	B

matrizes aleatórias (Stosic et al., 2018; James, 2022), contribui para o entendimento das dinâmicas de mercado e a identificação de padrões e segmentações úteis para a construção de portfólios.

Outra linha de pesquisa na literatura explora o uso de técnicas de aprendizado de máquina e métodos de análise multicritério para a seleção e otimização de portfólios de criptoativos. Esses métodos incluem a aplicação de algoritmos como o CLUS-MCDA (Maghsoodi, 2023) e o PROMETHEE II, árvores de decisão e redes de memória de longo e curto prazo (LSTM) (Hashemkhani Zolfani et al., 2022). Estas abordagens auxiliam na identificação de ativos com características específicas, como a diversificação, a eficiência e a resistência a eventos sistêmicos (Ren et al., 2022). Outras técnicas utilizadas na literatura incluem a análise de frequência e o uso de modelos como o COGARCH e o GARCH, que permitem avaliar a efetividade da cobertura e o risco associado a diferentes criptoativos e estratégias de investimento.

A literatura também aborda a diversidade de criptoativos disponíveis e suas implicações nos mercados financeiros. Estudos como os de Begušić et al. (2018) analisam a relação entre criptomoedas e leis de potência, enquanto Trimbom e Härdle (2018) se concentram na construção de índices e na seleção de modelos. Outros trabalhos abordam aspectos como análise de frequência de tempo (Mensi et al., 2019), teoria de matriz aleatória (Stosic et al., 2018) e técnicas de otimização de portfólio (Maghsoodi, 2023). Essas pesquisas mostram que a literatura sobre criptomoedas é diversificada e explora várias abordagens para entender e analisar os mercados financeiros e os portfólios de criptoativos.

No que diz respeito à clusterização e seleção de bons portfólios de criptoativos, diversos autores têm contribuído com diferentes perspectivas. Por exemplo, Ma et al. (2020) discute a inovação financeira e tecnológica na diversificação de portfólio, enquanto Demiralay e Bayracı (2021) examinam a diversificação e a correlação dinâmica condicional entre criptomoedas. Outros autores, como Aggarwal (2022), investigam a otimização de portfólio e estratégias de hedge, e X. Huang et al. (2022) analisam a diversificação de portfólio e a gestão no contexto da pandemia da Covid-19.

A literatura sobre criptomoedas tem abordado a otimização de portfólios de criptoativos (Tabela 9) com ênfase em diferentes estratégias e técnicas de gerenciamento de risco e diversificação. Estudos como o de Brauneis e Mestel (2019) e Platanakis e Urquhart (2019) analisam a eficiência das estratégias de diversificação ingênua (naive diversification) em comparação com outras abordagens, como a otimização de Markowitz. Além disso, a literatura tem explorado a relação entre criptomoedas e outros ativos, como ouro e moedas fiduciárias, para avaliar o desempenho dos portfólios em termos de hedge e diversificação de riscos (Akhtaruzzaman et al., 2020; Kumah & Mensah, 2022).

Outra vertente na literatura foca na aplicação de técnicas avançadas de modelagem e algoritmos para otimizar portfólios de criptoativos. Por exemplo, Mba e Mwambi (2020) e Pradhan et al. (2021) utilizam copulas e outros métodos de otimização, como a teoria do prospecto condicional e a abordagem de evolução diferencial, para analisar a gestão de risco e a diversificação em portfólios de criptomoedas. Além disso, estudos como o de Lucarelli e Borrotti (2020) e Nakano e Takahashi (2020) exploram o uso de aprendizado profundo e redes neurais artificiais para melhorar a eficiência e a previsibilidade das estratégias de investimento em criptoativos.

Com o intuito de apontar lacunas de pesquisa provenientes da literatura, a Tabela 10 faz um cruzamento estruturado dos estudos incluídos no portfólio bibliográfico em torno de três categorias identificadas na sistematização, quais sejam: foco, ferramentas metodológicas e região. Analisando a Tabela 10, podem-se identificar algumas lacunas de pesquisa que podem ser consideradas opor-

tunidades de investigação.

Tabela 10 – Avaliação dos estudos presentes no revisão em três dimensões: foco, ferramentas metodológicas utilizadas e economia da região estudada

Foco do Estudo Região	Ferramentas Metodológicas						Total
	A	B	C	D	E	F	
Eficiência de mercado	1	6	1	1	0	4	13
Developed	○	○	○	○	○	○	0
Emerging	○	○	○	○	○	○	0
Developing	○	3	○	○	○	3	6
Not mentioned	1	3	1	1	●	1	7
Gestão de Risco	12	4	14	12	4	2	48
Developed	3	1	7	1	●	○	12
Emerging	●	○	2	●	●	○	2
Developing	●	○	○	●	●	○	0
Not mentioned	9	3	5	11	4	2	34
Seleção de portfólio	19	10	30	16	5	7	87
Developed	9	3	20	5	2	○	39
Emerging	2	○	2	1	●	○	5
Developing	●	3	○	○	●	3	6
Not mentioned	8	4	8	10	3	4	37
Otimização de portfólio	10	6	37	16	7	3	79
Developed	3	○	16	3	●	○	22
Emerging	●	○	6	○	●	○	6
Developing	●	○	●	○	●	○	0
Not mentioned	7	6	15	13	7	3	51
Total de Estudos por Ferramenta	42	26	82	45	16	16	–

^a As ferramentas metodológicas foram agrupadas em seis categorias, codificadas da seguinte forma: A- Modelos autoregressivos; B- Regressões; C- Análise de Performance; D- Medidas / gestão de risco; E- Aprendizado de Máquina e IA; F- Outros.

^b Os campos sinalizados com "●" são aquelas oportunidades compreendidas como mais interessantes/pertinentes; e os espaços vazios (○) apresentam hiatos que não demonstram claramente uma omissão da literatura, posto que não há estudos utilizando determinada metodologia ou região a ser considerada, ou mesmo possuem foco distinto dos interesses desta revisão.

^c Os números totais **não** representam fielmente a quantidade de artigos que foram contemplados nesta revisão, pois como diversos artigos possuíam mais de uma classificação em cada categoria, estes foram somados mais de uma vez na tabela dinâmica. Assim, estes apenas indicam que houve estudos que contemplaram tal cruzamento. Assim, deve-se interpretar que dada cruzamento não vazio já possui pesquisas que o abarcam, mas não seu número exato.

Fonte: Elaborado pelos autores.

No que tange à pesquisa sobre eficiência de mercado, nota-se oportunidade na metodologia de inteligência artificial, desconsiderando o aspecto econômico/regional, dado que se trata de um mercado sem fronteiras e descentralizado, com preços e liquidez determinados pela oferta e

demanda mundial.

Lacuna 1: *Avaliar a eficiência de mercado das criptomoedas utilizando aprendizado de máquina.* A eficiência de mercado das criptomoedas ainda é um tópico não consolidado na literatura acadêmica (Aslan & Sensoy, 2020), e o uso de aprendizado de máquina pode oferecer insights oportunos sobre a previsibilidade e a dinâmica de preços dessa categoria de ativos. Recentemente, empregando modelos de aprendizado de máquina, Y. Liu et al. (2023) trouxeram alguns apontamentos importantes sobre a eficiência de mercado das criptomoedas, que não atenderiam a EMH em sua forma fraca, pois variáveis como retorno defasado, clima econômico global e atenção do investidor podem prever retornos de criptomoedas, particularmente das menores. Tais pesquisas podem contribuir para uma melhor compreensão das características do mercado e ajudar investidores na tomada de decisões.

É importante destacar que avaliar a eficiência de mercado das criptomoedas considerando regiões pode não ser uma abordagem adequada, visto que o mercado de criptomoedas é global e descentralizado, o que significa que os preços e a liquidez são determinados pela oferta e demanda em todo o mundo, e não por fatores regionais específicos. Além disso, os preços tendem a convergir em diferentes plataformas de negociação e regiões a partir dos agentes de arbitragem, tornando a análise da eficiência do mercado baseada em regiões específicas menos informativa, entendendo-se mais adequado considerar o mercado em sua totalidade ao avaliar sua eficiência. Por outro lado, é relevante considerar fatores regionais ao abordar aspectos da gestão de portfólio, incluindo alocação, seleção e otimização e carteiras e sua gestão de risco, devido às variações nas condições econômicas, políticas, regulatórias, culturais e de infraestrutura. Essas diferenças podem influenciar a abordagem dos investidores e a performance dos portfólios de criptomoedas.

No quesito da gestão de risco, é possível utilizar, em conjunto ou não, as metodologias de modelos autoregressivos e medidas de gestão de risco (por exemplo, CVaR e *drawdowns*), como foi utilizado por Chemkha et al. (2021) para analisar a estrutura de dependência entre o mercado de criptomoedas e o mercado de câmbio convencional ou para identificar alternativas de hedge Ozdurak et al. (2022). Pesquisas em gestão de risco usando aprendizado de máquina também é uma lacuna a ser explorada para todas as regiões econômicas. Assim, tem-se as lacunas de 2 e 3.

Lacuna 2: *Analisar a gestão de risco de criptomoedas em mercados emergentes e em desenvolvimento utilizando modelos autoregressivos e medidas de gestão de risco (por exemplo, CVaR e *drawdowns*).* Essa combinação permite a previsão da volatilidade com base em dados históricos (modelos autoregressivos) e a avaliação do risco de perdas extremas (CVaR) ou da redução máxima do valor do portfólio (*drawdowns*), abordagem útil para investidores preocupados com a exposição a riscos extremos e que desejam uma gestão de risco baseada em estatísticas. Ozdurak et al. (2022) estudou as dependências nos eventos de risco de cauda dentro das criptomoedas e para fornecer alternativas de hedge para mercados desenvolvidos, usando VAR-VECH-TARCH. Considerando que mercados emergentes e em desenvolvimento apresentam características distintas em

relação aos mercados desenvolvidos, isso pode afetar o desempenho de portfólios incluindo criptomoedas, e a aplicação dessas metodologias pode fornecer *insights* sobre a exposição ao risco e contribuir para estratégias de mitigação de risco mais eficientes.

Lacuna 3: *Investigar a gestão de risco de criptomoedas utilizando aprendizado de máquina em diferentes tipos de mercados (emergentes, em desenvolvimento e desenvolvidos).* Diversos estudos abordam a gestão de risco de criptomoedas e a construção de portfólios utilizando técnicas avançadas, como o aprendizado profundo combinado com o CVaR (T. Cui et al., 2023), distâncias de Mahalanobis robustas (Bae & Kim, 2022) e *Hierarchical Risk Parity* (Burggraf, 2021). No entanto, a aplicação dessas técnicas em diferentes tipos de mercados, como emergentes, em desenvolvimento e desenvolvidos, ainda não foi investigada de forma abrangente. Para abordar essa lacuna, pesquisas futuras podem se concentrar na adaptação e aplicação desses métodos de gestão de risco e aprendizado de máquina em diferentes contextos de mercado, levando em consideração as características específicas desses mercados, como volatilidade, liquidez e regulamentação. Essa análise também pode ajudar a identificar novas oportunidades de investimento e melhorar a eficiência dos portfólios de criptomoedas em diversos ambientes econômicos.

Dentre os campos ainda pouco explorados, a Tabela 10 evidencia a seleção e otimização de portfólios de criptomoedas, com destaque para os países emergentes e em desenvolvimento. O uso de modelos autoregressivos e aprendizado de máquina, e até mesmo análises mais simples com métricas de performance, pode ajudar a identificar padrões e criar estratégias de investimento mais eficientes, levando em consideração as especificidades desses mercados. Assim, identificam-se as lacunas de 4 a 7.

Lacuna 4: *Desenvolver pesquisas em seleção/otimização de portfólios com criptomoedas em países emergentes e em desenvolvimento utilizando modelos autoregressivos.* Com ênfase em países desenvolvidos, Ozdurak et al. (2022) empregaram um modelo VAR-GARCH assimétrico e Akhtaruzzaman et al. (2020) aplicaram o VARMA(1,1) DCC-GARCH para estudar os efeitos de transbordamento entre criptomoedas e ativos financeiros tradicionais, buscando oferecer abordagens de alocação de portfólio ideal e estratégias de *hedge*. Contreras-Valdez et al. (2022) analisaram a interação do Bitcoin com outros ativos financeiros de economias desenvolvidas (índices dos Estados Unidos, câmbio da Europa e Japão) e de uma economia emergente (China, por meio do índice SZSE), incluindo testes ARCH.

Demiralay e Bayracı (2021) quantificaram os benefícios da diversificação de criptomoe-
das em oito mercados desenvolvidos e oito emergentes, incluindo Brasil, com base nos pesos de portfólio ótimos variantes no tempo, correlações condicionais dinâmicas (DCC), equicorrelação dinâmica (DECO) e GARCH univariado, fornecendo evidências de que os benefícios da inclusão de criptomoedas para a diversificação de carteiras variam no tempo e são altamente sensíveis a eventos externos. No entanto, ainda se identifica uma oportunidade de análise mais aprofundada das interações entre diferentes séries temporais por meio de modelos GARCH multivariados (por

exemplo, o BEKK-MGARCH e o DCC-GARCH multivariado) para países emergentes e em desenvolvimento, permitindo identificar efeitos *spillovers* e outros fenômenos relacionados aos padrões de volatilidade e correlação condicional entre as variáveis em análise. ainda há uma lacuna na literatura sobre a aplicação dessas abordagens especificamente em países em desenvolvimento, que apresentam condições econômicas e regulatórias distintas.

Lacuna 5: *Desenvolver pesquisas em seleção de portfólio de criptomoedas em países emergentes e em desenvolvimento utilizando aprendizado de máquina.* Embora diversos estudos já tenham sido realizados na área de alocação e seleção de portfólio com criptomoedas, sugere-se uma maior ênfase no uso do aprendizado de máquina para lidar com essa problemática. Conforme Maghsoodi (2023), os modelos tradicionais não são capazes de capturar os padrões não lineares e tendências de problemas complexos de previsão em comparação com a capacidade dos algoritmos de *Machine Learning* (ML) e *Deep Learning* (DL) que poderiam obter um desempenho mais notável no tempo de previsão problemas de série.

Alguns estudos já aplicam técnicas de aprendizado de máquina, como Börner et al. (2022) e Hashemkhani Zolfani et al. (2022), mas são limitados em escopo. Hashemkhani Zolfani et al. (2022) propõem um modelo de alocação de portfólio com criptomoedas usando ARIMA, LSTM e RFR para prever retornos e SlideVaR, VaR e CVaR como critérios de risco. Outros estudos, como X. Huang et al. (2022) abordam a diversificação e segmentação de mercado em criptomoe-das utilizando técnicas de *machine learning*, mas considera índices de ações e títulos de um país desenvolvido (Estados Unidos). Para abordar a lacuna, futuras pesquisas podem explorar a aplicação de técnicas avançadas de aprendizado de máquina, como redes neurais profundas e aprendizado por reforço, na seleção de portfólio com criptomoedas considerando as características econômicas e financeiras específicas dos países emergentes e em desenvolvimento.

Lacuna 6: *Desenvolver pesquisas em otimização de portfólio de criptomoedas em diferentes tipos de países (desenvolvidos, em desenvolvimento e emergentes) utilizando aprendizado de máquina.* Estudos recentes têm utilizado aprendizado de máquina para otimizar portfólios de criptomoedas e melhorar a tomada de decisões dos investidores (Babaei et al., 2022; Lucarelli & Borrotti, 2020; Burggraf, 2021; Nakano & Takahashi, 2020; Ha & Moon, 2018). Por exemplo, a abordagem de aprendizado profundo por reforço para gerenciamento de portfólio tem mostrado resultados promissores (Lucarelli & Borrotti, 2020). A programação genética é mencionada como uma opção consistente para encontrar padrões técnicos atraentes (Ha & Moon, 2018), tratando também o problema da negociação automática e dos serviços de *robot advisors* (Babaei et al., 2022), que se configuram um foco importante que necessita de mais estudos. Entretanto, os estudos mencionados não consideram a diferenciação econômica entre os tipos de países, sendo que a otimização de portfólios pode variar significativamente dependendo do contexto de mercado: países desenvolvidos, com cenários econômicos estáveis e maduros; países em desenvolvimento, que possuem desafios específicos, como flutuações cambiais, volatilidade e fatores políticos e econômicos; e,

em países emergentes, a pesquisa pode contribuir no entendimento das oportunidades e riscos associados ao investimento em criptomoedas nesses mercados, e fornecer *insights* para a criação de estratégias adaptadas a condições locais.

Lacuna 7: *Desenvolver pesquisas em otimização de portfólio de criptomoedas utilizando análise de desempenho em países em desenvolvimento.* Diversos estudos têm explorado a otimização de portfólios de criptomoedas e a diversificação de ativos tradicionais com criptomoedas, como ações e títulos em países desenvolvidos (Trimborn & Li, 2020; Hatemi-J et al., 2022; Tavares et al., 2022; Castro et al., 2020; Bondar et al., 2020) e emergentes (Portelinha, 2021; Batista & Alves, 2021; Ababio et al., 2020). Para abordar lacuna observada, pesquisas futuras podem se concentrar na análise de desempenho de portfólios de criptomoedas em países em desenvolvimento, levando em consideração fatores específicos desses mercados, como volatilidade, liquidez e regulamentação. Essa análise pode ajudar a identificar estratégias de investimento mais adequadas para esses países e aprimorar a compreensão dos investidores sobre os benefícios e riscos associados à inclusão de criptomoedas em seus portfólios. Além disso, técnicas avançadas de otimização de portfólio, como a *Liquidity Bounded Risk-return Optimization* (LIBRO) (Trimborn & Li, 2020) e a *Cumulative Prospect Theory* (CPT) (Ababio et al., 2020), podem ser aplicadas para desenvolver estratégias de investimento mais eficientes e adaptadas às condições específicas dos mercados em desenvolvimento.

**Desempenho de um sistema de negociação automatizado para criptomoedas:
comparando estratégias com o uso de estimador autoregressivo de volatilidade**

4 Desempenho de um sistema de negociação automatizado para criptomoedas: comparando estratégias com o uso de estimador autoregressivo de volatilidade

4.1 Introdução

As criptomoedas têm crescido rapidamente em capitalização de mercado nos últimos anos e, apesar da notável volatilidade, estabeleceram-se como ativos de investimento alternativos devido aos seus altos retornos médios e baixas correlações (Petukhina et al., 2021). Com o interesse crescente, tanto de bancos de investimentos e gestores de portfólio quanto do público em geral, esses ativos digitais têm sido cada vez mais discutidas como alternativas às moedas fiduciárias e investimentos tradicionais (Chu et al., 2020). Para tanto, gerenciar as flutuações de preços extremos nas criptomoedas é de importância central para os investidores neste segmento de mercado (Kaya & Mostowfi, 2022).

A definição de estratégias de negociação para o gerenciamento de portfólios, incluindo negociação algorítmica, e a seleção dinâmica de ativos para a formação do portfólio ideal são questões críticas no contexto das criptomoedas (Terentiev et al., 2021; James, 2022). Diversas metodologias foram propostas, incluindo a otimização robusta para a formação de portfólios de estratégias de negociação (Terentiev et al., 2021), a seleção de criptomoedas baseada em sua volatilidade histórica (Kaya & Mostowfi, 2022), e a análise da dinâmica evolutiva do mercado de criptomoedas (James, 2022).

Alguns dos desafios presentes ao se considerarem os criptoativos como instrumento de investimento incluem sua alta volatilidade e flutuações de preço, a dificuldade de identificação dos possíveis *scams* (tokens criados com intenção maliciosa ou que não sobrevivem), além a identificação de períodos de bolha / comportamento de manada.

Buscando contribuir para o avanço nessas questões ora expostas, delimitou-se como objeto de análise deste estudo as criptomoedas como instrumento de investimento. Para o gerenciamento do risco dos ativos, foi aplicado um modelo estatístico de volatilidade utilizando a estratégia desenvolvida por Fiorucci et al. (2022b), uma metodologia capaz de operar em quaisquer condições de mercado, baseada em quantis GARCH. Assim, o objetivo geral deste estudo foi avaliar o desempenho de uma estratégia de investimento em criptomoedas usando um estimador autoregressivo de volatilidade. Para alcançar tal objetivo, foram detalhados os seguintes objetivos específicos:

- Ajustar o estimador de volatilidade futura proposto por Fiorucci et al. (2022b) no contexto das criptomoedas;
- Implementar uma estratégia automatizada de negociação para gerenciar um portfólio de criptomoedas.

- Comparar o desempenho conjunto das estratégias automatizadas para as criptomoedas individuais com estratégias passivas *buy and hold*.

Apesar dos numerosos estudos, a volatilidade das criptomoedas ainda representa um desafio significativo para os investidores. As metodologias de seleção de portfólio aplicadas ao mercado de ações nem sempre se traduzem em ganhos de desempenho quando aplicadas ao mercado de criptomoedas (Tavares et al., 2022). A gestão de volatilidade é crucial nos mercados de criptomoedas devido às suas flutuações extremas de preço, e estratégias de investimento dinâmicas que selecionam criptomoedas com base em sua volatilidade histórica podem gerar retornos em excesso estatisticamente significativos (Kaya & Mostowfi, 2022).

A utilização de métodos de tomada de decisão consistentes no contexto de incerteza em relação ao comércio de criptomoedas permite a redução de riscos como resultado de tomadas de decisão incorretas ou atrasadas. Nesse sentido, a negociação algorítmica pode resolver o problema de formação de um portfólio com estratégias ideais de negociação, especialmente em instrumentos financeiros altamente lucrativos e arriscados, como criptomoedas (Terentiev et al., 2021).

Estratégias de negociação baseadas em momentum tem sido investigadas para os mercados de criptomoedas, com resultados sugerindo que elas podem ser usadas com sucesso em um ambiente de alta frequência (Chu et al., 2020; Kosc et al., 2019). Todavia, a eficácia dessas estratégias pode ser limitada por várias condições de mercado e parâmetros específicos (Kosc et al., 2019).

Este estudo pretende avançar nossa compreensão da negociação de criptomoedas por meio da avaliação de uma estratégia de investimento usando um estimador autoregressivo de volatilidade. Através da implementação de um sistema de negociação automatizado, este trabalho busca explorar a eficácia de tal estratégia e sua capacidade de mitigar os riscos associados à negociação de criptomoedas. Além disso, este estudo contribui para a literatura existente, explorando novas abordagens para a gestão de portfólios de criptomoedas e a aplicação de estratégias de negociação automatizadas no contexto das criptomoedas. Conforme Terentiev et al. (2021), a aplicação de estratégias automatizadas de negociação de criptomoedas pode ser benéfica para os investidores, permitindo a maximização de retornos e minimização de riscos. A contribuição desta pesquisa também reside em suas implicações práticas para os gestores de portfólio, oferecendo uma abordagem sistemática e fundamentada para a negociação de criptomoedas, considerando a volatilidade do mercado e estratégias de alocação de ativos (Kaya & Mostowfi, 2022; Terentiev et al., 2021).

Em relação ao risco, no campo dos investimentos, este se define em sentido lato como volatilidade nos retornos, o que atinge todo o mercado de renda variável mas que, no caso das criptomoedas, é um ponto particularmente sensível (Chowdhury et al., 2020). Cumpre salientar que, na ausência de um gerenciamento de risco adequado, a variação de retornos característica dos mercados voláteis pode se manifestar inclusive na forma de destruição do patrimônio investido. Dessa forma, o estudo pretende orientar os gestores de fundos e demais participantes do mercado

na construção de carteiras capazes de gerar retornos ajustados pelo risco adequados, investindo apenas em ativos criptográficos.

Cabe lembrar, conforme bem apontado por Swensen (2009), que inexistindo habilidades do investidor/gestor em tomar decisões ativas de gerenciamento de seus portfólios, como proposto neste ensaio, as estratégias passivas de baixo custo, o portfólio "ingênuo" de pesos iguais (Brauneis & Mestel, 2019; Platanakis et al., 2018; DeMiguel et al., 2009) e a estratégia de *buy and hold* (particularmente no caso das criptomoedas) (Kosc et al., 2019) atende melhor e oferece retornos superiores do que as estratégias de gestão ativa o fariam. Assim, a estrutura proposta aplicar-se-ia a investidores dispostos a buscar retornos superiores ao mercado. No entanto, este estudo visa reduzir este abismo entre as duas estratégias ao propor o desenvolvimento de um sistema de negociação automatizado e flexível para o gerenciamento de portfólios.

Este trabalho pretende contribuir para a literatura sobre criptoativos de diversas maneiras.

Para a prática, o estudo contribuirá ao agregar um algoritmo aprimorado de alto desempenho como estimador de volatilidade futura, mais adequado para tratar o problema do que um indicador que apenas espelha uma performance já ocorrida (Burggraf, 2021).

Como contribuição social, a ferramenta algorítmica produto desta pesquisa será disponibilizada publicamente, trazendo praticidade e condições mais adequadas para pequenos investidores terem a chance de lograr êxito em estratégias ativas de gestão.

4.2 Referencial teórico

4.2.1 Teoria de carteiras e gestão de risco no campo dos criptoativos

Uma carteira (ou portfólio) de investimentos pode ser caracterizada por posições em um certo número de ativos constituintes, expressos em uma moeda base (Jorion, 2011). A área de gerenciamento de portfólios é um dos domínios mais amplamente estudados na tomada de decisões financeiras, e está envolvida no projeto e gerenciamento de investimentos financeiros, geralmente constituídos por ativos do mercado de ações, bem como fundos, investimentos de renda fixa, moedas e commodities (Andriosopoulos et al., 2019).

Segundo Saksonova e Kuzmina-Merlino (2019), a seleção de uma carteira de criptomoedas deve considerar (a) os objetivos do investidor; (b) a relação entre risco e lucratividade; a ausência de correlação entre os ativos; (c) a diversificação para minimizar o risco não sistemático; (d) a liquidez das mesmas, ou seja, podem ser trocadas livremente por uma moeda fiduciária; (e) o reequilíbrio regular da carteira.

Os pesos de cada ativo na carteira podem seguir uma alocação 'ingênua' $1/N$, ou serem otimizadas de acordo com diferentes critérios. W. Liu (2019) encontraram evidências robustas de que o modelo de utilidade máxima domina o utilitário fora da amostra, mas concluiu que nenhum dos modelos consegue vencer consistentemente o portfólio ingênuo $1/N$ na razão Sharpe. Enquanto

isso, (Brauneis & Mestel, 2019) encontrou que o 1/N supera portfólios de média-variância em 75% das vezes.

DeMiguel et al. (2009) corroboraram mostrando que o 1/N foi superior a 14 modelos diferentes de otimização de portfólio em vários mercados na configuração fora da amostra. Os autores concluíram que a janela de estimativa necessária para a estratégia de média-variância seja capaz de superar o *benchmark* 1/N é de cerca de 3.000 meses para uma carteira com 25 ativos e cerca de 6.000 meses para uma carteira com 50 ativos.

A prática do mercado de investimentos e fundos de pensões, entretanto, demanda usualmente algumas condições que as otimizações teóricas deixam de considerar – como a restrição de cardinalidade máxima (que restringe o número de ativos permitidos na carteira para reduzir o custo de gestão), limites de buy-in (que define um valor mínimo a ser investido para qualquer ativo a ser incluído no portfólio, a fim de reduzir os custos de transação) ou a regra 5–10–40 (que define um limite superior para cada ativo individual e também para a soma de todos os ‘pesos pesados’ da carteira), pois tais restrições tornam o espaço de pesquisa não convexo (Branke et al., 2009).

A inserção de mais e mais ativos, sob o ponto de vista teórico da diversificação do portfólio, é uma boa solução para a minimização do risco. Observa-se, porém, que à medida que o número de ativos na carteira aumenta, o risco diminui, mas o retorno esperado da carteira também diminui independentemente para cada medida de risco (Anagnostopoulos & Mamanis, 2010), indicando um melhor desempenho de carteiras com um menor número de ativos.

Corroborando tal observação, Mansini et al. (2015) apontam alguns fatores, como as imperfeições do mercado e os custos de transação envolvidos, que criam na prática um limite para a diversificação e, quando ultrapassado, faz com que a inclusão de mais ativos diminua ganhos no investimento. Observa-se, porém, que à medida que o número de ativos na carteira aumenta, o risco diminui, mas o retorno esperado da carteira também diminui independentemente para cada medida de risco (Mamanis, 2021).

Cesarone et al. (2016), em uma pesquisa que objetivou a minimização do risco sujeito à restrição de cardinalidade, identificaram que, geralmente, os portfólios com os menores riscos são compostos de poucos ativos. Ou seja, existiria uma ‘cardinalidade crítica’ (geralmente menor que 15) capaz de minimizar o risco e, a partir dela, aumentar a quantidade de ativos significaria aumentar o risco. Além disso, constataram que, quase sempre, existe um portfólio com 10 ou menos ativos tal que a diferença entre seu risco e o menor risco dentre todos os portfólios é menor que 1%. Por sua relevância, na presente pesquisa, será considerada a restrição da cardinalidade.

A gestão de riscos é um processo essencial tanto para investidores, fundos de hedge, *traders* e formadores de mercado, e tem como ponto-chave a estimativa de medidas de risco adequadas que possam melhorar as decisões de investimento e estratégias de negociação. A alta volatilidade das criptomoedas as torna um investimento realmente arriscado e, conseqüentemente, a estimativa de medidas de risco adequadas é extremamente necessária (Trucíos et al., 2020).

O risco – ou volatilidade – de uma carteira pode ser mensurado de diversas maneiras, como o desvio-padrão, a variância-covariância, o *Value at Risk* – VaR e o *Conditional Value at Risk* – CVaR ou *Expected Shortfall* – ES. Quando se trata de uma carteira de ativos, o VaR da carteira pode ser construído a partir de uma combinação dos riscos dos títulos subjacentes (Jorion, 2011).

Em se tratando do quesito ‘risco’, o mercado de criptomoedas é caracterizado por uma volatilidade alta até mesmo em comparação com outros mercados voláteis como ações e commodities. Apesar disso, a literatura reconhece que há uma relação negativa entre a volatilidade implícita do Bitcoin e a dos Estados Unidos da América (Bouri et al., 2017), que as criptomoedas são pouco relacionadas com outros ativos (Bouri, Lucey, & Roubaud, 2019), apesar de altamente correlacionadas entre si (Katsiampa, 2019), e que a relação retorno-volatilidade do Bitcoin é negativa, inexistindo o *trade-off* risco-retorno para esta criptomoeda (Ahmed, 2020).

Para controlar o risco relacionado à volatilidade dos ativos, há várias alternativas, desde a adequada diversificação, a *Tactical asset allocation* – TAA, que sobrepondera ativos menos voláteis e subpondera os mais voláteis, regras de *stop loss*, até técnicas avançadas de previsão de volatilidade GARCH e *machine learning*. Segundo Kyriazis (2021a), modelos GARCH sofisticados explicam melhor as flutuações na volatilidade das criptomoedas. Para esses ativos, notoriamente voláteis, (Mba et al., 2018) encontrou que o GARCH-DE-t-cópula mostrou capacidade de controle de risco, confirmando a capacidade do t-copula de capturar a estrutura de dependência na cauda gorda.

Sobre a diversificação entre as criptomoedas, a literatura concorda que ela possa melhorar significativamente os resultados dos investidores (W. Liu, 2019), mas há limites para o benefício de diversificação dentro do mercado de criptomoedas, devido a quebras estruturais e *spillover* de volatilidade (Canh et al., 2019). Por outro lado, há relatos de transmissão unidirecional de volatilidade entre algumas criptomoedas, como por exemplo do Bitcoin para o Etehereum, com resposta atrasada, o que permite a obtenção de retornos anormais, já que os choques de volatilidade precisam de tempo para serem totalmente precificados (Beneki et al., 2019).

De um modo geral, Wajdi et al. (2020) recomendam carteiras diversificadas de criptomoe-das, orientam os investidores a construir suas carteiras pela avaliação dos co-movimentos entre os ativos e, além disso, a ajustar os portfólios com frequência de acordo com o tipo de criptomoeda e as condições do mercado.

Outras ferramentas gerenciam o risco individual de cada ativo, como as técnicas de *stop-loss*, que podem ajudar no gerenciamento do risco de investimento em criptoativos e são capazes de reduzir quase pela metade a volatilidade dos retornos com alguma redução dos retornos. Białkowski (2020) alerta que a taxa de sobrevivência de posições longas em criptomoedas com regras de *stop-loss* em vigor não excede 35%.

A atratividade da criptomoeda pode ser avaliada a partir de sua tendência de preço, ou seja, a direção do movimento do preço, estudada na análise técnica. As tendências podem ser ascendentes, descendentes e laterais (quando não há movimento de preço pronunciado e a linha de tendência está

se movendo dentro de uma faixa sem inclinação) (Saksonova & Kuzmina-Merlino, 2019).

Nesse sentido, a maioria dos sistemas de negociação desenvolvidos a partir de indicadores técnicos são projetados para operar em mercados de tendência ou não, mas raramente são úteis para ambos os mercados. Wilder (1978) trouxe um avanço nesse sentido ao criar o *Reaction Trend Sistem* (RTS), que permite operações em ambos os mercados (Fiorucci et al., 2022a).

4.2.2 Estado da arte sobre o gerenciamento de portfólios de criptomoedas

Koker e Koutmos (2020) apresentaram um modelo para negociação ativa baseado em aprendizado de máquina de reforço e aplicaram às cinco principais criptomoedas em circulação, demonstrando que esse modelo gera retornos ajustados ao risco aprimorados em relação a estratégia *buy and hold* e serve para reduzir o risco de queda, inclusive ao considerar os custos reais de transação. Concluíram que a aplicação do modelo de gerenciamento de portfólio no mundo real é viável, mas o desempenho pode variar de acordo com a forma como ele é calibrado em amostras de teste.

Aras (2021) comparou os desempenhos de previsão de 110 modelos do tipo GARCH e propôs um novo método de combinação baseado em *support vector machines* (SVM). Seu estudo indicou que a especificação GARCH de melhor desempenho depende da função de perda escolhida, mas o método proposto levou a previsões de volatilidade mais precisas do que as dos melhores modelos do tipo GARCH e outros métodos combinados investigados.

Na tese de Raimundo Junior (2022), foi aplicada uma abordagem baseada na dispersão transversal de ações betas individuais para extrair padrões de rebanho, usando duas metodologias dinâmicas para medir o fenômeno do rebanho ao longo do tempo, sendo que seu terceiro estudo foi com criptomoedas.

Schnaubelt (2022) apresentou uma aplicação de aprendizado de reforço profundo para otimizar a execução em exchanges de criptomoedas, aprendendo estratégias de colocação de ordens de limite ideais. Segundo os autores, a otimização da execução é altamente relevante tanto para gestores de ativos profissionais quanto para investidores privados, pois a qualidade da execução afeta o desempenho da carteira em níveis economicamente significativos.

Burggraf (2021) empregaram a abordagem de paridade de risco hierárquica, incluindo teoria dos grafos e aprendizado de máquina não supervisionado a um grande portfólio de criptomoe-das. Os autores alertam que a estimação de grandes matrizes de covariância empírica pode levar a soluções muito instáveis, com erros de estimativa que anulam os benefícios da diversificação.

Joshi, Wang, e Busler (2022) analisaram os efeitos de transbordamento da volatilidade no mercado de ações dos EUA (S&P500) e no mercado de criptomoedas usando dados intradiários durante a pandemia de COVID-19, aplicando MGARCH-BEKK e modelo de aprendizado de máquina GA(2) M baseado em algoritmo. Os autores identificaram que os choques negativos nos retornos

impactam o S&P500 e o mercado de criptomoedas mais do que os choques positivos em ambos os mercados. Além disso, concluíram que há benefício potencial da diversificação de portfólio entre o S&P500 e o mercado de criptomoedas.

X. Huang et al. (2022) examinaram os benefícios de diversificação das diversas categorias de ativos criptográficos, empregando o modelo Bayes-Stein sem restrições de vendas a descoberto e baseadas em variância para mitigar os efeitos do risco de estimativa. Considerando nove categorias de criptoativos, concluíram que todas, exceto duas, fornecem benefícios significativos de diversificação fora da amostra, sendo que quanto menor a aversão ao risco do investidor, mais benéficas são as criptomoedas como diversificadores de portfólio, mesmo durante ambientes econômicos incertos.

Chowdhury et al. (2020) aplicaram técnicas de aprendizado de máquina com o objetivo de prever os preços de fechamento das criptomoedas usando algoritmos e modelos de aprendizado de máquina para que seja mais fácil para as pessoas negociarem essas moedas. Por outro lado, considerando a alta não linearidade característica do mercado de criptomoedas, Saksonova e Kuzmina-Merlino (2019) escolheram uma linha de tendência polinomial, usada para descrever quantidades que aumentam e diminuem alternadamente, bastante útil para analisar um grande conjunto de dados em um valor instável.

Wajdi et al. (2020) investigaram o efeito assimétrico e as relações dinâmicas entre o Bitcoin e um grande conjunto de retornos de outras criptomoedas, buscando confirmar a presença do efeito contágio entre as criptomoedas. Para capturar a dinâmica do transbordamento, a análise empírica baseou-se nos modelos VAR, GJR-GARCH e DCC-GJR-GARCH, detectando a existência de correlação condicional dinâmica e um transbordamento dinâmico entre os retornos do Bitcoin e de outras criptomoedas.

Igualmente, a partir de dados horários, Mensi et al. (2020) examinaram as correlações condicionais dinâmicas e estratégias de cobertura nos principais mercados de criptomoedas. Modelos GARCH multivariados forneceram evidências de correlações condicionais dinâmicas positivas significativas entre esses mercados.

4.3 Procedimentos metodológicos

Este estudo se classifica como uma pesquisa *ex post facto*, por utilizar informações históricas para testar relações a partir das variáveis selecionadas e prever a volatilidade dos ativos em janelas rolantes já no passado; aplicada, por se dirigir a solução prática de um problema específico; quantitativa; e experimental, já que a partir dos dados coletados, será aplicado um conjunto de técnicas relacionadas à análise de séries temporais para configuração de modelos com os melhores ajustes.

4.3.1 Amostra da pesquisa e dados coletados

Para o experimento prático deste estudo, foram consideradas para a amostra todas as criptomoedas listadas com dados históricos de negociação disponíveis por meio do Yahoo Finance no período mínimo necessário para a estimação de volatilidade e realização dos testes (de 2017 a 2023).

Foi criada uma lista com todos os criptoativos disponíveis no CoinMarketCap, excluídos os *tickers* repetidos e/ou com problemas na identificação, restando 7245 *tickers*. Para estes foram coletadas as cotações de todo o período disponível, a fim de filtrar quais possuem período suficiente de dados diários para a aplicação das técnicas GARCH, incluindo estimações e *backtesting* (pelo menos 1800 observações). Identificou-se que 6184 ativos possuíam o número mínimo de observações, mas com diferentes datas de início/final e *missing values*. Assim, a amostra foi limitada aos 390 ativos com dados completos desde 17 de setembro de 2014 até 29 de abril de 2023, resultando em 3147 observações.

Dentre estes, a etapa de teste da estratégia se limitará aos criptoativos disponíveis para o Metatrader 5 (MT5) a partir da conta de corretora que tenha os dados históricos para o maior período possível. Identificou-se, assim, as criptomoedas que atendem aos requisitos de observações mínimas e presença no MT5: Bitcoin Cash (BCH), Litecoin (LTC), Ripple (XRP), Stellar (XLM), Cardano (ADA), Bitcoin (BTC), Ethereum (ETH), Basic Attention Token (BAT), Enjin Coin (ENJ). Para cada uma das criptomoedas selecionadas, foram coletados as cotações de abertura, fechamento, máxima e mínima diárias.

4.3.2 DCC-GARCH

O modelo DCC-GARCH (*Dynamic Conditional Correlations - Generalized Autoregressive Conditional Heteroskedasticity*) é uma extensão dos modelos GARCH tradicionais, desenvolvido para capturar as dinâmicas de volatilidade e correlação em séries temporais financeiras. Os modelos GARCH são conhecidos por modelar eficazmente a volatilidade condicional de uma única série temporal, mas não abordam diretamente as correlações entre séries temporais múltiplas.

O modelo DCC-GARCH, introduzido por (Engle, 2002), preenche essa lacuna ao modelar as correlações entre diferentes séries temporais de forma dinâmica, permitindo que as correlações variem ao longo do tempo. Isso é particularmente útil em Finanças, pois as relações entre diferentes ativos podem mudar em resposta a eventos de mercado e outros fatores. O modelo DCC-GARCH é amplamente utilizado em análises de carteiras de investimentos, gerenciamento de risco e outras aplicações financeiras onde a compreensão das interações dinâmicas entre diferentes ativos é crítica.

No contexto de análise de séries temporais financeiras, os modelos GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*) desempenham um papel crucial na modelagem da

volatilidade condicional. Introduzidos por Bollerslev (1986), os modelos GARCH são uma extensão natural dos modelos ARCH (*Autoregressive Conditional Heteroskedasticity*) propostos por Engle em 1982. A principal característica dos modelos GARCH é que eles permitem que a variância condicional de uma série temporal seja uma função tanto dos valores passados dos erros ao quadrado (como no modelo ARCH) quanto de suas próprias *lagged* (defasadas) variações. A inclusão de variações defasadas na variância condicional torna os modelos GARCH mais flexíveis e capazes de capturar várias formas de heterocedasticidade condicional em séries temporais financeiras.

O modelo GARCH padrão é frequentemente denotado como GARCH(p, q), sendo p a ordem dos termos autoregressivos e q é a ordem dos termos de médias móveis. Assim, um modelo GARCH permite que a volatilidade seja uma função tanto dos erros quadrados passados (termos ARCH) quanto das volatilidades passadas (termos GARCH).

Em Finanças, é importante considerar não apenas as volatilidades das séries temporais individualmente, mas também as correlações entre elas. Essas correlações podem, assim como as volatilidades, ser dinâmicas e exibir comportamento condicionalmente heteroscedástico. Em outras palavras, a força da relação linear entre pares de séries temporais pode variar ao longo do tempo em resposta a eventos de mercado, alterações nas condições macroeconômicas, entre outros fatores. As correlações condicionalmente heteroscedásticas são particularmente relevantes no gerenciamento de riscos e na otimização de carteiras, onde a correlação entre diferentes ativos pode ter um impacto significativo na diversificação do risco e no desempenho geral da carteira.

O modelo DCC, como uma extensão dos modelos GARCH, foi desenvolvido para capturar a natureza dinâmica das correlações entre séries temporais financeiras (Engle, 2002). O modelo DCC assume que a matriz de correlações entre diferentes séries temporais é dinâmica e pode variar ao longo do tempo. A matriz de correlação é transformada em cada etapa do tempo para garantir que ela seja positiva e definida, o que é uma propriedade necessária para qualquer matriz de correlação válida. A transformação garante que a matriz de correlação estimada não apenas satisfaça as restrições matemáticas, mas também capture de maneira efetiva as correlações dinâmicas que são fundamentais na modelagem de séries temporais financeiras.

Para modelar as correlações dinâmicas, (Engle, 2002) propôs o modelo DCC que formula a matriz de correlação condicional R_t como uma função das inovações passadas e suas correlações de longo prazo. No modelo DCC-GARCH, a matriz de covariância condicional H_t é decomposta em uma matriz diagonal de volatilidades condicionais D_t e uma matriz de correlações condicionais R_t . A equação de volatilidade DCC-GARCH pode ser expressa como:

$$H_t = D_t^{1/2} R_t D_t^{1/2} \quad (4.1)$$

O modelo GARCH é definido pelas Equações 4.2 e 4.3, sendo h_t a volatilidade (variância) ϵ_t o termo de erro. A volatilidade GARCH é definida pelo intercepto ω e pelos parâmetros α mul-

tiplicado pelo retorno ao quadrado do tempo passado e β multiplicado pela volatilidade do tempo passado.

$$Y_t = \sqrt{h_t} \epsilon_t \quad (4.2)$$

$$h_t = \omega + \alpha Y_{t-1}^2 + \beta h_{t-1} \quad (4.3)$$

Em que: α e β são parâmetros a serem estimados, $\bar{R}$ é a média de longo prazo das correlações, e ϵ_t é o vetor de inovações.

4.3.3 Estratégias de gerenciamento do investimento

A estratégia automatizada de negociação *Reaction Trend System* – RTS (Wilder, 1978; Fiorucci et al., 2022b, 2022a) propõe-se capitalizar os movimentos de preço em mercados tanto de tendência quanto não tendenciais, utilizando uma combinação de modos de reação e tendência, sendo que cada modo utiliza bandas específicas para sinalizar pontos de entrada e saída. No modo "Reação", as bandas definem um intervalo onde se espera que o preço oscile, enquanto no modo "Tendência", a estratégia busca identificar e se aproveitar de movimentos direcionais mais robustos. A lógica subjacente é fundamentada no cálculo do ponto de pivô, uma métrica amplamente reconhecida na análise técnica para determinar níveis de suporte e resistência.

O algoritmo, proposto inicialmente por (Wilder, 1978) e modificado por (Fiorucci et al., 2022a), começa calculando o ponto de pivô usando a média dos preços de alta (H), baixa (L) e fechamento (C) do dia anterior. Em seguida, ele calcula quatro pontos de ação de preço críticos: B1, S1, HBOP e LBOP, que representam, respectivamente, os pontos de compra, venda, ruptura alta e ruptura baixa.

A estratégia RTS-GARCH trabalha com duas séries temporais, uma de máximas e outra de mínimas. Os pontos S1 e B1, acionados na estratégia de reação, consideram os quantis 75% e 25% da probabilidade condicional da distribuição de retornos, respectivamente.

$$S1 = \exp \left[\sqrt{\frac{h_t}{100}} U B^*(75\%) \right] H_{t-1} \quad (4.4)$$

$$B1 = \exp \left[\sqrt{\frac{h_t}{100}} L B^*(25\%) \right] L_{t-1} \quad (4.5)$$

A partir da probabilidade condicional da distribuição de retornos, são definidos os pontos de ruptura definidores da estratégia de tendência: HBOP (*High breakout point*) – Equação 4.6 e LBOP (*Low breakout point*) – Equação 4.7, com probabilidades muito baixas de serem alcançados (5% ou 2.5% para cada lado, na configuração sugerida). As bandas UB (*upper bounds*) e LB (*lower bounds*) são calculadas a partir das séries de preços de alta (H) e de baixa (L), respectivamente.

Algorithm 1 Algoritmo: Estratégia RTS-Garch

```

1:  $X\_bar \leftarrow (H + L + C)/3$ 
2:  $B1 \leftarrow 2 \times X\_bar - H$  (substituído pela Equação 4.5)
3:  $S1 \leftarrow 2 \times X\_bar - L$  (substituído pela Equação 4.4)
4:  $HBOP \leftarrow 2 \times X\_bar - 2 \times L + H$  (substituído pela Equação 4.6)
5:  $LBOP \leftarrow 2 \times X\_bar - 2 \times H + L$  (substituído pela Equação 4.7)
6: if hoje é dia "B" then
7:   Atualizar posições vendidas:  $TP = B1$ ;  $Stop = HBOP$ 
8:   if Preço  $\in [B1, LBOP]$  then
9:     Comprar com  $Stop = LBOP$  e  $TP = HBOP$ 
10:  end if
11:  Encerrar posições vendidas no final do dia
12: else if hoje é dia "O" then
13:   Atualizar posições compradas:  $TP = S1$ ;  $Stop = LBOP$ 
14:   Encerrar qualquer posição aberta no fechamento
15: else if hoje é dia "S" then
16:   if Preço  $\in [S1, HBOP]$  then
17:     Vender com  $Stop = HBOP$  e  $TP = LBOP$ 
18:   end if
19: end if
20: if Preço  $> HBOP$  or Preço  $< LBOP$  then
21:   Ativar modo "Trend"
22:   if Preço  $= HBOP$  then
23:     Comprar com  $Stop =$  mínimo dos últimos dois dias
24:   else if Preço  $= LBOP$  then
25:     Vender com  $Stop =$  máximo dos últimos dois dias
26:   end if
27:   Continuar ordem até trailing stop (mínimo dos últimos dois dias no caso de compra, máximo dos últimos dois dias no caso de venda)
28: end if

```

$$HBOP = \exp \left[\sqrt{\frac{h_t}{100}} UB^*(97.5\%) \right] H_{t-1} \quad (4.6)$$

$$LBOP = \exp \left[\sqrt{\frac{h_t}{100}} LB^*(2.5\%) \right] L_{t-1} \quad (4.7)$$

O modo "Reação" é projetado para um mercado não tendencial e pode utilizar a sequência "B", "O", "S", "B", "O", "S" para determinar a ação de negociação. Em dias "B", as posições vendidas são atualizadas e uma operação de compra é considerada. Em dias "O", todas as posições são encerradas no final do dia. Já em dias "S", uma operação de venda é iniciada.

O modo "Tendência" é ativado quando um dos pontos de *breakout* (HBOP ou LBOP) é atingido, indicando uma possível tendência emergente no mercado. Neste modo, o sistema tenta

capitalizar movimentos de tendência estendidos, mantendo posições até que um *trailing stop* seja atingido. Ao combinar esses dois modos, a estratégia visa otimizar retornos em diferentes condições de mercado, permitindo flexibilidade e adaptabilidade na tomada de decisões de negociação.

Para a presente pesquisa, cada ativo foi operado seguindo a estratégia RTS-GARCH, utilizando o percentual a ele destinado na definição da carteira. Esta carteira dinâmica de rebalanceamento contínuo foi comparada com a estratégia passiva 1/N (carteira ingênua), *buy and hold* e também com rebalanceamento periódico, mensal e semestral.

4.3.4 Softwares e pacotes utilizados

Foram utilizados nesta pesquisa o *software* Metatrader 5 para coleta de dados; e, para desenvolvimento da pesquisa foram construídos algoritmos em linguagens R e Python. O R foi utilizado para também para coletar, assim como preparar e filtrar os dados. O pacote ‘quantmod’ em R foi usado para coletar dados históricos de ativos, incluindo preços diários de abertura, fechamento, máximos e mínimos. Os dados foram obtidos do Yahoo Finance usando a função ‘getSymbols’ do pacote ‘quantmod’ (Ryan, Ulrich, Thielen, Teetor, & Bronder, 2013).

Para o tratamento da volatilidade do conjunto de dados, um modelo Bayesiano DCC-GARCH foi aplicado utilizando R. As estimativas de parâmetros obtidas através do modelo (documento GARCH_Estimation.Rmd) (Fiorucci et al., 2022b) foram usadas como entradas para o *Expert Advisor*, estratégia de negociação a ser aplicada no MetaTrader 5.

Por sua vez, o Meta Trader 5 foi empregado para realizar *backtesting* da estratégia de negociação RTS desenvolvida com os parâmetros obtidos do modelo DCC-GARCH de (Fiorucci et al., 2022a). O Meta Trader, uma plataforma de *trading* algorítmico, permite simular como a estratégia teria se comportado no passado com os dados históricos disponíveis, além de poder ser usado para executar negociações automatizadas em tempo real usando a estratégia desenvolvida.

Os resultados da estratégia RTS-GARCH, implementada e testada no Meta Trader 5, foram exportados em excel e html para comparação com as demais estratégias. Após a construção das carteiras, a performance destas foi testada utilizando a estratégia *buy and hold*, na qual os ativos selecionados serão mantidos imutáveis na carteira pelo mesmo período utilizado na estratégia RTS, e também com rebalanceamento mensal e semestral. O retorno de cada uma das carteiras foi calculado ao longo deste período para fornecer uma medida da performance de cada estratégia.

Finalmente, a construção e análise de performance das diferentes estratégias das carteiras de investimento foi realizada usando uma combinação dos pacotes Python ‘PyPortfolioOpt’ e *empyrica*. Primeiramente, a construção das carteiras foi realizada utilizando o pacote ‘PyPortfolioOpt’, desenvolvido por Martin (2021), biblioteca que permite a implementação de técnicas de otimização moderna para definir a alocação de ativos em um portfólio. Duas abordagens de construção de carteiras foram utilizadas, sendo a primeira a estratégia de alocação 1/N, que atribui pesos

iguais a todos os ativos, e a outra uma carteira otimizada pelo *max_sharpe* (Fronteira Eficiente de Markovitz)

4.3.5 Análise de performance

O objetivo da análise de performance foi avaliar se a estratégia ativa RTS-GARCH oferece retornos consistentemente superiores em comparação às estratégias passivas 1/N, seja *buy and hold* ou com rebalanceamentos periódicos, dado que estas assumem custos de transação menores e pouco gasto de recursos, tanto de tempo quanto de máquina. Foram analisados os retornos brutos e ajustados ao risco, além de outros indicadores de performance, como o índice de Sharpe, Índice de Sortino, *Information Ratio*, *Annual Volatility*, *Max Drawdown*, *Compounded Annual Growth Rate* – CAGR, *Annual Return* e *Calmar Ratio*. Além disso, a estratégia ativa pode envolver custos de transação mais significativos devido ao alto volume de negociações, o que pode afetar os retornos líquidos.

4.4 Resultados

4.4.1 A estratégia

Para a estimação de volatilidade futura foram utilizados todos os dados disponíveis até 01 de julho de 2021 (período de aprendizado e estimação da volatilidade futura). E de julho de 2021 a 31 de julho de 2023, o período de testes no Meta Trader 5. Para os ativos com histórico mais longo, como Bitcoin e Litecoin, considerou-se a princípio a possibilidade de utilizar apenas os períodos com volume de transações e histórico mais consolidado. Entretanto, verificou-se que as estimações de volatilidade calculadas desta forma não foram tão boas quanto as que utilizaram todo o período disponível (Início em 17 de setembro de 2014 para Bitcoin e Litecoin e 09 de novembro de 2017)

No contexto de negociações automatizadas utilizando a estratégia RTS-Garch, duas configurações distintas foram analisadas em relação a diversos ativos, conforme resumido nas Tabelas 11 e 12.

A primeira configuração (Tabela 11) mostrou que ativos como ETH, ENJ e ADA obtiveram resultados líquidos positivos, com ETH liderando com um lucro de 991.47. Em contraste, ativos como BAT, BCH e LTC apresentaram as maiores perdas. O ativo BTC pôde realizar apenas uma negociação, pois foi liquidado, não havendo mais saldo para as operações subsequentes. O tempo médio de negociação variou entre os ativos, com a maioria oscilando entre dois e cinco dias, mas chegando a mais de dois meses em algumas operações com Ethereum.

Na segunda configuração (Tabela 12), que difere da primeira pela permissão de movimento do *Take Profit Reaction*, o ativo BTC destacou-se com o Lucro Líquido mais alto de todos os ativos/configurações, 65261.9, com um Índice de Sharpe também elevado de 1.08. Isso sugere que

Tabela 11 – Desempenho de Negociações usando a estratégia RTS-Garch por Ativo, com bandas C_Trend = 0,90 e C_Reaction = 0,50. Parâmetros: Operar Reaction (True), Uso de BOS (False), Mover Stop Reaction (True), Mover Stop Contrário (True), Mover Take Profit Reaction (False)

Ativo	ADA	BAT	BCH	BTC	ENJ	ETH	LTC	XLM	XRP
Negociações	70	34	24	1	86	102	18	186	156
L. Líquido	314.87	-998.99	-996.3	-1001.93	594.77	991.47	-1007.1	-738.46	506.55
F. Lucro	1.23	0.44	0.83	0	1.24	1.13	0.38	0.46	1.19
F. Recup.	0.68	-0.74	-0.18	-0.270021	0.56	0.23	-0.55	-0.77	0.55
Payoff	4.50	-29.38	-41.51	-1001.93	6.92	9.72	-55.95	-3.97	3.25
Í. Sharpe	0.32	-4.18	-2.08	-0.151362	0.66	0.22	-2.58	-2.85	0.47
T. Mínimo	0:00	0:00	0:04	118:25	0:00	39:47	0:00	0:00	0:00
T. Máximo	544:17	300:48	638:31	118:25	1097:13	1538:13	529:41	870:29	714:00
T. Médio	125:30	72:38	98:54	118:25	105:37	120:05	90:52	59:52	78:08

Tabela 12 – Desempenho de Negociações usando a estratégia RTS-Garch por Ativo, com bandas C_Trend = 0,90 e C_Reaction = 0,50. Configurações: Operar Reaction (True), Uso de BOS (False), Mover Stop Reaction (True), Mover Stop Contrário (True), Mover Take Profit Reaction (True)

Ativo	ADA	BAT	BCH	BTC	ENJ	ETH	LTC	XLM	XRP
Negociações	142	43	21	304	15	35	27	252	211
L. Líquido	-567.55	-1007.05	-996.3	65261.9	-995.17	-1000.91	-998.8	-139.5	-1002.88
F. Lucro	0.77	0.42	0.78	1.484832	0.48	0.77	0.41	0.96	0.41
F. Recup.	-0.51	-0.87	-0.27	3.59458	-0.64	-0.40	-0.67	-0.12	-0.96
Payoff	-4.00	-23.42	-47.44	214.6773	-66.34	-28.60	-36.99	-0.55	-4.75
Í. Sharpe	-0.28	-5.00	-2.55	1.085353	-5.00	-2.34	-3.41	-0.12	-5.00
T. Mínimo	0:00	0:00	0:00	0:00	31:25	0:00	0:00	0:00	0:00
T. Máximo	308:40	139:28	405:21	363:33	164:49	382:49	201:05	247:37	411:23
T. Médio	62:51	46:13	71:53	38:05	82:41	73:21	48:53	48:19	39:20

as negociações para BTC nesta configuração são de alta qualidade, proporcionando bom retorno ajustado ao risco. A alta quantidade de negociações (304) para BTC sugere que houve muitas oportunidades de negociação, e a estratégia conseguiu capitalizar sobre elas efetivamente, com um Sharpe de 1.08. Nessa estratégia, entretanto, todos os demais ativos exibiram perdas substanciais.

A estratégia RTS-Garch aplicada sob diferentes configurações produziu resultados variados para diferentes ativos. Enquanto a opção de permitir o movimento do *Take Profit Reaction* mostrou-se consideravelmente benéfica para o BTC, outros ativos não experimentaram o mesmo nível de sucesso. Estes resultados sublinham a importância de uma avaliação cuidadosa e adaptada ao ativo ao implementar estratégias de negociação e ajustes, garantindo que as decisões tomadas se alinhem aos objetivos e tolerâncias de risco específicos do *trader*.

Os resultados da otimização para diferentes criptomoedas mostram que o BTC teve a melhor configuração com a combinação TFTTT, enquanto as outras criptomoedas tiveram desempenhos superiores com TFTTF. Esclarecendo e discutindo um pouco mais os parâmetros de otimização da estratégia *Reaction Trend System*:

- *operar reaction*: Indica se o modo de reação deve ser operado ou não. T significa que a estratégia irá operar no modo "Reação", o que é útil em mercados sem tendência, nos quais espera-se que o preço oscile entre determinados pontos. Operar neste modo pode resultar em mais negociações, mas cada uma delas pode ter um retorno menor. E, quando *False*, a estratégia não opera no modo "Reação". Isso pode ser benéfico em mercados que estão claramente em tendência, evitando negociações falsas que poderiam resultar em perdas. Ambas as configurações optaram por operar no modo de reação, o que indica que as moedas frequentemente exibem comportamento oscilatório dentro das bandas de reação.
- *use BOS*: Decide se a sequência (*Buy, Observe, Sell*) deve ser usada, o que introduziria uma estrutura mais rigorosa e disciplinada de negociação. Para a maioria das criptomoedas analisadas, isso foi definido como F, uma estratégia mais flexível, significando que o padrão de alternância entre comprar e vender dias não foi considerado útil. Já para o ETH foi identificado como T, potencialmente indicando padrões mais previsíveis.
- *mov stop reaction*: Define se um *stop* móvel deve ser usado no modo Reação. Quando *True*, a estratégia ajustará o *stop loss* dinamicamente, o que pode proteger os lucros, mas também pode resultar no encerramento precoce de negociações antes que alcancem seu potencial completo. Quando *false*, o *stop loss* é estático, o que pode eventualmente resultar em maiores perdas se o mercado se mover rapidamente na direção oposta. Para todas as criptomoedas, a melhor opção foi *True*, mostrando que se beneficiam de ter *stops* móveis no modo Reação.
- *mov stop contrario*: Define se um *stop* deve ser usado quando o mercado se move na direção oposta. Para todas as criptomoedas estudadas, a configuração ideal foi T. Isso sugere que essas criptomoedas podem ter tendências mais fortes e menos reversões falsas, de forma que mover o *stop* na direção contrária pode ser benéfico para capturar maiores ganhos.
- *mov tp reaction*: Decide se um *take profit* móvel é usado no modo Reação. Se *False*, isso pode permitir que as negociações atinjam seu potencial completo. Enquanto *True* ajusta o *take profit* dinamicamente no modo Reação, protegendo os lucros, mas também podendo resultar no encerramento precoce de negociações. Para o BTC, foi definido como T, mostrando que ajustar o alvo de lucro nesse modo pode ser vantajoso. Em contraste, para outras criptomoedas, a configuração F sugere que um alvo fixo é mais apropriado.

Dentro dos parâmetros otimizados da estratégia, percebe-se que a opção de operar no modo de reação (*Operar reaction*) foi unanimemente positiva. Isso sugere que as moedas frequentemente apresentam movimentos que são bem capturados quando se opera reativamente dentro das bandas. A decisão de não usar o padrão "BOSBOS" (*Use BOS*) em muitas moedas indica que alternar entre comprar e vender diariamente pode não ser uma estratégia eficaz para a maioria dos ativos, com exceções notáveis.

Em termos práticos, ao considerar as configurações de banda 0.90 com 0.60, no modo "Reação", a amplitude maior proporciona ao preço um espaço mais amplo para oscilar, potencialmente reduzindo negociações precipitadas baseadas em movimentos de preço insignificantes. Por outro lado, no modo "Tendência", a banda de 0.90 posiciona o ponto de *breakout* mais próximo ao preço atual, possibilitando que tendências sejam identificadas mais prontamente. Em contraste, com configurações 0.95 e 0.50, a estratégia adota uma postura mais conservadora no modo "Tendência", exigindo movimentos de preço mais acentuados para acionar o ponto de *breakout*. Assim, o ajuste preciso dessas bandas é crucial para equilibrar a frequência de negociações com a qualidade dos sinais gerados, otimizando o desempenho da estratégia de acordo com as peculiaridades de cada criptomoeda.

Os testes conduzidos indicaram que a maioria das criptomoedas teve desempenho satisfatório com as configurações de banda $C_Trend = 0,90$ e $C_Reaction = 0,50$, padrão em todos os resultados aqui apresentados. No entanto, para algumas criptomoedas analisadas, o melhor desempenho apresentado na otimização completa do Metatrader foi ainda com outras larguras de banda / ajustes de parâmetros, como $C_Trend = 0,90$ e $C_Reaction = 0,60$ para a XRP (TFFTF), ADA (TFFTF) e ETH (TFTTF); $C_Trend = 0,95$ e $C_Reaction = 0,50$ para o BCH (TFTTF), ENJ (TFTTF).

Em contrapartida, ao testar combinações de larguras de banda, observou-se que bandas mais estreitas, como $C_Trend = 0,98$ ou $C_Reaction = 0,40$, foram menos eficazes para todos os ativos avaliados, gerando, potencialmente, mais falsos positivos. De fato, bandas estreitas podem induzir a mais negociações, já que os preços frequentemente tocam nos limites definidos, porém isso não necessariamente se traduz em negociações bem-sucedidas, podendo, em alguns casos, resultar em perdas.

4.4.2 A carteira

Analisando a Tabela 13 e Figura 4, o Bitcoin (BTC), Ethereum (ETH) e Ripple (XRP) foram as que apresentaram maior resiliência e ou capacidade de recuperação no período, contribuindo para os melhores resultados da carteira *Buy and Hold* em comparação com as carteiras 1/N Mensal e Semestral, que foram prejudicadas ao rebalancear seus pesos em prol de ativos em tendência continuada de baixa. Da mesma forma, estes ativos entregaram bons resultados nas carteiras ativas.

A carteira RTS TFTTF apresentou uma diversidade de resultados e, mesmo com seu desempenho negativo de -25,83%, ainda superou as carteiras tradicionais. Já a carteira RTS TFTTT apresentou um retorno estratosférico devido ao bom ajuste da volatilidade para o Bitcoin, mas a ausência do parâmetro de ajuste do *Take Profit* prejudicou todas as altcoins. Por fim, distinguindo o parâmetro de ajuste dinâmico do *Take Profit* entre Bitcoin e altcoins, foi possível chegar a um retorno de 710,32% na carteira otimizada.

A Figura 5 exibe o desempenho histórico de todas as estratégias. Nota-se que a carteira




Figura 4 – Desempenho dos Ativos Individuais a partir de um Investimento Inicial de \$1000

Tabela 13 – Valores finais dos ativos por estratégia

Ativo	B&H	1/N. Mensal	1/N Semestral	RTS TFTTF	RTS TFTTT	RTS Ótima
ADA	236.32 (-76.37%)	270.49 (-72.95%)	211.63 (-78.84%)	1314.87 (31.49%)	432.45 (-56.76%)	1314.87 (31.49%)
BAT	360.56 (-63.94%)	307.21 (-69.28%)	208.96 (-79.10%)	1.01 (-99.90%)	-7.05 (-100.70%)	1.01 (-99.90%)
BCH	507.50 (-49.25%)	697.09 (-30.29%)	436.72 (-56.33%)	3.70 (-99.63%)	3.70 (-99.63%)	3.70 (-99.63%)
BTC	872.01 (-12.80%)	341.18 (-65.88%)	294.90 (-70.51%)	-1.93 (-100.19%)	66261.90 (6526.19%)	66261.90 (6526.19%)
ENJ	264.12 (-73.59%)	287.02 (-71.30%)	208.26 (-79.17%)	1605.33 (60.53%)	4.83 (-99.52%)	1594.77 (59.48%)
ETH	880.79 (-11.92%)	312.47 (-68.75%)	259.60 (-74.04%)	1991.47 (99.15%)	-0.91 (-100.09%)	1991.47 (99.15%)
LTC	683.91 (-31.61%)	312.96 (-68.70%)	222.51 (-77.75%)	-7.10 (-100.71%)	1.20 (-99.88%)	-7.10 (-100.71%)
XLM	580.86 (-41.91%)	537.66 (-46.23%)	361.81 (-63.82%)	261.54 (-73.85%)	-2.88 (-100.29%)	261.54 (-73.85%)
XRP	1066.48 (6.65%)	434.44 (-56.56%)	348.59 (-65.14%)	1506.55 (50.65%)	860.50 (-13.95%)	1506.55 (50.65%)
Total	5452.55 (-39.42%)	3500.52 (-61.11%)	2552.98 (-71.63%)	6675.44 (-25.83%)	67553.74 (650.60%)	72928.71 (710.32%)

1/N Mensal teve um desempenho diferenciado durante os meses iniciais, que foram altistas, mas a ausência de uma estratégia que considerasse a volatilidade negativa fez com que se tornasse a segunda pior até o final do período analisado, atrás apenas da carteira 1/N Semestral. Enquanto isso, as estratégias automatizadas apresentaram resultado consistente no balanço de suas operações e visivelmente foram pouco afetadas com a reversão de tendência.




Figura 5 – Desempenho histórico das estratégias

Tabela 14 – Métricas de desempenho das estratégias / carteiras

	B&H	1/N Men- sal	1/N Semes- tral	RTS TFTTT	RTS TFTTF	RTS Ótima
Sharpe Ratio	-2.03	-1.38	-1.97	-0.78	-4.61	-0.81
Sortino Ratio	-2.55	-1.94	-2.49	-1.85	-5.83	-1.92
Alpha	-0.21	-0.04	-0.20	NaN	NaN	NaN
Beta	0.88	0.94	0.88	NaN	NaN	NaN
Information Ratio	-0.04	-0.00	-0.04	NaN	NaN	NaN
Max Drawdown	-0.82	-0.96	-0.80	-0.32	-0.57	-0.33
Annual Volatility	0.61	0.87	0.61	0.57	0.29	0.54
CAGR	-0.15	-0.26	-0.13	0.95	-0.09	1.00
Annual Return	-0.15	-0.26	-0.13	0.95	-0.09	1.00
Calmar Ratio	-0.19	-0.27	-0.16	2.96	-0.17	3.00

A Tabela 14 apresenta métricas de desempenho para as carteiras. As carteiras RTS apresentam índices Sharpe e Sortino mais favoráveis, sugerindo uma melhor relação risco-retorno quando ajustadas pelo risco de queda. A métrica Max Drawdown, que avalia a máxima queda de uma carteira antes de um novo pico, indica que as estratégias RTS são menos suscetíveis a grandes retrações, tornando-as potencialmente mais resistentes a períodos de adversidade do mercado. Em termos de crescimento, o Crescimento Anual Composto (CAGR) das carteiras RTS supera significativamente as abordagens B&H e 1/N, indicando um crescimento mais robusto ao longo do tempo.

Notadamente, as estratégias RTS exibem métricas de desempenho superiores em categorias como CAGR, Calmar Ratio e Max Drawdown, sugerindo um perfil de desempenho mais robusto e resiliente a flutuações do mercado. Por outro lado, métricas como Sharpe Ratio e Sortino Ratio indicam um perfil de risco mais elevado para as carteiras 1/N, com ou sem rebalanceamento. É

importante destacar que, dentre as estratégias de alocação 1/N, a *Buy and Hold* apresentou resultado superior às com rebalanceamento, mas com prejuízo nos índices de desempenho. Destaca-se que sua volatilidade anual foi inferior à estratégia de rebalanceamento mensal, que provavelmente forçou a compra das altcoins mais voláteis, as quais sofreram e continuaram sofrendo neste período majoritariamente de baixa no mercado de criptomoedas.

Evidencia-se que a abordagem ativa de trade, amparada pela modelagem de volatilidades GARCH personalizada para cada ativo, apresentou vantagens significativas. Em contraste, as carteiras ingênuas, mesmo com rebalanceamento, não conseguiram acompanhar o desempenho das estratégias RTS em termos de retorno ajustado ao risco. Isto sugere que, no contexto volátil e dinâmico das criptomoedas, uma estratégia ativa, informada por modelagens sofisticadas e operacionalizada de forma automatizada, pode ser preferível a abordagens mais tradicionais e passivas.

4.5 Conclusões

Os resultados da otimização do MT5 destacam a sensibilidade da estratégia RTS Garch às diferentes configurações, evidenciando a necessidade de personalização cuidadosa em mercados voláteis como o de criptomoedas. Pequenas mudanças nas configurações podem impactar significativamente o desempenho, tornando essencial a adaptação da estratégia com base na natureza do ativo e nas condições de mercado. Algumas configurações maximizam os lucros, mas também aumentam os riscos associados, sublinhando a importância de uma abordagem informada.

O consenso sobre a movimentação dos *stops*, seja no modo de reação ou na direção oposta, sugere que as criptomoedas tendem a manter movimentos fortes, durante os quais ajustar *stops* pode ser crucial para proteger ganhos e limitar perdas. Por fim, a decisão sobre se o *take profit* deve ser ajustado no modo de reação mostrou variações, indicando que, enquanto o Bitcoin pode se beneficiar de um alvo de lucro ajustável, outras moedas podem preferir um alvo fixo. Portanto, ao se aplicar estratégias de negociação, é essencial considerar a singularidade de cada ativo, garantindo uma abordagem adaptada e informada.

A estratégia mostrou ser altamente sensível às configurações, com algumas levando a prejuízos substanciais e outras a lucros significativos, indicando que a estratégia RTS Garch precisa ser calibrada cuidadosamente para cada ativo. Um estudo de backtest para nove criptomoedas demonstrou resultados consistentes em 24 meses (de julho de 2021 a 31 de julho de 2023), mas a generalização foi comprometida pelas particularidades de cada ativo, ainda que a quantidade de ativos testados contribua para a robustez da estratégia.

Baseada em uma análise detalhada das configurações da estratégia e sua aplicação em criptoativos, este estudo confirmou a eficácia e viabilidade da estratégia de negociação automatizada RTS-Garch. Destacam-se as seguintes conclusões:

1. **Estratégia Adaptativa e Personalizada:** A necessidade de ajustar as estratégias às carac-

terísticas específicas de cada ativo foi evidente, com desempenhos superiores para ativos ajustados individualmente. O Bitcoin, por exemplo, teve desempenho notavelmente superior sob a configuração que permitia o movimento do *Take Profit Reaction*, demonstrando a necessidade de ajustar as estratégias às características específicas de cada ativo.

2. **Superioridade da Abordagem Automatizada:** Comparativamente às estratégias tradicionais de investimento, como Buy and Hold e 1/N, as estratégias de negociação automatizadas demonstraram superioridade em termos de retorno ajustado ao risco. As métricas de desempenho, incluindo índices Sharpe e Sortino mais favoráveis, bem como um menor Max Drawdown, evidenciam a robustez e a resiliência das estratégias RTS frente às flutuações do mercado de criptomoedas. A estratégia RTS não apenas superou as abordagens tradicionais durante os períodos de alta do mercado, mas também demonstrou resiliência e capacidade de recuperação em fases de baixa, validando a robustez e a adaptabilidade da estratégia em diversos cenários de mercado.
3. **Importância da Modelagem de Volatilidade:** O uso de modelos de volatilidade GARCH para estimar a volatilidade futura e ajustar as operações de acordo com essas previsões mostrou-se crucial para o sucesso das estratégias automatizadas.
4. **Necessidade de Avaliação e Ajuste Contínuos:** As condições de mercado em constante mudança requerem uma abordagem dinâmica, capaz de se adaptar a novos dados para manter a eficácia operacional.
5. **Diversificação Estratégica:** A diversificação entre diferentes criptomoedas e múltiplas configurações estratégicas contribuiu para um desempenho geral positivo da carteira, apesar de algumas perdas específicas.

Concluindo, este estudo fornece evidências empíricas do potencial das estratégias de negociação automatizadas no mercado de criptomoedas. A abordagem detalhada e a análise rigorosa das operações, aliadas à modelagem avançada de volatilidade, oferecem uma nova perspectiva sobre o trade de criptoativos.

Na análise dos resultados obtidos, observa-se que a aplicação do modelo RTS-GARCH oferece uma abordagem robusta para a previsão de volatilidade em mercados financeiros. O estudo de Fiorucci et al. (2022a) destaca a eficácia dos modelos GARCH na captura de flutuações de preços, proporcionando uma base estatística sólida para a tomada de decisões de investimento. No contexto das criptomoedas, essa abordagem se mostra particularmente valiosa, dado o comportamento altamente volátil e não linear desses ativos. A implementação de estratégias automatizadas, como o RTS-GARCH, não apenas melhora a precisão das previsões de mercado, mas também facilita a diversificação de portfólios, reduzindo riscos associados a movimentos bruscos de preços. Assim, os resultados do nosso estudo corroboram a eficácia dos modelos discutidos, sugerindo que

a integração de técnicas avançadas de modelagem de volatilidade pode otimizar o gerenciamento de portfólios de criptomoedas. Futuras pesquisas podem explorar outras técnicas de modelagem de volatilidade e frequências de tempo maiores, semanal por exemplo, para que as estratégias de negociação automatizadas atendam diferentes perfis de investidores.

Uma abordagem de aprendizado profundo para a seleção e otimização dinâmica de portfólios

5 Uma abordagem de aprendizado profundo para a seleção e otimização dinâmica de portfólios

5.1 Introdução

5.1.1 Contextualização

O mercado de criptomoedas tem ganhado crescente importância no cenário financeiro global. Caracterizadas pela descentralização e uso de tecnologia de criptografia *blockchain*, as criptomoedas oferecem alternativas ao sistema financeiro tradicional, ao permitir transações seguras, transparentes e sem intermediários. No entanto, sua natureza volátil e em constante evolução apresenta desafios únicos para investidores e pesquisadores interessados em explorar seu potencial de retorno e diversificação de portfólio.

No contexto do gerenciamento de portfólio, esses desafios se tornam ainda mais evidentes, dado a alta volatilidade e as estruturas descentralizadas das criptomoedas. Essas características peculiares podem comprometer a eficácia de estratégias tradicionais de gestão de portfólio, que falham em lidar eficientemente com as informações de mercado (J. Li, Zhang, Yang, & Chen, 2023).

Uma abordagem inovadora para esse impasse é o Aprendizado por Reforço (*Reinforcement Learning* - RL). Os agentes RL, orientados a objetivos, buscam maximizar recompensas e minimizar perdas, o que os torna adequados para o desafio de gerenciar portfólios em mercados dinâmicos e abertos como o das criptomoedas, cuja estrutura e sua disponibilidade de informações ao público tornam essa abordagem particularmente promissora (Lucarelli & Borrotti, 2020).

A pesquisa em gerenciamento de portfólio baseado em RL tem avançado de maneira significativa, representando um marco importante no cenário financeiro, especialmente em mercados não estacionários, como o de criptomoedas (J. Li et al., 2023). Resultados positivos foram demonstrados na otimização de sistemas automatizados de negociação no domínio das criptomoedas, apesar dos desafios associados à otimização de parâmetros em estratégias de negociação, enfatizando a importância da continuação dessas investigações (Tran, Pham-Hi, & Bui, 2023).

Adicionalmente, existe uma lacuna na literatura em relação ao estudo de abordagens para otimização de parâmetros em estratégias de negociação. O uso do RL pode se mostrar uma abordagem eficaz para preencher essa lacuna (Tran et al., 2023). Problemas de negociação e otimização de portfólio podem ser encarados como uma tomada de decisões em um espaço de ação grande e complexo, cenário propício para a aplicação do RL.

Por outro lado, o cenário distinto que o mercado de criptomoedas levanta questões sobre a aplicabilidade da hipótese dos mercados eficientes de Fama (1970), a qual assume que os preços dos ativos refletem todas as informações disponíveis. As peculiaridades deste mercado, como

a descentralização e a falta de regulamentação (Lucarelli & Borrotti, 2020; Almeida & Gonçalves, 2022), podem resultar em características distintas, como a volatilidade persistente e a longa memória dos preços, especialmente em ativos menores (Aydoğan, Vardar, & Taçoğlu, 2022).

Tendo em vista esse contexto, abordagens adaptativas e fractais têm sido consideradas para entender a dinâmica do mercado de criptomoedas (Cao & Ling, 2022; Kristjanpoller et al., 2022; Nkrumah-Boadu et al., 2022; Kristoufek & Vosvrda, 2019). A noção de fractalidade sugere a presença de padrões semelhantes em diferentes níveis de detalhe, o que pode ser explorado por técnicas de aprendizado de máquina, como o RL, para melhorar as estratégias de negociação, pois essas abordagens reconhecem a natureza dinâmica e não linear dos mercados, que podem exibir comportamentos repetitivos em diferentes escalas de tempo.

Considerando a natureza volátil e a ampla variedade de criptomoedas, é importante explorar estratégias adaptativas de investimento que levem em conta as características específicas desses ativos digitais. Capaz de aprender e lidar simultaneamente com uma vasta gama de aspectos não suportados por técnicas tradicionais, o *Deep Reinforcement Learning* - DRL combina o RL com redes neurais profundas, o que confere um alto grau de acurácia e eficiência na identificação e exploração de padrões em grandes conjuntos de dados e se adapta às condições do mercado, tornando-se uma opção potencialmente viável para a seleção e otimização de carteiras de criptomoedas.

Esta pesquisa busca investigar e validar a aplicação do DRL na seleção e otimização de carteiras de investimento em criptomoedas com diferentes tamanhos de mercado e liquidez. A inclusão das criptomoedas menores e com menor liquidez como parte da análise oferece um desafio interessante para a aplicação de técnicas avançadas de aprendizado de máquina, já que esses criptoativos podem apresentar uma eficiência de mercado diferente daquelas com maior capitalização e liquidez, criando um cenário propício para explorar abordagens mais sofisticadas e adaptativas (Aggarwal, 2022).

5.1.2 Problema de Pesquisa e Objetivos

Diante desse contexto, surge o seguinte problema de pesquisa: Como a aplicação de modelos DRL pode contribuir para a seleção e otimização de carteiras de investimento compostas por criptomoedas com diferentes características de tamanho, liquidez e também levando em conta os custos de transação associados às negociações?

O objetivo desta pesquisa é verificar a efetividade e o desempenho de abordagens de *Deep Reinforcement Learning* em portfólios de investimento composto por criptomoedas, considerando diferentes características de tamanho, e liquidez e os custos de transação associados às negociações.

A fim de alcançar o objetivo proposto, foram delineados os seguintes objetivos específicos:

1. Selecionar criptoativos com diferentes características de tamanho (*Market Cap*) e liquidez (volume de negociação e/ou quantidade de corretoras nas quais é listado), visando a formação

de carteiras diversificadas.

2. Implementar um modelo de DRL para a seleção e otimização de carteiras compostas exclusivamente por criptomoedas de grande liquidez e capitalização de mercado e carteiras que combinem ativos de alta e baixa liquidez/tamanho, considerando o impacto das diferentes características no desempenho das carteiras.
3. Comparar o desempenho das carteiras de investimento compostas por criptomoedas com diferentes características de tamanho e liquidez, utilizando tanto a abordagem de DRL quanto outras estratégias, como *buy and hold* igualmente ponderada 1/N e *benchmarks*.
4. Analisar a sensibilidade das carteiras de criptomoedas às variações nos custos de transação, identificando os limites em que esses custos afetam a eficácia das estratégias de seleção e otimização.
5. Verificar se o modelo de DRL supera outras abordagens em termos de desempenho e rentabilidade das carteiras de investimento.
6. Ponderar as implicações dos achados para a eficiência do mercado de criptomoedas.

5.1.3 Justificativa e Contribuições

A justificativa para esta pesquisa reside na necessidade de abordagens mais avançadas e eficazes para a gestão de carteiras de investimento em criptomoedas, considerando as oportunidades e desafios apresentados pelas criptomoedas menores em relação às maiores. Já foi apontado que as criptomoedas menores podem ser menos eficientes e apresentar maior volatilidade, tornando-se um terreno fértil para a aplicação de técnicas avançadas de aprendizado de máquina, como o *Reinforcement Learning*. Nesse contexto, o uso de modelos DRL surge como uma abordagem promissora para explorar as características das criptomoedas menores e/ou menos líquidas e adaptar as estratégias de investimento de forma mais precisa. A natureza descentralizada e em constante evolução das criptomoedas proporciona um ambiente rico em dados que podem ser explorados por algoritmos de aprendizado de máquina. Essa abordagem permite que os investidores aproveitem as oportunidades de lucro oferecidas por essas criptomoedas, enquanto gerenciam os riscos associados à sua menor eficiência.

Além disso, esta pesquisa busca preencher uma lacuna na literatura existente, que muitas vezes se concentra em estratégias tradicionais de investimento em criptomoedas de maior porte. Ao explorar a aplicação de modelos DRL em criptomoedas menores, pretende-se fornecer uma compreensão mais aprofundada das oportunidades e desafios específicos apresentados por esse subconjunto do mercado (Aggarwal, 2022). Assim, esta pesquisa busca contribuir para o desenvolvimento de abordagens mais sofisticadas e automatizadas, capazes de lidar com a complexidade e

volatilidade de todo o mercado de criptomoedas, considerando fatores como tamanho, liquidez e custos de transação, gerando resultados mais robustos e consistentes.

Ademais, esta pesquisa busca investigar e validar a hipótese de que os mercados de criptomoedas, devido à sua natureza descentralizada, volátil e em constante evolução, apresentam características distintas que os tornam mais adequados à abordagem adaptativa e fractal, em contraste com a visão tradicional dos mercados financeiros eficientes. Nesse sentido, a aplicação de técnicas avançadas, como o DRL, torna-se fundamental para capturar padrões e comportamentos não aleatórios presentes nas criptomoedas que podem ser explorados para a seleção e otimização de carteiras de investimento, adaptando as estratégias de investimento com base em *feedbacks* e recompensas ao longo do tempo.

Assim, espera-se que o modelo DRL, por meio dessa abordagem adaptativa combinada com a capacidade de aprendizado contínuo do modelo, possa melhorar a seleção de ativos e a otimização de carteiras de criptomoedas, permitindo aos investidores explorar oportunidades de lucro em cenários dinâmicos e imprevisíveis. Dessa forma, esta pesquisa busca contribuir para o avanço do conhecimento no campo dos investimentos em criptomoedas, desafiando a visão tradicional dos mercados eficientes e explorando a adaptabilidade, os padrões fractais e a previsibilidade limitada para aprimorar as estratégias de investimento através do uso de técnicas avançadas de aprendizado de máquina.

Em relação a contribuição teórica, a aplicação de DRL na seleção e otimização de carteiras de investimento em criptomoedas amplia o conhecimento no campo da inteligência artificial aplicada ao mercado financeiro, especificamente no contexto das criptomoedas. A análise das diferentes características de tamanho e liquidez das criptomoedas e seu impacto nas estratégias de investimento proporciona uma compreensão mais profunda sobre a dinâmica desses ativos digitais.

Já para a prática/mercado, a aplicação do DRL na seleção e otimização de carteiras de criptomoedas oferece uma abordagem inovadora e automatizada para investidores, permitindo a adaptação contínua às condições de mercado e a identificação de oportunidades de investimento. Com a crescente importância e popularidade das criptomoedas, o desenvolvimento de abordagens mais sofisticadas para gerenciar portfólios nesse mercado em rápida evolução é crucial. A análise dos custos de transação associados às negociações de criptomoedas fornece informações práticas sobre os custos envolvidos nas operações, ajudando os investidores a otimizar suas estratégias e minimizar os impactos negativos desses custos. Os resultados podem ajudar a melhorar a eficiência e a rentabilidade das carteiras de investimento em criptomoedas, proporcionando uma vantagem competitiva para instituições financeiras, fundos de investimento e *traders* ativos.

Por fim, considerando o crescente interesse e participação do público geral no mercado de criptomoedas, a pesquisa contribui socialmente ao fornecer uma base científica para a tomada de decisões de investimento nesse setor. Ao investigar estratégias de alocação de ativos e considerar as características de tamanho, liquidez e custos de transação, o estudo pode ajudar a proteger inves-

tidores contra decisões desinformadas e promover uma maior conscientização sobre a importância da gestão adequada de carteiras em criptomoedas. Além disso, ao considerar diferentes criptomoedas e suas características, incluindo aquelas com menor liquidez e *Market Cap* menor (*small caps*), o estudo pode ajudar a promover a diversificação do mercado de criptomoedas e facilitar a inclusão de ativos menos conhecidos, ampliando as oportunidades de investimento.

5.2 Revisão teórica

O gerenciamento de portfólios de criptomoedas pode se beneficiar da utilização de algoritmos de Aprendizado por Reforço Profundo (*Deep Reinforcement Learning* - DRL). DRL é uma subcategoria de aprendizado de máquina que treina agentes para tomar decisões por meio de interação com um ambiente. No contexto de investimento em criptomoedas, esses algoritmos podem ser treinados para maximizar os retornos de um portfólio enquanto gerenciam riscos associados.

O Quadro 15 apresenta características dos algoritmos e os achados da literatura em relação a sua aplicabilidade em investimentos e em portfólios.

Algoritmo	Características	Prós / Contras	Autores
PPO (<i>Proximal Policy Optimization</i>)	- Pertence à família de métodos de gradiente de política (PG). - Usa replay de experiência. - Framework Actor-Critic. - Melhoria do algoritmo TRPO (<i>Trust Region Policy Optimization</i>), utilizando métodos de primeira ordem. - Utiliza um fator de corte (<i>clipping factor</i>) para limitar as atualizações de política.	- Adaptável a mudanças no ambiente. - Reduz a alta variância das redes de políticas. - Simples de implementar. - Robusto e alcança alta performance em diversos cenários. - Capaz de explorar um conjunto maior de características. - Menos custoso computacionalmente comparado ao TRPO. - Eficiente em treinamento com minibatch Stochastic Gradient Descent. - Viés introduzido por valores dependentes do tempo em replay de experiência.	Aboussalah, Xu, e Lee (2022), Z. Huang e Tanaka (2022), Kochliaridis, Kouloumpiris, e Vlahavas (2023), F. Li, Wang, e Zhou (2022), F. Liu, Li, Li, Li, e Xie (2021), Peng, Ang, e Lim (2022)
DDPG (<i>Deep Deterministic Policy Gradient</i>)	- Algoritmo de aprendizado profundo. - Ênfase no controle de risco no investimento de portfólio. - Framework Actor-Critic. - Resolve problemas de espaço de ação contínuo.	- Notáveis realizações em perspectiva financeira. - Combinado com a estrutura Hierarchical RL, pode controlar o risco de investimento em portfólio. - A literatura frequentemente ignora o risco de ocorrências raras de eventos catastróficos. - Tende a superestimar os valores de ação devido a erros de aproximação de função.	Lillicrap et al. (2015), Aboussalah et al. (2022), Felizardo et al. (2022), Jiang e Wang (2023), Kabbani e Duman (2022), Wang e Ku (2022), Yu, Wu, Liao, e Han (2023)

A2C (<i>Advantage Actor-Critic</i>)	- Parte do framework Actor-Critic. - Usa valor das ações previstas pelo modelo crítico para otimizar o comportamento do modelo de ator.	- Pode ser usado em arquiteturas aninhadas para seleção dinâmica de tomada de decisão. - Convergência mais rápida comparada ao modelo AC original. - Permite ações geradas para combinar melhor o ambiente e estado atual.	Yu et al. (2023), F. Li et al. (2022)
SAC (<i>Soft Actor-Critic</i>)	- Parte do Framework Actor-Critic. - Orientado a maximização da recompensa esperada e entropia da política.	- Pode ser usado em arquiteturas aninhadas para seleção dinâmica de tomada de decisão.	Yu et al. (2023), F. Li et al. (2022)
TD3 (<i>Twin Delayed Deep Deterministic Policy Gradient</i>)	- Extensão do DDPG. - Usa duas redes críticas e atraso na atualização da política.	- Reduz o viés de superestimação, o que reduz o acúmulo de erros no processo de aprendizado.	Kabbani e Duman (2022), Jiang e Wang (2023)

Tabela 15 – Comparação de Algoritmos de Aprendizado por Reforço.

Diferentes algoritmos de DRL têm sido aplicados para o gerenciamento de portfólios de investimento em criptomoedas. O PPO é destacado por sua simplicidade e adaptabilidade às mudanças no ambiente de negociação. Isso é corroborado pelo estudo de Z. Huang e Tanaka (2022), que aponta o PPO como um método eficaz para alocação de ativos em um portfólio financeiro. Além disso, Schnaubelt relatam que o PPO obteve o menor déficit de implementação total em comparação com outras estratégias, reduzindo os custos totais de transação em até 37,71%. Kochliaridis et al. (2023) menciona que o PPO é um algoritmo de alto desempenho que geralmente supera outros algoritmos de gradiente de política e baseados em valor. Além disso, F. Liu et al. (2021) e Peng et al. (2022) sugerem que o PPO é particularmente adequado para lidar com a volatilidade do mercado de criptomoedas e pode gerar lucros significativos.

O DDPG, por outro lado, é notável por sua aplicação em espaços de estado contínuos e tem sido eficaz na extensão para o controle de riscos de investimento (Aboussalah et al., 2022; Wang & Ku, 2022). O TD3 (Twin Delayed Deep Deterministic Policy Gradient) é uma extensão do DDPG que aborda problemas de superestimação de valores Q, como discutido por Jiang e Wang (2023) e Kabbani e Duman (2022), e pode ser uma alternativa promissora. Além destes, o A3C também foi mencionado como um método promissor na abordagem ator-crítico aplicada ao *trading* (Felizardo et al., 2022). A eficácia do SAC em comparação com o A2C e PPO é mencionada por F. Li et al., mas seu desempenho foi superado pela estratégia de conjunto proposta em seu estudo.

Além disso, Yu et al. propõem uma arquitetura aninhada que combina múltiplos algoritmos

de aprendizado por reforço, incluindo A2C, DDPG e SAC, para selecionar dinamicamente o agente de decisão mais adequado e gerar estratégias de negociação ótimas em mercados de ações complexos e dinâmicos. Isso sugere que uma abordagem combinada também pode ser eficaz no contexto de investimento em criptomoedas.

Dadas as características dos algoritmos e a literatura apresentada, optou-se por aplicar neste estudo os algoritmos PPO e o DDPG, que já tem se mostrado uma abordagem promissora para otimizar portfólios de criptomoedas. O PPO é especialmente atraente devido à sua simplicidade e adaptabilidade, enquanto o DDPG pode ser valioso em cenários que envolvem espaços de estado contínuos e controle de riscos. Além disso, considerar uma combinação de algoritmos pode proporcionar uma estratégia mais robusta e adaptável às complexidades do mercado de criptomoedas (Yu et al., 2023).

5.3 Procedimentos Metodológicos

5.3.1 Dados e Seleção de Criptoativos

Para a realização deste estudo, a conjunto de dados utilizado foi o mesmo previamente definido na seção 4.3.1, abrangendo os 390 ativos com dados completos desde o ano de 2017. A coleta de dados do mercado de criptomoedas foi realizada através de uma série de etapas sistemáticas para obter as informações necessárias para a seleção dos criptoativos. Foi utilizada a linguagem de programação R para a coleta dos dados diários de fechamento e volume de cada ativo. Foi utilizada a biblioteca 'quantmod' e a função *getSymbols* para extrair os dados históricos do Yahoo Finance. Para recuperar o *Market Cap* na data de início do período de pesquisa, foi utilizado o site CoinMarketCap.

Para o tamanho, foi considerado o *Market Cap* no início do período de testes, enquanto a liquidez foi avaliada a partir do volume de negociação no início do período de testes. Com base nos critérios mencionados, alguns portfólios foram agrupados com base nos critérios de tamanho e liquidez. Esses agrupamentos pretendiam que os diferentes segmentos do mercado de criptomoedas fossem representados, permitindo um estudo mais detalhado sobre o desempenho de diferentes tipos de carteiras e a eficácia da aplicação de modelos DRL na otimização dessas carteiras.

O processo de seleção das criptomoedas buscou representar a diversidade do mercado de ativos digitais com disponibilidade de dados a partir de 09/11/2017, Buscou-se filtrar o menor numero de CC que englobasse o máximo de categorias, de acordo com os dados da CoinGecko, com *developer score* diferente de zero, chegando a um conjunto de 27 criptomoedas (Tabela 16).

A diversidade das criptomoedas selecionadas é vasta, abrangendo desde criptomoedas amplamente reconhecidas como Bitcoin (BTC) e Ethereum (ETH) até ativos mais específicos como Viberate (VIB). Este conjunto diversificado permite uma análise abrangente da eficácia do modelo DRL na gestão de portfólios de criptomoedas com características distintas. Todas as criptomoedas

Tabela 16 – Criptomoedas da amostra, com Market Cap Ranking (Rnk), Score de Desenvolvimento (Dev), Score de liquidez (Liq), e data de início (Start)

Coin	Categories	Rnk	Dev	Liq	Start
Bitcoin (BTC)	Layer 1, Cryptocurrency	1	99.241	100.01	27/04/13
Ethereum (ETH)	Layer 1, Ethereum Ecosystem, Smart Contract Platform	2	97.494	95.18	06/08/15
Ripple (XRP)	Cryptocurrency	4	83.005	81.07	03/08/13
Binance Coin (BNB)	Layer 1, Ethereum / Moonriver / Polygon / BNB Chain / Avalanche Ecosystem, Smart Contract Platform, Centralized Exchange (CEX), Exchange-based Tokens	5	73.082	73.07	15/09/17
Cardano (ADA)	Layer 1, Cardano Ecosystem, Smart Contract Platform	9	70.27	72.12	17/10/17
Dogecoin (DOGE)	BNB Chain Ecosystem, Meme, Cryptocurrency	10	75.114	66.79	14/12/13
Litecoin (LTC)	Cryptocurrency	13	73.565	69.58	27/04/13
Stellar (XLM)	Smart Contract Platform, Cryptocurrency	23	87.516	62.83	05/08/14
Monero (XMR)	Privacy Coins	25	87.299	57.94	20/05/14
Decentraland (MANA)	BNB Chain/Ethereum/Polygon Ecosystem, Play To Earn, Metaverse, NFT, Entertainment	58	58.792	61.80	27/10/17
Neo (NEO)	Smart Contract Platform	71	78.441	52.64	08/09/16
Dash (DASH)	Privacy Coins, Governance, Cryptocurrency, Masternodes	103	65.377	55.66	13/02/14
Basic Attention (BAT)	Harmony/Avalanche/Polygon/Ethereum Ecosystem	112	76.3	53.59	07/06/17
Gnosis (GNO)	Smart Contract Platform, Layer 1, Ethereum /Arbitrum /Gnosis Chain Ecosystem, MEV Protection, Prediction Markets, Protocol, Decentralized Exchange (DEX), Decentralized Finance (DeFi)	118	50.522	34.13	30/04/17
Icon (ICX)	Edgware/Near Protocol Ecosystem, Smart Contract Platform	153	61.042	40.33	27/10/17
Golem (GLM)	Ethereum/Polygon Ecosystem, Business Platform	165	44.993	56.29	17/11/16
Siacoin (SC)	Near Protocol Ecosystem, Storage	180	56.344	36.63	25/08/15
Aragon (ANT)	Ethereum/Cosmos Ecosystem, Governance, Software	187	65.421	46.14	13/06/17
Lisk (LSK)	Smart Contract Platform	222	88.344	40.86	05/04/16
Nano (XNO)	Cryptocurrency	262	86.2	38.51	14/07/17
iExec (RLC)	Artificial Intelligence (AI), Ethereum Ecosystem, Oracle	276	54.872	45.47	19/04/17
Steem (STEEM)	SocialFi, Cryptocurrency	292	71.272	44.63	17/04/16
Syscoin (SYS)	Layer 2, Zero Knowledge (ZK), Identity, Masternodes	294	64.943	39.59	19/08/14
Ardor (ARDR)	Smart Contract Platform, Infrastructure	319	10.135	37.19	22/07/16
Request (REQ)	Ethereum/Polygon/Gnosis Chain Ecosystem, Business Services	368	42.075	32.15	29/10/17
Ambire AdEx (ADX)	Polygon/BNB Chain/Ethereum/Polkadot Ecosystem, Marketing, Media	641	50.077	40.24	15/09/17
Viberate (VIB)	Ethereum Ecosystem, Analytics, Music, Entertainment	953	12.5	59.95	25/10/17

selecionadas estão listadas na *exchange* Binance, o que potencialmente simplifica o processo de execução das estratégias indicadas pelos modelos.

Em seguida, o estudo procedeu com a implementação dos modelos DRL para a seleção e otimização dessas carteiras, conforme descrito nos objetivos específicos da pesquisa.

5.3.2 Implementação dos Modelos DRL

Neste estudo, optou-se por uma abordagem de Aprendizado por Reforço Profundo - DRL para a seleção e otimização de carteiras de investimento em criptomoedas. DRL combina as forças do Aprendizado por Reforço (RL) e do *Deep Learning*, permitindo que os agentes aprendam a tomar decisões ideais através da interação com o ambiente e maximizem uma recompensa cumulativa. Foram escolhidos os algoritmos *Proximal Policy Optimization* (PPO), *Deep Deterministic Policy Gradient* (DDPG) e *Soft Actor-Critic* SAC, que têm demonstrado desempenho promissor em contextos financeiros, conforme discutido na seção de revisão de literatura.

Proximal Policy Optimization (PPO) é um algoritmo de aprendizado por reforço que realiza atualizações de política não muito drásticas, para evitar instabilidade no treinamento (Aboussalah et al., 2022). As equações principais do PPO são baseadas no cálculo de uma razão de probabilidade de políticas, chamada de função de vantagem, e na minimização de uma função de perda "clipada", definida como:

$$L^{CLIP}(\theta) = \hat{\mathbb{E}}_t \left[\min(r_t(\theta) \hat{A}_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon) \hat{A}_t) \right] \quad (5.1)$$

Em que: $r_t(\theta)$ é a razão de probabilidade da política, $\hat{A}_t$ é a vantagem estimada no passo t , e ϵ é um hiperparâmetro que define o intervalo de "clipagem" para a razão de probabilidade.

O Algoritmo 2 ilustra o modus operandi do modelo PPO. Para esta pesquisa, os valores selecionados para os hiperparâmetros específicos foram `n_steps = 2048`, `ent_coef = 0.005`, `learning_rate = 0.0001`, e `batch_size = 128`.

O modelo DDPG é uma técnica de aprendizado por reforço que opera em espaços de ação contínua (Lillicrap et al., 2015), composto por duas redes neurais principais: o ator e o crítico. A rede do ator, $\mu(s|\theta^\mu)$, é responsável por aprender uma política determinística que mapeia estados para ações. A rede do crítico, $Q(s, a|\theta^Q)$, avalia o par estado-ação fornecendo uma estimativa do valor Q , que representa o retorno esperado ao se tomar uma ação em um determinado estado, sob uma política específica. Ambas as redes são inicialmente parametrizadas com pesos aleatórios e são aprimoradas iterativamente através do treinamento.

Durante o treinamento, são definidos os hiperparâmetros críticos. Para esta pesquisa, os valores adotados foram `batch_size = 128`, `buffer_size = 50000` e `learning_rate = 0.001`, parâmetros essenciais para a convergência e a eficácia do modelo.

No problema de alocação de portfólio, a cada momento de negociação t , o agente DDPG observa informações do mercado como dados OHLCV e representa essa observação como um

Algorithm 2 Proximal Policy Optimization (PPO)

```

1: Inicialize a rede da política  $\pi_\theta$  e a rede de valor  $V_\phi$  com pesos aleatórios  $\theta$  e  $\phi$ 
2: Inicialize o buffer de experiências  $\mathcal{D}$ 
3: Defina o coeficiente de entropia ent_coef, a taxa de aprendizado  $\alpha = \text{learning\_rate}$ ,
   o tamanho do mini-lote  $M = \text{batch\_size}$  e o número de passos por atualização  $T = \text{n\_steps}$ 
4: for iteração = 1, 2, ... do
5:   for ator = 1, ..., N do
6:     Execute a política  $\pi_{\theta_{old}}$  no ambiente por  $T$  passos
7:     Armazene os pares estado-ação-recompensa  $(s_t, a_t, r_t)$  no buffer  $\mathcal{D}$ 
8:     Calcule a vantagem estimada  $\hat{A}_t$  usando as recompensas e os valores estimados
9:   end for
10:  for atualização = 1, ..., K do
11:    Amostre um mini-lote de tamanho  $M$  do buffer  $\mathcal{D}$ 
12:    Calcule a razão de probabilidade  $r_t(\theta) = \frac{\pi_\theta(a_t|s_t)}{\pi_{\theta_{old}}(a_t|s_t)}$ 
13:    Calcule a função de perda clipada  $L^{CLIP}$  como:
        
$$L^{CLIP}(\theta) = \hat{\mathbb{E}}_t \left[ \min(r_t(\theta)\hat{A}_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon)\hat{A}_t) \right]$$

14:    Atualize  $\theta$  maximizando  $L^{CLIP} - \text{ent\_coef} \cdot H[\pi_\theta](s_t)$ 
15:  end for
16:  Atualize a função de valor  $V_\phi$  minimizando o erro quadrático médio
17:  Ajuste os parâmetros da política antiga:  $\theta_{old} \leftarrow \theta$ 
18: end for

```

vetor. O agente então toma uma ação, que neste contexto é equivalente a escolher um vetor de pesos para as criptomoedas no portfólio, denotado como a_t . O agente recebe uma recompensa baseada na mudança no valor do portfólio, que leva ou não em consideração o custo da transação (Wang & Ku, 2022).

Por fim, o SAC é um algoritmo de aprendizado por reforço que enfatiza a maximização da entropia da política para equilibrar a exploração e a exploração e se baseia em duas funções principais: a função de valor V e a função de vantagem Q , além de uma política estocástica π . A função de valor é otimizada para prever a soma esperada de recompensas futuras mais a entropia da política, enquanto a função de vantagem é utilizada para atualizar a política de forma a maximizar essa soma esperada com um coeficiente de entropia ajustável.

Esses algoritmos foram implementados usando a biblioteca FinRL (X.-Y. Liu et al., 2020), uma biblioteca de código aberto dedicada ao uso de DRL para finanças quantitativas. A biblioteca inclui um ambiente de negociação simulado, onde os algoritmos podem ser treinados e avaliados, e ferramentas para otimização de hiperparâmetros e avaliação de desempenho.

Algorithm 3 Deep Deterministic Policy Gradient (DDPG)

-
- 1: Inicialize a rede do ator $\mu(s|\theta^\mu)$ e a rede crítica $Q(s, a|\theta^Q)$ com pesos aleatórios
 - 2: Inicialize as redes alvo $\mu'(s|\theta^{\mu'})$ e $Q'(s, a|\theta^{Q'})$ com os pesos $\theta^{\mu'} \leftarrow \theta^\mu$, $\theta^{Q'} \leftarrow \theta^Q$
 - 3: Inicialize o buffer de repetição $\mathcal{R}$ com o tamanho `buffer_size`
 - 4: Defina o tamanho do mini-lote N como `batch_size` e a taxa de aprendizado α como `learning_rate`
 - 5: **for** episódio = 1 até M **do**
 - 6: Inicialize um processo de ruído aleatório $\mathcal{N}$ para exploração da ação
 - 7: Receba o estado de observação inicial s_1
 - 8: **for** $t = 1$ até T **do**
 - 9: Selecione a ação $a_t = \mu(s_t|\theta^\mu) + \mathcal{N}_t$ de acordo com a política atual e ruído de exploração
 - 10: Execute a ação a_t e observe a recompensa r_t e o novo estado s_{t+1}
 - 11: Armazene a transição (s_t, a_t, r_t, s_{t+1}) no $\mathcal{R}$
 - 12: Amostre um minibloco aleatório de N transições (s_i, a_i, r_i, s_{i+1}) do $\mathcal{R}$
 - 13: Defina $y_i = r_i + \gamma Q'(s_{i+1}, \mu'(s_{i+1}|\theta^{\mu'})|\theta^{Q'})$ para cada amostra no minibloco
 - 14: Atualize o crítico minimizando a perda: $L = \frac{1}{N} \sum_i (y_i - Q(s_i, a_i|\theta^Q))^2$, Em que: y_i é o alvo calculado como a soma da recompensa imediata r_i e o valor Q estimado pelo crítico alvo para o próximo estado, descontado pelo fator de desconto γ . (O objetivo é minimizar essa perda para aprimorar as estimativas do valor Q .)
 - 15: Atualize a política do ator usando o gradiente da política amostrada (que ajusta os parâmetros do ator na direção que maximiza o valor Q):

$$\nabla_{\theta^\mu} J \approx \frac{1}{N} \sum_i \nabla_a Q(s, a|\theta^Q)|_{s=s_i, a=\mu(s_i)} \nabla_{\theta^\mu} \mu(s|\theta^\mu)|_{s_i}$$

- 16: Atualize as redes alvo:

$$\theta^{Q'} \leftarrow \tau \theta^Q + (1 - \tau) \theta^{Q'}, \quad \theta^{\mu'} \leftarrow \tau \theta^\mu + (1 - \tau) \theta^{\mu'}$$

- 17: **end for**
 - 18: **end for**
-

Construção das Carteiras e comparação de desempenho

Para a construção das carteiras de investimento, os algoritmos DDPG e PPO foram empregados para otimizar as alocações de ativos em carteiras de criptomoedas com diferentes configurações de tamanho e liquidez. Como pontos de comparação, foram implementadas também a estratégia tradicional de "buy and hold", e a carteira de Mínima Variância.

O desempenho das carteiras construídas através de DRL foram então comparados com um *benchmark*, que neste caso foi o índice CRIX. Este representa o desempenho global do mercado de criptomoedas e é uma referência para avaliar se as estratégias de investimento adotadas são capazes de superar o mercado como um todo. Além disso, o Índice de Sharpe e o Índice de Sortino foram calculado para cada carteira, a fim de avaliar o desempenho ajustado ao risco.

Algorithm 4 Soft Actor-Critic (SAC)

-
- 1: Inicialize as redes de valor V_ϕ , a rede de vantagem Q_θ , e a política π_ψ com pesos aleatórios
 - 2: Inicialize o buffer de experiências $\mathcal{B}$ com capacidade `buffer_size = 100000`
 - 3: Defina o tamanho do lote de treinamento `batch_size = 128`
 - 4: Defina a taxa de aprendizado `learning_rate = 0.0003`
 - 5: Defina o início do aprendizado `learning_starts = 100`
 - 6: Defina o coeficiente de entropia `ent_coef` como "auto_0.1" para ajuste automático
 - 7: **for** cada iteração **do**
 - 8: Selecione ações de acordo com a política estocástica atual π_ψ e armazene no $\mathcal{B}$
 - 9: Após `learning_starts` iterações, amostre um lote do $\mathcal{B}$
 - 10: Atualize a rede de vantagem Q_θ minimizando a diferença do valor Q e o retorno descontado
 - 11: Atualize a rede de valor V_ϕ para minimizar o erro quadrático médio em relação ao retorno esperado e a entropia
 - 12: Atualize a política π_ψ para maximizar a expectativa do valor Q menos a entropia escalada pelo `ent_coef`
 - 13: Ajuste o `ent_coef` se configurado para ajuste automático
 - 14: **end for**
-

Este estudo focou também em avaliar se é possível construir carteiras compostas por ativos menores e menos líquidos, mas que ainda assim apresentem uma boa relação retorno/risco. Isso é especialmente importante no mercado de criptomoedas, onde os ativos menores podem, às vezes, oferecer oportunidades de retornos significativos. Paralelamente, uma análise de sensibilidade aos Custos de Transação foi realizada para avaliar o impacto destes nas estratégias de seleção e otimização de carteiras. Essa análise comparou o desempenho e a rentabilidade das carteiras em diferentes condições de custos, identificando os limites em que os custos de transação afetam significativamente a eficácia das estratégias.

Por fim, com os resultados obtidos, foram feitas análises comparativas entre as diferentes estratégias e configurações de carteira. Através destas análises, será possível compreender quais abordagens e combinações de ativos resultaram em um melhor desempenho ajustado ao risco. Também será essencial analisar a estabilidade e a robustez das carteiras ao longo do tempo.

5.4 Resultados

Esta seção apresenta os resultados obtidos a partir da implementação dos modelos de aprendizado por reforço profundo (DRL) - especificamente SAC, DDPG e PPO - na seleção e otimização de carteiras de investimento em criptomoedas, em comparação com as estratégias tradicionais Buy and Hold (B&H) e o portfólio de Mínima Variância (MV ou MinVar).

Ao considerar ambientes de mercado com e sem custos de transação, buscou-se entender não somente o impacto destes custos na performance dos modelos, mas também avaliar a eficácia das estratégias DRL frente a abordagens mais estabelecidas.

Tabela 17 – Estatísticas Descritivas dos Retornos das Criptomoedas

Criptomoeda	Média	Mediana	Desvio Padrão	Mínimo	Máximo	Assimetria	Curtose
ADA-USD	0.0033	-0.0000	0.0717	-0.3957	1.3668	5.2572	82.3807
ADX-USD	0.0022	-0.0001	0.0847	-0.4510	1.1880	3.4597	36.8238
ANT-USD	0.0031	0.0007	0.0726	-0.5410	0.4987	0.4988	5.8793
ARDR-USD	0.0016	0.0012	0.0660	-0.3803	0.6684	1.4416	14.9498
BAT-USD	0.0021	-0.0001	0.0634	-0.4022	0.4566	0.5641	5.4628
BNB-USD	0.0039	0.0010	0.0579	-0.4190	0.6976	1.9766	23.9183
BTC-USD	0.0014	0.0009	0.0386	-0.3717	0.2525	-0.1296	7.4989
DASH-USD	0.0006	0.0002	0.0591	-0.3722	0.5704	1.2688	14.2416
DOGE-USD	0.0053	-0.0008	0.1062	-0.4026	3.5555	18.9339	603.5346
ETH-USD	0.0020	0.0008	0.0487	-0.4235	0.2646	-0.2231	5.7075
GLM-USD	0.0022	0.0018	0.0676	-0.4431	0.7263	1.4089	15.7169
GNO-USD	0.0020	0.0001	0.0613	-0.3487	0.6636	0.9759	11.7067
ICX-USD	0.0018	0.0002	0.0725	-0.4466	0.5941	0.7453	7.7177
LSK-USD	0.0009	-0.0001	0.0614	-0.4233	0.3519	0.3283	5.4692
LTC-USD	0.0016	0.0002	0.0542	-0.3618	0.4760	0.7508	9.5145
MANA-USD	0.0048	0.0010	0.0884	-0.4673	1.5474	5.7313	88.7341
NEO-USD	0.0012	0.0006	0.0605	-0.3723	0.4111	0.3592	5.7683
REQ-USD	0.0035	-0.0012	0.0936	-0.4998	2.2521	7.9778	167.6831
RLC-USD	0.0034	0.0009	0.0816	-0.5250	1.0621	2.0121	23.3259
SC-USD	0.0022	-0.0004	0.0706	-0.4606	0.7938	1.3275	13.9977
STEEM-USD	0.0016	0.0004	0.0701	-0.4764	0.7093	1.7891	19.4344
SYS-USD	0.0026	0.0002	0.0804	-0.4407	1.0223	2.2866	23.8603
VIB-USD	0.0027	0.0005	0.0878	-0.4740	1.5578	4.3898	65.0091
XLM-USD	0.0025	-0.0004	0.0627	-0.3363	0.7492	2.3845	22.9288
XMR-USD	0.0015	0.0020	0.0518	-0.4139	0.4119	-0.0743	7.8556
XNO-USD	0.0038	-0.0014	0.0835	-0.4434	1.1088	3.4391	32.9100
XRP-USD	0.0026	-0.0006	0.0661	-0.4233	0.8347	3.0581	31.6876
Geral	0.0024	0.0000	0.0700	-0.5410	3.5555	5.1822	165.3915

Por meio da Tabela 17, é possível identificar algumas características dos retornos das 27 criptomoedas selecionadas para a amostra. A maioria das criptomoedas exibe uma mediana de retorno próxima a zero, indicando um retorno marginal em muitos períodos. Ao avaliar a média dos retornos em conjunto com os desvios padrão associados, a Dogecoin apresenta uma média de retornos relativamente alta (0.0053), com desvio padrão vinte vezes maior, identificando uma volatilidade considerável, mas ainda assim é a terceira criptomoeda com menor razão entre o desvio padrão e a média, atrás da Descentraland e BinanceCoin.

Além disso, várias criptomoedas, como DOGE-USD e MANA-USD, têm distribuições de retorno altamente assimétricas, com caudas longas à direita, indicando a presença de retornos extremamente positivos. Quanto à curtose, que indica a espessura das caudas da distribuição de retorno, criptomoedas como a Dogecoin e Request exibem valores de curtose superiores, sugerindo a presença de eventos extremos (tanto positivos quanto negativos) nos retornos desses ativos. Em uma visão geral, as estatísticas apresentam uma média de retorno de 0.0024 e um desvio padrão de 0.0700, destacando a natureza volátil e potencialmente lucrativa das criptomoedas.




Figura 6 – Evolução dos retornos das criptomoedas da amostra

Pela Figura 6, nota-se que o período delimitado para *trade* foi um período de indefinição/acumulação em que, com poucas exceções, as CC da amostra apresentaram um desempenho negativo ou andaram de lado.

O pacote FinRL foi empregado para explorar o desempenho de três modelos de aprendizado por reforço profundo: SAC, DDPG e PPO no contexto do mercado de criptomoedas. Estes modelos foram analisados sob duas condições distintas: uma em que os custos de transação (*tc*) não foram considerados e outra em que esses custos, fixados em 0,1% (conforme taxados pela Binance, onde todas as criptomoedas da amostra estão listadas), foram levados em conta.

Utilizou-se como *benchmark* o CRIX - um índice específico que representa o comportamento geral do mercado de criptomoedas. Adicionalmente, para fins de comparação, foram incluídas estratégias de *Buy and Hold* (B&H) e um portfólio de Mínima Variância (MV). Embora B&H e MV não sejam propriamente *benchmarks*, foram utilizados como parâmetro para comparar a performance dos modelos de *machine learning* em comparação com outras abordagens tradicionais.

5.4.1 Desempenho dos modelos para o conjunto completo - All CC

O desempenho de todos os portfólios com a amostra completa, com e sem custos de transação, é apresentado na Figura 7a. O modelo DDPG manteve-se por quase todo o período de *trade*

Tabela 18 – Performance dos portfólios contendo as 27 criptomoedas da amostra (grupo all_CC.)

Metric	Benchmarks		No transaction cost				With transaction cost			
	CRIX	B & H	SAC	DDPG	PPO	MV	SAC	DDPG	PPO	MV
R_p	0.079	0.054	0.075	0.106	0.053	0.192	-0.018	0.007	0.054	0.032
R_{acum}	0.113	0.077	0.107	0.154	0.076	0.280	-0.025	0.009	0.076	0.046
Vol.	0.432	0.490	0.497	0.499	0.490	0.464	0.479	0.482	0.489	0.423
S	0.389	0.356	0.397	0.456	0.355	0.610	0.205	0.258	0.355	0.289
CaR	0.219	0.157	0.210	0.303	0.156	0.622	-0.049	0.018	0.157	0.106
Stab.	0.502	0.212	0.205	0.300	0.210	0.566	0.127	0.154	0.210	0.317
MDD	-0.359	-0.342	-0.355	-0.351	-0.342	-0.308	-0.368	-0.372	-0.342	-0.304
Ω	1.089	1.067	1.076	1.086	1.067	1.125	1.039	1.049	1.067	1.055
SoR	0.580	0.480	0.539	0.615	0.479	0.880	0.274	0.347	0.479	0.391
Skew	0.607		-0.618	-0.687	-0.648	0.065	-0.757	-0.691	-0.647	-0.664
Kurt.	10.040		5.703	5.400	5.814	9.374	6.373	6.501	5.811	7.911
TR	1.040	0.979	1.027	0.991	0.982	0.967	0.965	0.914	0.980	0.930
VaR	-0.054	-0.061	-0.062	-0.062	-0.061	-0.057	-0.060	-0.060	-0.061	-0.053
α	0.000	0.014	0.064	0.097	0.039	0.140	-0.035	-0.010	0.039	0.002
β	1.000	0.790	0.783	0.780	0.785	0.750	0.775	0.780	0.785	0.696

Nota: R_p = Annual return, R_{acum} = Cumulative returns, Vol. = Annual volatility, S = Sharpe Ratio, CaR = Calmar Ratio, MDD = Max drawdown, Ω = Omega Ratio, SoR = Sortino Ratio, TR = Tail ratio, VaR = Daily value at risk, α = Alpha, β = Beta.

com a melhor performance dentre todos os portfólios. Entretanto, ao final, o portfólio de Mínima Variância teve uma propulsão possivelmente justificada pelos últimos arrojados reajustes de pesos, em que aumentou sua exposição a ativos com menor valor de mercado, e implicou nos resultados da Tabela 18.

A Tabela 18 apresenta o desempenho dos portfólios gerenciados por modelos de aprendizado por reforço profundo em comparação aos *benchmarks* e ao método de Mínima Variância. Observa-se que, em termos de retorno anual R_p e retorno acumulado R_{acum} , os modelos DDPG e SAC sem custos de transação supera os *benchmarks* CRIX e B&H. No entanto, quando os custos de transação são levados em conta, o desempenho destes modelos apresentaram declínio acentuado. Por outro lado, o modelo MinVar destaca-se por seu alto retorno anual R_p e acumulado R_{acum} , superando os demais modelos, especialmente quando não considerados os custos de transação. Isso sugere que, apesar do avanço tecnológico dos modelos DRL, o método tradicional MV ainda mantém uma forte posição, especialmente em termos de eficiência de retorno.

Quanto às métricas de risco, como a volatilidade anual (Vol.), a razão de Sharpe (S), e o máximo *drawdown* (MDD), há uma variedade no desempenho dos modelos DRL. O modelo PPO apresenta uma volatilidade e um MDD similares aos *benchmarks*, indicando uma gestão de risco moderada. O portfólio MinVar demonstra uma menor volatilidade e um menor MDD em comparação com os *benchmarks* e os modelos DRL, reafirmando a sua robustez na minimização do risco. Isso é particularmente evidente ao considerar os custos de transação, quando o MV ainda apresenta um desempenho superior ao demais, exceto ao PPO, que parece acompanhar a performance do portfólio B&H. Em contraste, o modelo SAC mostra um desempenho misto, com uma boa razão



Figura 7 – All CC and All CC-tc

de Sharpe, mas um MDD e uma volatilidade relativamente altos, refletindo uma abordagem mais agressiva na busca por retornos elevados. Esta análise sugere que, enquanto os modelos DRL oferecem oportunidades promissoras para a maximização de retornos em portfólios de criptomoedas, o método MV continua sendo uma escolha sólida para investidores que priorizam a minimização de riscos, não se podendo refutar a relevância da teoria moderna de portfólios de Markowitz no contexto de mercados emergentes como o das criptomoedas. Isso sugere também que, apesar da sofisticação dos algoritmos de aprendizado por reforço profundo, eles podem não superar consistentemente os métodos tradicionais de investimento em todas as condições de mercado.

A análise da Tabela 19 revela diferenças interessantes na quantidade de rebalanceamentos realizados por diferentes estratégias de gestão de portfólio de criptomoedas, considerando cenários

Tabela 19 – Pesos dos portfólios contendo as 27 criptomoedas da amostra (grupo all_CC.)

TC	Strategy	Weights			Rebalances		
		min	mean	max	min	mean	max
não	DDPG	0.020	0.037	0.062	52	52.0	52
	PPO	0.037	0.037	0.037	0	6.1	24
	SAC	0.018	0.037	0.052	7	7.0	7
	MV	0.000	0.037	0.100	0	85.7	273
sim	DDPG	0.018	0.037	0.053	65	65.1	67
	PPO	0.037	0.037	0.038	0	2.3	19
	SAC	0.019	0.037	0.053	14	14.0	14
	MV	0.000	0.037	0.100	0	85.7	273

com e sem custos de transação. O modelo PPO mostra a menor média de variação, o que sugere uma estratégia estável e com rebalanceamentos mínimos direcionados a ativos específicos. Quando adicionados os custos de transação, a frequência de rebalanceamento foi reduzida, o que faz sentido por minimizar o impacto dos custos de transação no retorno do portfólio.

SAC e DDPG também apresentam um número consistente de rebalanceamentos do qual participaram todos os ativos, refletindo uma abordagem moderada. Curiosamente, ao introduzir os custos de transação, observou-se um aumento expressivo no número de rebalanceamentos para ambos, sugerindo que os modelos são sensíveis ao custo de transação, mas de forma contra intuitiva, pois os aumentos nas atividades de negociação podem ter implicações para o risco-retorno do portfólio. Diferentemente, o modelo MinVar apresenta uma faixa extensa de rebalanceamentos (próxima a uma por dia), indicando uma abordagem altamente dinâmica na alocação de ativos.

Tabela 20 – Estatísticas Z-score do teste LW comparando os Índices Sharpe em carteiras com custos de transação (acima da diagonal) e carteiras sem custos (abaixo da diagonal) para o portfólio all_CC.

	DDPG	MinVar	PPO	PTF	SAC
DDPG	-	0.2824	0.2349	0.2346	0.0897
MinVar	-0.1601	-	-0.0490	-0.0493	-0.1987
PPO	-0.2077	0.0489	-	-0.0003	-0.1489
PTF	-0.2103	0.0493	0.0002	-	-0.1486
SAC	0.1087	-0.1987	0.1489	0.1486	-

Nota: Os níveis de significância de 1%, 5% e 10% são representados por ★, ◆ e ●, respectivamente.

Para comparar os Índices Sharpe de diferentes estratégias de portfólio, a Tabela 20 traz os valores de Z-score do teste de Ledoit e Wolf (LW). A maioria dos Z-scores estão próximos de zero, sugerindo que as diferenças nos Índices Sharpe entre as estratégias não são estatisticamente significativas. A partir disso, em termos de Índice Sharpe, não se pode afirmar que as estratégias de portfólio analisadas têm desempenhos distintos, considerando ou não os custos de transação.



Figura 8 – Large MC and Large MC-tc

5.4.2 MC-large

Considerando portfólios compostos pelas criptomoedas mais líquidas e com maior capitalização de mercado da amostra (acima de U\$1 bilhão de Market Cap e U\$100 milhões de volume negociado na data de início dos testes), a Tabela 21 e Figura 8 apresentam suas performances e distribuições de pesos.

Visualmente, não houve uma distinção notável entre os modelos no período de testes (Figuras 8a e 8b). O modelo DDPG se sobressaiu ao final do período com o maior retorno anual R_p e acumulado R_{acum} sem custos de transação, indicando sua eficácia em maximizar retornos em condições ideais. No entanto, quando se consideram os custos de transação, o desempenho de todos os modelos exceto PPO diminuiu. Novamente, o modelo PPO acompanhou a performance do modelo

Tabela 21 – Performance dos portfólios contendo as criptomoedas acima da média de Market Cap da amostra (grupo MC-large).

Metric	Benchmarks		No transaction cost				With transaction cost			
	CRIX	B & H	SAC	DDPG	PPO	MV	SAC	DDPG	PPO	MV
R_p	0.079	0.076	0.051	0.129	0.076	0.077	0.011	0.027	0.075	0.047
R_{acum}	0.113	0.109	0.073	0.187	0.109	0.109	0.015	0.039	0.108	0.067
Vol.	0.432	0.494	0.500	0.513	0.493	0.494	0.480	0.514	0.494	0.494
S	0.389	0.394	0.350	0.489	0.393	0.394	0.262	0.308	0.392	0.338
CaR	0.219	0.238	0.144	0.394	0.239	0.240	0.033	0.076	0.236	0.147
Stab.	0.502	0.246	0.281	0.284	0.242	0.247	0.166	0.177	0.239	0.241
MDD	-0.359	-0.319	-0.354	-0.328	-0.319	-0.319	-0.322	-0.356	-0.319	-0.319
Ω	1.089	1.078	1.067	1.100	1.078	1.078	1.050	1.059	1.078	1.067
SoR	0.580	0.574	0.498	0.739	0.573	0.575	0.369	0.442	0.571	0.491
Skew	0.607		-0.025	1.017	0.429	0.433	-0.058	0.170	0.437	0.436
Kurt.	10.040		5.479	12.974	8.702	8.692	5.805	5.903	8.742	8.636
TR	1.040	0.979	1.125	0.961	0.979	0.979	0.995	1.046	0.980	0.979
VaR	-0.054	-0.061	-0.062	-0.064	-0.061	-0.061	-0.060	-0.064	-0.061	-0.062
α	0.000	0.037	0.037	0.119	0.061	0.037	-0.004	0.020	0.061	0.032
β	1.000	0.782	0.800	0.799	0.777	0.782	0.751	0.801	0.778	0.783

Nota: R_p = Annual return, R_{acum} = Cumulative returns, Vol. = Annual volatility, S = Sharpe Ratio, CaR = Calmar Ratio, MDD = Max drawdown, Ω = Omega Ratio, SoR = Sortino Ratio, TR = Tail ratio, VaR = Daily value at risk, α = Alpha, β = Beta.

Tabela 22 – Pesos dos portfólios contendo as criptomoedas da amostra (grupo MC-large.)

TC	Strategy	Weights			Rebalances		
		min	mean	max	min	mean	max
não	DDPG	0.049	0.100	0.134	1	1.0	1
	PPO	0.100	0.100	0.101	1	1.4	3
	SAC	0.059	0.100	0.179	14	14.0	14
	MV	0.100	0.100	0.100	0	0.0	0
sim	DDPG	0.074	0.100	0.202	1	1.0	1
	PPO	0.100	0.100	0.101	2	29.5	78
	SAC	0.059	0.100	0.161	1	1.0	1
	MV	0.100	0.100	0.100	0	0.0	0

B&H, bem como o modelo de Mínima Variância, que em portfólios com poucos ativos demonstrou uma abordagem estável, com pesos médios constantes e nenhum rebalanceamento, refletindo estratégias passivas de investimento.

5.4.3 MC-small

A Figura 9 e Tabela 23 apresentam a performance de portfólios compostos por criptomoedas com capitalização de mercado abaixo de 200 milhões de dólares (na data de início dos testes). Em geral, os retornos anuais R_p e acumulados R_{acum} são mais elevados neste grupo em comparação com os *benchmarks*.

Destaca-se o modelo SAC, que consistentemente se distingue dos demais tanto em retorno anual quanto acumulado, tanto na ausência dos custos de transação quanto ao considerá-los. Curi-




Figura 9 – Small MC and Small MC-tc

osamente, como pode ser visto a partir da Tabela 24, para apenas manter um desempenho similar considerando os custos de transação, o modelo optou por realizar 21 rebalanceamentos a mais. Este resultado pode sugerir que a estratégia SAC seja particularmente eficaz em portfólios de criptomoedas de menor capitalização, potencialmente devido à sua capacidade de capturar ganhos significativos em ativos mais voláteis e de alto risco. Por outro lado, o DDPG apresenta um desempenho mais modesto em termos de retorno, enquanto o PPO, assim como nos demais grupos de ativos, acompanhou a performance da carteira B&H, com variações milésimas em seus pesos.

Do ponto de vista do risco, apesar de uma maior volatilidade anual (Vol.), o modelo SAC apresenta um Sharpe Ratio (S) e um Sortino Ratio (SoR) altos, indicando uma eficiente compensação de risco-retorno. Além disso, o Calmar Ratio (CaR) para o SAC é notavelmente superior ao dos

Tabela 23 – Performance dos portfólios contendo as criptomoedas abaixo da média de Market Cap da amostra (Grupo MC-small)

Metric	Benchmarks		No transaction cost				With transaction cost			
	CRIX	B & H	SAC	DDPG	PPO	MV	SAC	DDPG	PPO	MV
R_p	0.079	0.186	0.286	0.058	0.185	0.186	0.287	0.024	0.187	0.160
R_{acum}	0.113	0.272	0.427	0.083	0.271	0.272	0.428	0.033	0.274	0.233
Vol.	0.432	0.526	0.574	0.520	0.525	0.526	0.581	0.502	0.526	0.526
S	0.389	0.590	0.724	0.370	0.588	0.590	0.722	0.300	0.591	0.548
CaR	0.219	0.492	0.707	0.152	0.490	0.494	0.697	0.062	0.495	0.424
Stab.	0.502	0.318	0.327	0.188	0.320	0.318	0.296	0.159	0.321	0.321
MDD	-0.359	-0.377	-0.404	-0.382	-0.377	-0.377	-0.412	-0.382	-0.377	-0.377
Ω	1.089	1.113	1.146	1.072	1.113	1.113	1.146	1.057	1.114	1.105
SoR	0.580	0.827	1.080	0.518	0.824	0.827	1.094	0.411	0.829	0.767
Skew	0.607		0.276	-0.199	-0.401	-0.398	0.503	-0.480	-0.394	-0.391
Kurt.	10.040		6.688	6.930	5.275	5.249	7.415	6.069	5.276	5.228
TR	1.040	0.898	1.050	0.900	0.896	0.898	0.974	0.823	0.897	0.896
VaR	-0.054	-0.065	-0.071	-0.065	-0.065	-0.065	-0.071	-0.063	-0.065	-0.065
α	0.000	0.173	0.331	0.063	0.198	0.173	0.339	0.024	0.200	0.172
β	1.000	0.746	0.748	0.761	0.741	0.746	0.734	0.736	0.741	0.746

Nota: R_p = Annual return, R_{acum} = Cumulative returns, Vol. = Annual volatility, S = Sharpe Ratio, CaR = Calmar Ratio, MDD = Max drawdown, Ω = Omega Ratio, SoR = Sortino Ratio, TR = Tail ratio, VaR = Daily value at risk, α = Alpha, β = Beta.

Tabela 24 – Pesos dos portfólios contendo as criptomoedas da amostra (grupo MC-small.)

TC	Strategy	Weights			Rebalances		
		min	mean	max	min	mean	max
não	DDPG	0.054	0.100	0.161	3	3.0	3
	SAC	0.054	0.100	0.146	1	1.0	1
	PPO	0.100	0.100	0.101	1	4.9	7
	MV	0.100	0.100	0.100	0	0.0	0
sim	DDPG	0.045	0.100	0.134	2	2.0	2
	SAC	0.049	0.100	0.161	22	22.0	22
	PPO	0.100	0.100	0.101	1	5.2	23
	MV	0.100	0.100	0.100	0	0.0	0

benchmarks, reforçando a ideia de que, embora investir em criptomoedas de menor capitalização possa ser mais arriscado, estratégias como a SAC podem oferecer retornos compensadores. Contudo, apesar de os resultados indicarem uma distinção entre os modelos, com destaque do modelo SAC para o grupo de criptomoedas de menor capitalização, o teste LW, que comparou as razões de Sharpe tanto entre as estratégias quanto entre os grupos, não confirmou diferença significativa entre deles.

5.4.4 Vol-low-liquid

Na Tabela 26 e Figuras 10a e 10b, observa-se a performance dos portfólios compostos por criptomoedas com volume abaixo de US\$5 milhões da amostra (na data de início dos testes), o que pode sugerir menor liquidez e, potencialmente, maior volatilidade.

Tabela 25 – Estatísticas Z-score do teste LW comparando os Índices Sharpe em carteiras com custos de transação (acima da diagonal) e carteiras sem custos (abaixo da diagonal) em portfólios separados por Market Cap.

(a) Portfólio large_MC.						(b) Portfólio small_MC.					
	DDPG	MinVar	PPO	PTF	SAC		DDPG	MinVar	PPO	PTF	SAC
DDPG	-	0.3384	0.3444	0.3391	0.3174	-	0.3223	0.0152	0.0154	-0.1880	
MinVar	0.1390	-	0.0062	0.0008	-0.0218	0.6486	-	-0.3182	-0.3179	-0.5289	
PPO	0.1383	-0.2058	-	-0.0055	-0.0280	0.3521	-0.2058	-	-0.0008	-0.2035	
PTF	0.1396	0.2221	0.0002	-	-0.0226	0.3524	0.2221	0.0002	-	-0.2038	
SAC	0.4537	0.4405	0.2229	0.2237	-	0.0391	-0.3089	-0.3687	-0.3657	-	

Nota: Os níveis de significância de 1%, 5% e 10% são representados por ★, ◆ e ●, respectivamente.

Tabela 26 – Performance dos portfólios contendo as criptomoedas abaixo da média de Volume da amostra (Grupo VOL_low_liquidCC)

Metric	Benchmarks		No transaction cost				With transaction cost			
	CRIX	B & H	SAC	DDPG	PPO	MV	SAC	DDPG	PPO	MV
R_p	0.079	0.097	0.085	-0.028	0.097	0.097	0.143	0.177	0.097	0.070
R_{acum}	0.113	0.140	0.122	-0.039	0.140	0.140	0.208	0.258	0.140	0.100
Vol.	0.432	0.534	0.529	0.510	0.533	0.534	0.546	0.580	0.533	0.534
S	0.389	0.444	0.422	0.204	0.444	0.444	0.519	0.569	0.444	0.396
CaR	0.219	0.250	0.225	-0.072	0.251	0.251	0.368	0.421	0.251	0.180
Stab.	0.502	0.145	0.166	0.023	0.148	0.145	0.201	0.136	0.148	0.147
MDD	-0.359	-0.388	-0.379	-0.388	-0.388	-0.388	-0.389	-0.419	-0.388	-0.388
Ω	1.089	1.085	1.080	1.038	1.085	1.085	1.100	1.114	1.085	1.076
SoR	0.580	0.619	0.581	0.272	0.619	0.619	0.742	0.837	0.619	0.552
Skew	0.607		-0.518	-0.809	-0.417	-0.417	-0.120	0.310	-0.416	-0.410
Kurt.	10.040		5.756	5.869	5.750	5.728	5.676	8.233	5.754	5.696
TR	1.040	0.983	0.933	0.994	0.982	0.983	1.029	0.967	0.980	0.981
VaR	-0.054	-0.066	-0.066	-0.064	-0.066	-0.066	-0.068	-0.072	-0.066	-0.066
α	0.000	0.081	0.089	-0.033	0.107	0.081	0.161	0.221	0.107	0.284
β	1.000	0.785	0.797	0.793	0.780	0.785	0.772	0.754	0.781	0.410

Nota: R_p = Annual return, R_{acum} = Cumulative returns, Vol. = Annual volatility, S = Sharpe Ratio, CaR = Calmar Ratio, MDD = Max drawdown, Ω = Omega Ratio, SoR = Sortino Ratio, TR = Tail ratio, VaR = Daily value at risk, α = Alpha, β = Beta.

A Tabela 26 mostra que, sob condições sem custos de transação, o SAC e o PPO alinham-se de perto com os *benchmarks* CRIX e B&H em termos de retorno anual R_p e acumulado R_{acum} , enquanto o DDPG apresentou um desempenho inferior e negativo. Interessantemente, ao se introduzirem os custos de transação, o modelo SAC superou tanto os *benchmarks* quanto o modelo de Mínima Variância, enquanto o DDPG reverteu o sinal e passou a apresentar a melhor performance dentre todas as estratégias. Entretanto, pelo teste Ledoit-Wolf (Tabela 28), não se pôde confirmar diferença entre as razões Sharpe desses portfólios.

A Tabela 27 revela as estratégias de alocação de ativos e rebalanceamentos dos modelos. O MV manteve pesos iguais e sem rebalanceamento, tanto em cenários com quanto sem custos de transação. Por outro lado, o PPO teve uma maior frequência de rebalanceamentos, mas com mínima




Figura 10 – Low-liquid and Low-liquid-tc

variação. Já os modelos DDPG e SAC tiveram apenas uma alteração em suas posições, mas com pesos bem variados, embora nunca menores que 5%.

5.5 Discussão e Conclusões

Em todos os subgrupos de ativos testados, notou-se que o modelo PPO fez uma gestão aproximadamente igual dos pesos, obtendo a mesma performance da carteira B&H. Isso pode ser justificado pela natureza do algoritmo PPO, que utiliza uma restrição de região de confiança no espaço de política, desencorajando os agentes de RL a tomar ações agressivas e tendendo a ser mais conservadoras e focadas na diversificação (Aboussalah et al., 2022).

Tabela 27 – Pesos dos portfólios contendo as criptomoedas da amostra (grupo low_liquidCC.)

TC	Strategy	Weights			Rebalances		
		min	mean	max	min	mean	max
não	DDPG	0.054	0.100	0.146	1	1.0	1
	PPO	0.099	0.100	0.101	1	7.6	14
	SAC	0.074	0.100	0.202	1	1.0	1
	MV	0.100	0.100	0.100	0	0.0	0
sim	DDPG	0.059	0.100	0.161	1	1.0	1
	PPO	0.099	0.100	0.101	0	6.9	11
	SAC	0.045	0.100	0.123	1	1.0	1
	MV	0.100	0.100	0.100	0	0.0	0

Tabela 28 – Estatísticas Z-score do teste LW comparando os Índices Sharpe em carteiras com custos de transação (acima da diagonal) e carteiras sem custos (abaixo da diagonal) para o portfólio low_liquidCC.

	DDPG	MinVar	PPO	PTF	SAC
DDPG	-	0.0031	0.0606	0.0577	-0.3057
MV	-0.2704	-	0.0575	0.0546	-0.3089
PPO	-0.2141	-0.0469	-	-0.0029	-0.1489
PTF	-0.2141	-0.0495	0.0026	-	-0.1486
SAC	0.0205	0.2642	0.0744	0.0750	-

Nota: Os níveis de significância de 1%, 5% e 10% são representados por ★, ◆ e ●, respectivamente.

Identificou-se que os modelos DRL não entregaram resultados consistentes em carteiras com muitos ativos (Figura 7) nem nas carteiras compostas apenas pelas *blue ships* do mercado cripto (Figura 8), situações em que a estratégia B&H atendeu suficientemente bem sem necessitar de esforço computacional. Já para carteiras com ativos menores e/ou menos líquidos, os modelos SAC e DDPG se destacaram com resultados amplamente superiores aos *benchmarks*.

Ao aplicar o teste Ledoit-Wolf (LW), que compara as razões de Sharpe inter portfólios, entre as estratégias e entre os subgrupos de ativos que compuseram as carteiras, não foi comprovada, entretanto, diferença significativa entre elas. Essa ausência de significância talvez possa ser atribuída à especificidade dos portfólios compostos por criptomoedas, conhecidas por sua natureza excepcionalmente volátil e com períodos de assimetria positiva. Assim, métricas que consideram apenas a volatilidade total, como a razão de Sharpe, podem não ser tão adequada quanto medidas de risco que se concentram especificamente na volatilidade negativa, como a razão de Sortino, ou medidas de risco condicional (CVaR), as quais poderiam fornecer uma avaliação mais precisa do desempenho do portfólio ao considerar a tolerância ao risco na parte inferior da distribuição de retornos.

Para as carteiras compostas pelo conjunto completo de ativos da amostra, a estratégia de Mínima Variância ofereceu retornos superiores em comparação com a abordagem passiva de comprar e manter, durante o período analisado, e com as estratégias DRL. Entretanto, ao ser ponderada

a eficácia do MV considerando os custos associados ao rebalanceamento de ativos, verificou-se que essa vantagem deixou de existir. Assim mesmo, ainda mostrou desempenho superior às estratégias DRL (exceto PPO) nesse caso, o que pode ser explicado pela liberdade que o modelo de Mínima Variância possui de zerar os pesos dos ativos que não atendem suas restrições, o que parece ser vetado aos modelos DRL em suas configurações padrão. Além disso, é importante considerar que o desempenho dos modelos DRL é afetado pelo número de ativos, dado que a complexidade do espaço de ação aumenta, tornando o treinamento mais desafiador (X.-Y. Liu et al., 2020)

Os achados indicam que a sensibilidade das carteiras de criptomoedas às variações nos custos de transação é um fator que afeta a performance das estratégias de seleção e otimização de portfólios. Em cenários sem custos de transação, a estratégia MinVar e o modelo DDPG apresentaram desempenho superior no conjunto completo de ativos, enquanto em cenários com custos de transação, a ordem de desempenho das estratégias mudou. Na categoria de criptomoedas com maior capitalização de mercado, o DDPG destacou-se em cenários sem custos de transação mas, a partir de sua inclusão, perdeu sua posição de protagonismo. Isso sugere que, embora o DDPG seja eficaz em maximizar retornos em um ambiente sem custos, seu desempenho é sensivelmente impactado pela inclusão de custos de transação. Para as criptomoedas de menor capitalização, o modelo SAC demonstrou ser o mais resiliente, mantendo o topo do desempenho tanto em cenários incluindo ou desconsiderando os custos de transação.

Por fim, nos portfólios compostos por ativos com menores volumes de negociação, os modelos DDPG e o SAC tiveram um desempenho superior em um ambiente com custos de transação, mostrando que podem efetivamente lidar com a volatilidade e as particularidades de portfólios compostos por ativos menores e menos líquidos. Esses resultados indicam que a inclusão de custos de transação é um fator crítico na avaliação da eficácia das estratégias de investimento em criptomoedas. Estratégias que podem parecer promissoras em um cenário sem custos podem não manter sua vantagem quando os custos são considerados. Isso ressalta a importância de avaliar estratégias de investimento em condições que se assemelhem o mais próximo possível do ambiente real de negociação, onde os custos de transação costumam desempenhar um papel significativo.

Em portfólios "vencedores" (compostos por ativos com bom desempenho no período), os modelos de *machine learning* sempre superaram o MV, mas percebe-se que esses modelos precisam ser configurados para serem capazes de rejeitar ativos com indicadores ruins, pois na configuração original não zeram pesos para ativo algum.

Outro ponto a ser aprimorado nos modelos para aplicação prática no mundo real é a possibilidade de uma parte do montante das carteiras ser alocada em caixa de oportunidade, o que é muito relevante em ambientes altamente voláteis como o das criptomoedas. Foram realizados testes adicionais com a inclusão de uma moeda estável (USDT) na expectativa de que os modelos tivessem um refúgio em condições de aumento de volatilidade, mas não houve melhora nos modelos com sua inclusão, pelo contrário.

Os modelos de DRL, em particular o DDPG e SAC, mostraram potencial para melhorar os retornos em relação às estratégias clássicas. No entanto, a incorporação de custos de transação pode em alguns casos reduzir a vantagem desses modelos, sublinhando a necessidade de otimizações adicionais e considerações cuidadosas sobre as frequências de negociação. Concluiu-se que os modelos de aprendizado por reforço profundo mostram potencial para superar estratégias clássicas em determinadas condições, como também identificado por Aboussalah et al. (2022), mas percebe-se a necessidade de mais pesquisas para que se tornem efetivos para aplicação ao mercado de criptomoedas.

Percebe-se a necessidade de calibrar o ajuste dos modelos DRL para que tenham maior consistência, considerando diferentes configurações como: as proporções entre os períodos de treinamento e teste (Santos et al., 2023), filtragem de recursos descartando um dentre os que apresentarem correlação acima de 60% (Gort et al., 2022); a combinação de modelos DRL usando uma estrutura de aprendizagem por reforço aninhada, como proposto no estudo de Yu et al. (2023).

Para pesquisas futuras, sugere-se a inclusão de informações adicionais, como sentimento de mercado e atenção da mídia (Souza, Barboza, & Garruti, 2023); inclusão de controle de risco de quebra do mercado (X.-Y. Liu et al., 2020); inclusão de estimadores de volatilidade futura (Fiorucci et al., 2022a), que se mostraram bastante promissores no estudo 2. Além disso, os modelos de *Machine Learning* precisam ser adequados para permitir uma maior flexibilidade em termos de rebalanceamentos, incluindo pesos nulos e a opção de manter posições em caixa, o que é particularmente relevante em mercados voláteis.

Conclusões Gerais

6 Conclusões Gerais

Diferentes aspectos financeiros das criptomoedas têm sido cada vez mais estudados por pesquisadores e profissionais de mercado desde 2012. O interesse no assunto é claramente justificado, pois as moedas virtuais conquistaram um espaço significativo como ativo de investimento em todo o mundo.

Assim, a partir do objetivo geral de investigar o potencial e a efetividade de estratégias avançadas de gestão de portfólios compostos por criptomoedas e suas implicações esta tese foi desenvolvida em três estudos, sendo o primeiro para embasar e verificar lacunas de pesquisa e os demais abarcaram duas dessas oportunidades.

Mais especificamente, o primeiro estudo envolveu uma análise sistemática da literatura acadêmica sobre criptomoedas com foco em gestão de risco, utilização em portfólios e eficiência de mercado segundo a Hipótese do Mercado Eficiente (HME). Além disso, a regionalidade foi um tema examinado, a fim de verificar como essa questão tem sido aplicada nesse contexto. O protocolo *Methodi Ordinatio* auxiliou na etapa de seleção e ranqueamento dos 108 estudos considerados na base final, que foram classificados e codificados em sete categorias de análise.

No segundo estudo, investigou-se o desempenho de uma estratégia de investimento em criptomoedas usando um estimador autorregressivo de volatilidade. Os resultados da otimização do MT5 indicaram a sensibilidade da estratégia RTS Garch às diferentes configurações. A ampla variação nos lucros e perdas sugere que pequenas mudanças nas configurações podem ter um impacto significativo no desempenho, o que é esperado em mercados voláteis como o de criptomoedas. Destacou-se a importância da personalização, pois não existe uma configuração única que seja a melhor para todas as situações. É essencial personalizar a estratégia com base na natureza do ativo e nas condições do mercado. Enquanto algumas configurações maximizam os lucros, elas também podem aumentar o risco.

O consenso sobre a movimentação dos *stops*, seja no modo de reação ou na direção oposta, sugeriu a tendência das criptomoedas por movimentos fortes, durante os quais ajustar *stops* pode ser crucial para proteger ganhos e limitar perdas. Por fim, a decisão sobre se o *take profit* deve ser ajustado no modo de reação mostrou variações, indicando que, enquanto o BTC pode se beneficiar de um alvo de lucro ajustável, outras moedas podem preferir um alvo fixo. Portanto, ao se aplicar estratégias de negociação, é essencial considerar a singularidade de cada ativo, garantindo uma abordagem adaptada e informada.

A variação nos resultados sugere que a estratégia é altamente sensível às configurações escolhidas. O fato de que algumas configurações resultam em prejuízos significativos enquanto outras geram lucros substanciais indica que a estratégia automatizada RTS Garch não é à prova de falhas e precisa ser calibrada cuidadosamente para cada ativo.

Por último, o terceiro estudo avaliou o desempenho e a eficácia do uso de *Deep Reinforcement Learning* na seleção e otimização de carteiras de investimento em criptomoedas, considerando diferentes características de tamanho, liquidez e os custos de transação associados às negociações.

A análise revelou que os custos de transação têm um impacto considerável sobre a eficácia das estratégias de seleção e otimização de portfólios. Em portfólios com um grande número de ativos ou com ativos de alta capitalização, estratégias como a Mínima Variância e B&H mostraram-se eficientes. Por outro lado, em portfólios compostos por ativos menores ou menos líquidos, os modelos DRL, especialmente SAC e DDPG, se destacaram.

O teste Ledoit-Wolf, ao comparar as razões de Sharpe, não mostrou diferença significativa entre as estratégias em portfólios de criptomoedas. Isso traz um alerta de que métricas focadas na volatilidade total podem não ser adequadas para testar a efetividade de portfólios compostos apenas por criptomoedas. Por conseguinte, testes derivados de métricas que considerassem especificamente a volatilidade negativa, como a razão de Sortino ou o CVaR, poderiam fornecer uma avaliação mais precisa do desempenho do portfólio.

Os modelos de DRL, especialmente SAC e DDPG, demonstraram bom potencial para melhorar os retornos em comparação com estratégias clássicas. No entanto, foi identificada a necessidade de otimizações adicionais para garantir uma maior acurácia dos modelos em portfólios de criptomoedas. Os modelos DRL precisam de ajustes para aumentar sua eficácia, incluindo a possibilidade de rebalanceamentos com pesos nulos e a inclusão de posições em caixa. Além disso, futuras pesquisas podem beneficiar-se da inclusão de dados de sentimento de mercado e controle de risco de quebra do mercado.

(Fiorucci et al., 2022a)

Referências

- Ababio, K. A. (2020, April). Behavioural Portfolio Selection and Optimisation: Equities versus Cryptocurrencies. *Journal of African Business*, 21(2), 145–168. doi: 10.1080/15228916.2019.1625018 39
- Ababio, K. A., Mba, J. C., & Koumba, U. (2020, January). Optimisation of mixed assets portfolio using copula differential evolution: A behavioural approach. *Cogent Economics & Finance*, 8(1), 1780838. doi: 10.1080/23322039.2020.1780838 39, 62, 68, 146
- Abdul-Rahim, R., Khalid, A., Karim, Z. A., & Rashid, M. (2022, June). Exploring the Driving Forces of Stock-Cryptocurrency Comovements during COVID-19 Pandemic: An Analysis Using Wavelet Coherence and Seemingly Unrelated Regression. *Mathematics*, 10(12), 2116. doi: 10.3390/math10122116 40
- Aboussalah, A. M., Xu, Z., & Lee, C.-G. (2022, June). What is the value of the cross-sectional approach to deep reinforcement learning? *QUANTITATIVE FINANCE*, 22(6), 1091–1111. (Place: 2-4 PARK SQUARE, MILTON PARK, ABINGDON OX14 4RN, OXON, ENGLAND Publisher: ROUTLEDGE JOURNALS, TAYLOR & FRANCIS LTD Type: Article) doi: 10.1080/14697688.2021.2001032 99, 100, 103, 117, 120
- Aggarwal, V. (2022, September). Optimum investor portfolio allocation in new age digital assets. *International Journal of Innovation Science*, 14(3/4), 648–658. doi: 10.1108/IJIS-10-2020-0237 61, 63, 96, 97, 144
- Ahmed, W. (2020). Is there a risk-return trade-off in cryptocurrency markets? The case of Bitcoin. *Journal of Economics and Business*, 108. doi: 10.1016/j.jeconbus.2019.105886 41, 75
- Akhtaruzzaman, M., Sensoy, A., & Corbet, S. (2020, November). The influence of Bitcoin on portfolio diversification and design. *Finance Research Letters*, 37, 101344. doi: 10.1016/j.frl.2019.101344 27, 42, 62, 63, 66, 143
- Almeida, J., & Gonçalves, T. C. (2022, May). A Systematic Literature Review of Volatility and Risk Management on Cryptocurrency Investment: A Methodological Point of View. *Risks*, 10(5), 107. doi: 10.3390/risks10050107 49, 51, 96
- Al-Yahyaee, K. H., Mensi, W., Al-Jarrah, I. M. W., Hamdi, A., & Kang, S. H. (2019, July). Volatility forecasting, downside risk, and diversification benefits of Bitcoin and oil and international commodity markets: A comparative analysis with yellow metal. *North American Journal of Economics and Finance*, 49, 104–120. doi: 10.1016/j.najef.2019.04.001 27
- Anagnostopoulos, K., & Mamanis, G. (2010, July). A portfolio optimization model with three objectives and discrete variables. *Computers & Operations Research*, 37(7), 1285–1297. doi: 10.1016/j.cor.2009.09.009 46, 74
- Andriosopoulos, D., Doumpos, M., Pardalos, P. M., & Zopounidis, C. (2019, October). Computational approaches and data analytics in financial services: A literature review. *Journal of the*

- Operational Research Society*, 70(10), 1581–1599. doi: 10.1080/01605682.2019.1595193 33, 73
- Aras, S. (2021, October). On improving GARCH volatility forecasts for Bitcoin via a meta-learning approach. *Knowledge-Based Systems*, 230, 107393. doi: 10.1016/j.knosys.2021.107393 44, 76
- Aslan, A., & Sensoy, A. (2020, July). Intraday efficiency-frequency nexus in the cryptocurrency markets. *Finance Research Letters*, 35, 101298. doi: 10.1016/j.frl.2019.09.013 35, 59, 65, 143
- Aydoğan, B., Vardar, G., & Taçoğlu, C. (2022, January). Volatility spillovers among G7, E7 stock markets and cryptocurrencies. *Journal of Economic and Administrative Sciences*. doi: 10.1108/JEAS-09-2021-0190 96
- Aysan, A. F., Demir, E., Gozgor, G., & Lau, C. K. M. (2019, January). Effects of the geopolitical risks on Bitcoin returns and volatility. *Research in International Business and Finance*, 47, 511–518. doi: 10.1016/j.ribaf.2018.09.011 27
- Babaei, G., Giudici, P., & Raffinetti, E. (2022, June). Explainable artificial intelligence for crypto asset allocation. *Finance Research Letters*, 47, 102941. doi: 10.1016/j.frl.2022.102941 62, 67, 144
- Bae, G., & Kim, J. H. (2022, November). Observing Cryptocurrencies through Robust Anomaly Scores. *Entropy*, 24(11), 1643. doi: 10.3390/e24111643 44, 59, 60, 61, 66, 145
- Batista, D. T., & Alves, C. F. (2021, June). Analysis of Bitcoin's Impact on the Efficiency of a Diversified Portfolio for Brazilian Investors. *Review of Business Management*, 23(2), 353–369. doi: 10.7819/rbgn.v23i2.4098 62, 68, 146
- Bedi, P., & Nashier, T. (2020, January). On the investment credentials of Bitcoin: A cross-currency perspective. *Research in International Business and Finance*, 51, 101087. doi: 10.1016/j.ribaf.2019.101087 27, 35, 36, 41, 59, 61, 144
- Begušić, S., Kostanjčar, Z., Eugene Stanley, H., & Podobnik, B. (2018, November). Scaling properties of extreme price fluctuations in Bitcoin markets. *Physica A: Statistical Mechanics and its Applications*, 510, 400–406. doi: 10.1016/j.physa.2018.06.131 57, 59, 62, 143
- Bender, J., Briand, R., Nielsen, F., & Stefek, D. (2010, January). Portfolio of Risk Premia: A New Approach to Diversification. *The Journal of Portfolio Management*, 36(2), 17–25. doi: 10.3905/JPM.2010.36.2.017 43
- Beneki, C., Koulis, A., Kyriazis, N., & Papadamou, S. (2019). Investigating volatility transmission and hedging properties between Bitcoin and Ethereum. *Research in International Business and Finance*, 48, 219–227. doi: 10.1016/j.ribaf.2019.01.001 34, 75
- Białkowski, J. (2020, June). Cryptocurrencies in institutional investors' portfolios: Evidence from industry stop-loss rules. *Economics Letters*, 191, 108834. doi: 10.1016/j.econlet.2019.108834 41, 60, 75, 145

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 31(3), 307–327. 41, 79
- Bondar, M. I., Stovpova, A. S., Ostapiuk, N. A., Biriuk, O. H., & Tsiatkovska, O. V. (2020). Efficiency of Using Cryptocurrencies as an Investment Asset. *International Journal of Criminology and Sociology*, 61, 68, 147
- Bouri, E., Gupta, R., & Roubaud, D. (2019, June). Herding behaviour in cryptocurrencies. *Finance Research Letters*, 29, 216–221. doi: 10.1016/j.frl.2018.07.008 36, 57, 59, 143
- Bouri, E., Lucey, B., & Roubaud, D. (2019). Cryptocurrencies and the downside risk in equity investments. *Finance Research Letters*. doi: 10.1016/j.frl.2019.06.009 41, 75
- Bouri, E., Molnár, P., Azzi, G., Roubaud, D., & Hagfors, L. I. (2017). On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier? *Finance Research Letters*, 20, 192 – 198. doi: <https://doi.org/10.1016/j.frl.2016.09.025> 41, 75
- Branke, J., Scheckenbach, B., Stein, M., Deb, K., & Schmeck, H. (2009, December). Portfolio optimization with an envelope-based multi-objective evolutionary algorithm. *European Journal of Operational Research*, 199(3), 684–693. doi: 10.1016/j.ejor.2008.01.054 45, 74
- Brauneis, A., & Mestel, R. (2019, March). Cryptocurrency-portfolios in a mean-variance framework. *Finance Research Letters*, 28, 259–264. doi: 10.1016/j.frl.2018.05.008 45, 62, 63, 73, 74, 143
- Bruhn, P., & Ernst, D. (2022, August). Assessing the Risk Characteristics of the Cryptocurrency Market: A GARCH-EVT-Copula Approach. *Journal of Risk and Financial Management*, 15(8), 346. doi: 10.3390/jrfm15080346 38
- Burggraf, T. (2021, January). Beyond risk parity – A machine learning-based hierarchical risk parity approach on cryptocurrencies. *Finance Research Letters*, 38, 101523. doi: 10.1016/j.frl.2020.101523 29, 46, 59, 60, 66, 67, 73, 76, 146
- Börner, C. J., Hoffmann, I., Krettek, J., & Schmitz, T. (2022, July). Bitcoin: like a satellite or always hardcore? A core–satellite identification in the cryptocurrency market. *Journal of Asset Management*, 23(4), 310–321. doi: 10.1057/s41260-022-00267-z 58, 61, 67, 145
- Caiado, R. G. G., de Freitas Dias, R., Mattos, L. V., Quelhas, O. L. G., & Leal Filho, W. (2017, November). Towards sustainable development through the perspective of eco-efficiency - A systematic literature review. *Journal of Cleaner Production*, 165, 890–904. doi: 10.1016/j.jclepro.2017.07.166 53
- Campos, E. A. R., Pagani, R. N., Resende, L. M., & Pontes, J. (2018, August). Construction and qualitative assessment of a bibliographic portfolio using the methodology Methodi Ordinatio. *Scientometrics*, 116(2), 815–842. doi: 10.1007/s11192-018-2798-3 51
- Canh, N., Wongchoti, U., Thanh, S., & Thong, N. (2019). Systematic risk in cryptocurrency market: Evidence from DCC-MGARCH model. *Finance Research Letters*, 29, 90–100. doi: 10.1016/j.frl.2019.03.011 34, 75

- Cao, G., & Ling, M. (2022, February). Asymmetry and conduction direction of the interdependent structure between cryptocurrency and US dollar, renminbi, and gold markets. *CHAOS SOLITONS & FRACTALS*, 155. (Place: THE BOULEVARD, LANGFORD LANE, KIDLINGTON, OXFORD OX5 1GB, ENGLAND Publisher: PERGAMON-ELSEVIER SCIENCE LTD Type: Article) doi: 10.1016/j.chaos.2021.111671 36, 96
- Capes. (2017). *Relatório da Avaliação Quadrienal 2017: Administração, Ciências Contábeis e Turismo Quadriênio 2013-2016*. Retrieved 2020-04-27, from <http://www.capes.gov.br/avaliacao/sobre-as-areas-de-avaliacao/74-dav/caa2/4649-administracao-ciencias-contabeis-e-turismo> 54
- Capes. (2020). *Relatório do Qualis Periódicos Área 27: ADMINISTRAÇÃO PÚBLICA E DE EMPRESAS, CIÊNCIAS CONTÁBEIS E TURISMO*. 54
- Caporale, G., & Plastun, A. (2019). The day of the week effect in the cryptocurrency market. *Finance Research Letters*, 31, 258–269. doi: 10.1016/j.frl.2018.11.012 42
- Caporale, G. M., & Zekokh, T. (2019, April). Modelling volatility of cryptocurrencies using Markov-Switching GARCH models. *Research in International Business and Finance*, 48, 143–155. doi: 10.1016/j.ribaf.2018.12.009 33, 46, 57, 59, 60, 143
- Castro, J. G., Tito, E. A. H., Brandão, L. E. T., & Gomes, L. L. (2020, April). Crypto-assets portfolio optimization under the omega measure. *The Engineering Economist*, 65(2), 114–134. doi: 10.1080/0013791X.2019.1668098 62, 68, 146
- Cesarone, F., Moretti, J., & Tardella, F. (2016). Optimally chosen small portfolios are better than large ones. *Economics Bulletin*, 36(4), 1876–1891. (Publisher: AccessEcon) 46, 74
- Charfeddine, L., Benlagha, N., & Maouchi, Y. (2020). Investigating the dynamic relationship between cryptocurrencies and conventional assets: Implications for financial investors. *Economic Modelling*, 85, 198–217. doi: 10.1016/j.econmod.2019.05.016 27
- Chaudhari, H., & Crane, M. (2020, July). Cross-correlation dynamics and community structures of cryptocurrencies. *Journal of Computational Science*, 44, 101130. doi: 10.1016/j.jocs.2020.101130 35, 61, 146
- Chemkha, R., BenSaïda, A., & Ghorbel, A. (2021, March). Connectedness between cryptocurrencies and foreign exchange markets: Implication for risk management. *Journal of International Financial Management*, 59, 100666. doi: 10.1016/j.mulfin.2020.100666 60, 65, 144
- Chen, R., Lepori, G. M., Tai, C. C., & Sung, M. C. (2022, November). Can salience theory explain investor behaviour? Real-world evidence from the cryptocurrency market. *International Review Of Financial Analysis*, 84. doi: 10.1016/j.irfa.2022.102419 37
- Chowdhury, R., Rahman, M. A., Rahman, M. S., & Mahdy, M. (2020, August). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine

- learning. *Physica A: Statistical Mechanics and its Applications*, 551, 124569. doi: 10.1016/j.physa.2020.124569 27, 28, 72, 77
- Chu, J., Chan, S., & Zhang, Y. (2020, April). High frequency momentum trading with cryptocurrencies. *Research in International Business and Finance*, 52, 101176. doi: 10.1016/j.ribaf.2019.101176 59, 71, 72, 145
- CoinMarketCap. (2023). Retrieved from <https://coinmarketcap.com/> 27
- Contreras-Valdez, M. I., Núñez, J. A., & Perales, G. B. (2022, April). Bitcoin in Portfolio Selection: A Multivariate Distribution Approach. *SAGE Open*, 12(2), 215824402210961. doi: 10.1177/21582440221096124 39, 61, 66, 145
- Corbet, S., Lucey, B., Urquhart, A., & Yarovaya, L. (2019). Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*, 62, 182 – 199. doi: <https://doi.org/10.1016/j.irfa.2018.09.003> 49, 50
- Cui, J., & Maghyereh, A. (2022, September). Time–frequency co-movement and risk connectedness among cryptocurrencies: new evidence from the higher-order moments before and during the COVID-19 pandemic. *Financial Innovation*, 8(1), 90. doi: 10.1186/s40854-022-00395-w 60, 61, 145
- Cui, T., Ding, S., Jin, H., & Zhang, Y. (2023, February). Portfolio constructions in cryptocurrency market: A CVaR-based deep reinforcement learning approach. *Economic Modelling*, 119, 106078. doi: 10.1016/j.econmod.2022.106078 40, 60, 66, 144
- DeMiguel, V., Garlappi, L., & Uppal, R. (2009, May). Optimal Versus Naive Diversification: How Inefficient is the $1/N$ Portfolio Strategy? *Review of Financial Studies*, 22(5), 1915–1953. doi: 10.1093/rfs/hhm075 45, 73, 74
- Demiralay, S., & Bayracı, S. (2021, October). Should stock investors include cryptocurrencies in their portfolios after all? Evidence from a conditional diversification benefits measure. *International Journal of Finance & Economics*, 26(4), 6188–6204. doi: 10.1002/ijfe.2116 61, 63, 66, 144
- Demo, G., Fogaça, N., Ponte, V., Fernandes, T., Cardoso, H., Demo, G., ... Cardoso, H. (2015, October). Marketing de relacionamento (CRM): estado da arte, revisão bibliométrica da produção nacional de primeira linha, institucionalização da pesquisa no Brasil e agenda de pesquisa. *RAM. Revista de Administração Mackenzie*, 16(5), 127–160. doi: 10.1590/1678-69712015/administracao.v16n5p127-160 55
- Dyhrberg, A. (2016). Bitcoin, gold and the dollar - A GARCH volatility analysis. *Finance Research Letters*, 16, 85–92. doi: 10.1016/j.frl.2015.10.008 27
- Engle, R. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica*, 50(4), 987–1007. Retrieved 2023-06-08, from <http://www.jstor.org/stable/1912773> 79
- Engle, R. (2002). Dynamic conditional correlation: A simple class of multivariate generalized auto-

- regressive conditional heteroskedasticity models. *Journal of Business & Economic Statistics*, 20(3), 339–350. 42, 78, 79
- Ensslin, L., Ensslin, S. R., Dutra, A., Nunes, N. A., & Reis, C. (2017, February). BPM governance: a literature analysis of performance evaluation. *Business Process Management Journal*, 23(1), 71–86. doi: 10.1108/BPMJ-11-2015-0159 51
- Ensslin, L., Ensslin, S. R., & Pinto, H. d. M. (2013, June). Processo de investigação e análise bibliométrica: avaliação da qualidade dos serviços bancários. *Revista de Administração Contemporânea*, 17(3), 325–349. doi: 10.1590/S1415-65552013000300005 51
- Fakhfekh, M., & Jeribi, A. (2020). Volatility dynamics of crypto-currencies' returns: Evidence from asymmetric and long memory GARCH models. *Research in International Business and Finance*, 51, 101075. doi: <https://doi.org/10.1016/j.ribaf.2019.101075> 38
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, 25(2), 383–417. 34, 95
- Fang, F., Ventre, C., Basios, M., Kanthan, L., Martinez-Rego, D., Wu, F., & Li, L. (2022, December). Cryptocurrency trading: a comprehensive survey. *Financial Innovation*, 8(1), 13. doi: 10.1186/s40854-021-00321-6 27, 35, 36, 49, 50
- Fantazzini, D., & Zimin, S. (2020, March). A multivariate approach for the simultaneous modeling of market risk and credit risk for cryptocurrencies. *Journal of Industrial and Business Economics*, 47(1), 19–69. doi: 10.1007/s40812-019-00136-8 40, 46, 59, 60, 146
- Felizardo, L. K., Lima Paiva, F. C., Graves, C. d. V., Matsumoto, E. Y., Reali Costa, A. H., Del-Moral-Hernandez, E., & Brandimarte, P. (2022, September). Outperforming algorithmic trading reinforcement learning systems: A supervised approach to the cryptocurrency market. *EXPERT SYSTEMS WITH APPLICATIONS*, 202. (Place: THE BOULEVARD, LANGFORD LANE, KIDLINGTON, OXFORD OX5 1GB, ENGLAND Publisher: PERGAMON-ELSEVIER SCIENCE LTD Type: Article) doi: 10.1016/j.eswa.2022.117259 99, 100
- Feng, W., Wang, Y., & Zhang, Z. (2018). Can cryptocurrencies be a safe haven: a tail risk perspective analysis. *Applied Economics*, 50(44), 4745–4762. doi: 10.1080/00036846.2018.1466993 42
- Fiorucci, J. A., Silva, G. N., & Barboza, F. (2022a, July). Reaction trend system with GARCH quantiles as action points. *Expert Systems with Applications*, 198, 116750. doi: 10.1016/j.eswa.2022.116750 11, 43, 76, 80, 82, 90, 120, 124
- Fiorucci, J. A., Silva, G. N., & Barboza, F. (2022b, August). RTS: Expert advisor for reaction trend system. *Software Impacts*, 13, 100331. doi: 10.1016/j.simpa.2022.100331 28, 71, 80, 82
- Flori, A. (2019). Cryptocurrencies in Finance: review and applications. *International Journal of Theoretical and Applied Finance*, 22(5). doi: 10.1142/S0219024919500201 50
- Gkillas, K., & Katsiampa, P. (2018). An application of extreme value theory to cryptocurrencies. *Economics Letters*, 164, 109–111. doi: 10.1016/j.econlet.2018.01.020 38

- Gort, B. J. D., Liu, X.-Y., Sun, X., Gao, J., Chen, S., & Wang, C. D. (2022). Deep reinforcement learning for cryptocurrency trading: Practical approach to address backtest overfitting. doi: 10.48550/ARXIV.2209.05559 120
- Ha, S., & Moon, B.-R. (2018, September). Finding attractive technical patterns in cryptocurrency markets. *Memetic Computing*, 10(3), 301–306. doi: 10.1007/s12293-018-0252-y 62, 67, 146
- Haq, I. U., Maneengam, A., Chupradit, S., Suksatan, W., & Huo, C. (2021, September). Economic Policy Uncertainty and Cryptocurrency Market as a Risk Management Avenue: A Systematic Review. *Risks*, 9(9), 163. doi: 10.3390/risks9090163 49, 51
- Haryanto, S., Subroto, A., & Ulpah, M. (2020, March). Disposition effect and herding behavior in the cryptocurrency market. *Journal of Industrial and Business Economics*, 47(1), 115–132. doi: 10.1007/s40812-019-00130-0 59, 144
- Hashemkhani Zolfani, S., Mehtari Taheri, H., Gharehgozlou, M., & Farahani, A. (2022, December). An asymmetric PROMETHEE II for cryptocurrency portfolio allocation based on return prediction. *Applied Soft Computing*, 131, 109829. doi: 10.1016/j.asoc.2022.109829 61, 62, 67, 146
- Hatemi-J, A., Hajji, M. A., Bouri, E., & Gupta, R. (2022, August). The Benefits of Diversification Between Bitcoin, Bonds, Equities and the US Dollar: A Matter of Portfolio Construction. *Asia-Pacific Journal of Operational Research*, 39(04), 2040024. doi: 10.1142/S0217595920400242 62, 68, 144
- Hordei, O., Patsai, B., Hurochkina, V., Ovdiienko, O., & Mishchenko, R. (2021, May). Optimization of the Investment Portfolio in the Environment of Table Processor MS Excel. *Studies of Applied Economics*, 39(5). doi: 10.25115/eea.v39i5.4983 60, 146
- Hsu, S.-H., Sheu, C., & Yoon, J. (2021, July). Risk spillovers between cryptocurrencies and traditional currencies and gold under different global economic conditions. *The North American Journal of Economics and Finance*, 57, 101443. doi: 10.1016/j.najef.2021.101443 60, 143
- Huang, X., Han, W., Newton, D., Platanakis, E., Stafylas, D., & Sutcliffe, C. (2022, March). The diversification benefits of cryptocurrency asset categories and estimation risk: pre and post Covid-19. *The European Journal of Finance*, 1–26. doi: 10.1080/1351847X.2022.2033806 27, 39, 61, 63, 67, 77, 145
- Huang, Z., & Tanaka, F. (2022, February). MSPM: A modularized and scalable multi-agent reinforcement learning-based system for financial portfolio management. *PLOS ONE*, 17(2). (Place: 1160 BATTERY STREET, STE 100, SAN FRANCISCO, CA 94111 USA Publisher: PUBLIC LIBRARY SCIENCE Type: Article) doi: 10.1371/journal.pone.0263689 99, 100
- James, N. (2022, June). Evolutionary correlation, regime switching, spectral dynamics and optimal trading strategies for cryptocurrencies and equities. *Physica D: Nonlinear Phenomena*, 434, 133262. doi: 10.1016/j.physd.2022.133262 44, 61, 62, 71, 144

- Jiang, C., & Wang, J. (2023, January). A Portfolio Model with Risk Control Policy Based on Deep Reinforcement Learning. *MATHEMATICS*, 11(1). (Place: ST ALBAN-ANLAGE 66, CH-4052 BASEL, SWITZERLAND Publisher: MDPI Type: Article) doi: 10.3390/math11010019 99, 100
- Jorion, P. (2011). *Value at risk* (Third edition ed.). McGraw-Hill Professional Publishing. 33, 40, 73, 75
- Joshi, P., Wang, J., & Busler, M. (2022, March). A Study of the Machine Learning Approach and the MGARCH-BEKK Model in Volatility Transmission. *Journal of Risk and Financial Management*, 15(3), 116. doi: 10.3390/jrfm15030116 76
- Kabbani, T., & Duman, E. (2022). Deep Reinforcement Learning Approach for Trading Automation in the Stock Market. *IEEE ACCESS*, 10, 93564–93574. (Place: 445 HOES LANE, PISCATAWAY, NJ 08855-4141 USA Publisher: IEEE-INST ELECTRICAL ELECTRONICS ENGINEERS INC Type: Article) doi: 10.1109/ACCESS.2022.3203697 99, 100
- Katsiampa, P. (2019). An empirical investigation of volatility dynamics in the cryptocurrency market. *Research in International Business and Finance*, 50, 322 – 335. doi: <https://doi.org/10.1016/j.ribaf.2019.06.004> 41, 75
- Kaya, O., & Mostowfi, M. (2022, May). Low-volatility strategies for highly liquid cryptocurrencies. *Finance Research Letters*, 46, 102422. doi: 10.1016/j.frl.2021.102422 60, 71, 72, 144
- Khadjeh Nassirtoussi, A., Aghabozorgi, S., Ying Wah, T., & Ngo, D. C. L. (2014, November). Text mining for market prediction: A systematic review. *Expert Systems with Applications*, 41(16), 7653–7670. Retrieved 2023-04-20, from <https://linkinghub.elsevier.com/retrieve/pii/S0957417414003455> doi: 10.1016/j.eswa.2014.06.009 34, 35
- Khaki, A., Prasad, M., Al-Mohamad, S., Bakry, W., & Vo, X. V. (2023, January). Re-evaluating portfolio diversification and design using cryptocurrencies: Are decentralized cryptocurrencies enough? *Research in International Business and Finance*, 64, 101823. doi: 10.1016/j.ribaf.2022.101823 61, 144
- Khan, A., & Augustine, P. (2019). Predictive analytics in cryptocurrency using neural networks: A comparative study. *International Journal of Recent Technology and Engineering*, 7(6), 425–429. 27
- Klarin, A. (2020). The decade-long cryptocurrencies and the blockchain rollercoaster: Mapping the intellectual structure and charting future directions. *Research in International Business and Finance*, 51, 101067. doi: <https://doi.org/10.1016/j.ribaf.2019.101067> 49
- Kochliaridis, V., Kouloumpris, E., & Vlahavas, I. (2023, April). Combining deep reinforcement learning with technical analysis and trend monitoring on cryptocurrency markets. *NEURAL COMPUTING & APPLICATIONS*. (Place: 236 GRAYS INN RD, 6TH FLOOR, LONDON

- WC1X 8HL, ENGLAND Publisher: SPRINGER LONDON LTD Type: Article; Early Access) doi: 10.1007/s00521-023-08516-x 99, 100
- Koker, T. E., & Koutmos, D. (2020, August). Cryptocurrency Trading Using Machine Learning. *Journal of Risk and Financial Management*, 13(8), 178. doi: 10.3390/jrfm13080178 76
- Kosc, K., Sakowski, P., & Ślepaczuk, R. (2019, June). Momentum and contrarian effects on the cryptocurrency market. *Physica A: Statistical Mechanics and its Applications*, 523, 691–701. doi: 10.1016/j.physa.2019.02.057 61, 72, 73, 144
- Kristjanpoller, W., Fernandes, L. H. S., & Tabak, B. M. (2022, May). Examining the fractal market hypothesis considering daily and high frequency for cryptocurrency assets. *Fractals-Complex Geometry Patterns And Scaling In Nature And Society*, 30(03). doi: 10.1142/S0218348X22500700 36, 96
- Kristoufek, L., & Vosvrda, M. (2019, October). Cryptocurrencies market efficiency ranking: Not so straightforward. *PHYSICA A- Statistical Mechanics And Its Applications*, 531. doi: 10.1016/j.physa.2019.04.089 36, 96
- Kumah, S. P., & Mensah, J. O. (2022, July). Are cryptocurrencies connected to gold? A wavelet-based quantile-in-quantile approach. *International Journal of Finance & Economics*, 27(3), 3640–3659. doi: 10.1002/ijfe.2342 62, 63, 144
- Kurosaki, T., & Kim, Y. S. (2022, March). Cryptocurrency portfolio optimization with multivariate normal tempered stable processes and Foster-Hart risk. *Finance Research Letters*, 45, 102143. doi: 10.1016/j.frl.2021.102143 62, 144
- Kyriazis, N. A. (2021a, June). A Survey on Volatility Fluctuations in the Decentralized Cryptocurrency Financial Assets. *Journal of Risk and Financial Management*, 14(7), 293. doi: 10.3390/jrfm14070293 41, 75
- Kyriazis, N. A. (2021b, January). Trade Policy Uncertainty Effects on Macro Economy and Financial Markets: An Integrated Survey and Empirical Investigation. *Journal of Risk and Financial Management*, 14(1), 41. doi: 10.3390/jrfm14010041 29
- Li, F., Wang, Z., & Zhou, P. (2022, September). Ensemble Investment Strategies Based on Reinforcement Learning. *SCIENTIFIC PROGRAMMING*, 2022. (Place: ADAM HOUSE, 3RD FLR, 1 FITZROY SQ, LONDON, W1T 5HF, ENGLAND Publisher: HINDAWI LTD Type: Article) doi: 10.1155/2022/7648810 99, 100
- Li, J., Zhang, Y., Yang, X., & Chen, L. (2023, May). Online portfolio management via deep reinforcement learning with high-frequency data. *INFORMATION PROCESSING & MANAGEMENT*, 60(3). doi: 10.1016/j.ipm.2022.103247 95
- Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., ... Wierstra, D. (2015). Continuous control with deep reinforcement learning. *arXiv preprint arXiv:1509.02971*. 99, 103
- Liu, F., Li, Y., Li, B., Li, J., & Xie, H. (2021, December). Bitcoin transaction strategy construction

- based on deep reinforcement learning. *APPLIED SOFT COMPUTING*, 113(B). (Place: RADARWEG 29, 1043 NX AMSTERDAM, NETHERLANDS Publisher: ELSEVIER Type: Article) doi: 10.1016/j.asoc.2021.107952 99, 100
- Liu, W. (2019). Portfolio diversification across cryptocurrencies. *Finance Research Letters*, 29, 200–205. doi: 10.1016/j.frl.2018.07.010 33, 45, 73, 75
- Liu, W., Liang, X., & Cui, G. (2020). Common risk factors in the returns on cryptocurrencies. *Economic Modelling*, 86, 299–305. doi: 10.1016/j.econmod.2019.09.035 27
- Liu, X.-Y., Yang, H., Chen, Q., Zhang, R., Yang, L., Xiao, B., & Wang, C. D. (2020). Finrl: A deep reinforcement learning library for automated stock trading in quantitative finance. *arXiv preprint arXiv:2011.09607*. 104, 119, 120
- Liu, Y., Li, Z., Nekhili, R., & Sultan, J. (2023, January). Forecasting cryptocurrency returns with machine learning. *Research In International Business And Finance*, 64. doi: 10.1016/j.ribaf.2023.101905 35, 65
- Lorenzo, L., & Arroyo, J. (2022, December). Analysis of the cryptocurrency market using different prototype-based clustering techniques. *Financial Innovation*, 8(1), 7. doi: 10.1186/s40854-021-00310-9 27
- Lorenzo, L., & Arroyo, J. (2023, January). Online risk-based portfolio allocation on subsets of crypto assets applying a prototype-based clustering algorithm. *FINANCIAL INNOVATION*, 9(1). (Place: ONE NEW YORK PLAZA, SUITE 4600, NEW YORK, NY, UNITED STATES Publisher: SPRINGER Type: Article) doi: 10.1186/s40854-022-00438-2 35
- Lucarelli, G., & Borrotti, M. (2020, December). A deep Q-learning portfolio management framework for the cryptocurrency market. *Neural Computing and Applications*, 32(23), 17229–17244. doi: 10.1007/s00521-020-05359-8 62, 63, 67, 95, 96, 145
- Ma, Y., Ahmad, F., Liu, M., & Wang, Z. (2020, December). Portfolio optimization in the era of digital financialization using cryptocurrencies. *Technological Forecasting and Social Change*, 161, 120265. doi: 10.1016/j.techfore.2020.120265 61, 63, 144
- Madhavan, S., & Sreejith, S. (2022, August). A Comparative Analysis on the Role and Market Linkages of Gold Backed Assets During COVID-19 Pandemic. *Scientific Annals of Economics and Business*, 69(3), 417–433. doi: 10.47743/saeb-2022-0019 42
- Maghsoodi, A. I. (2023, February). Cryptocurrency portfolio allocation using a novel hybrid and predictive big data decision support system. *Omega*, 115, 102787. doi: 10.1016/j.omega.2022.102787 27, 61, 62, 67, 144
- Mamanis, G. (2021). A Comparative Study on Multi-objective Evolutionary Algorithms for Tri-objective Mean-Risk-Cardinality Portfolio Optimization Problems. In S. Patnaik, K. Tajeddini, & V. Jain (Eds.), *Computational Management* (Vol. 18, pp. 277–303). Cham: Springer International Publishing. (Series Title: Modeling and Optimization in Science and Technologies) doi: 10.1007/978-3-030-72929-5_13 46, 74

- Mansini, R., Ogryczak, W., & Speranza, M. G. (2015). *Linear and Mixed Integer Programming for Portfolio Optimization* (Vol. 21). Cham: Springer International Publishing. doi: 10.1007/978-3-319-18482-1 46, 74
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77–91. (Publisher: Wiley Online Library) 33, 36
- Martin, R. A. (2021). Pyportfoliopt: portfolio optimization in python. *Journal of Open Source Software*, 6(61), 3066. 82
- Mba, J. C., & Mwambetania Mwambi, S. (2022, April). Crypto-assets portfolio selection and optimization: a COGARCH-Rvine approach. *Studies in Nonlinear Dynamics & Econometrics*, 26(2), 173–190. doi: 10.1515/snde-2020-0072 61, 145
- Mba, J. C., & Mwambi, S. (2020, June). A Markov-switching COGARCH approach to cryptocurrency portfolio selection and optimization. *Financial Markets and Portfolio Management*, 34(2), 199–214. doi: 10.1007/s11408-020-00346-4 62, 63, 146
- Mba, J. C., Pindza, E., & Koumba, U. (2018, November). A differential evolution copula-based approach for a multi-period cryptocurrency portfolio optimization. *Financial Markets and Portfolio Management*, 32(4), 399–418. doi: 10.1007/s11408-018-0320-9 41, 62, 75, 147
- Medeiros, I. L. d., Vieira, A., Braviano, G., & Gonçalves, B. S. (2015, ago.). Revisão sistemática e bibliometria facilitadas por um canvas para visualização de informação. *InfoDesign - Revista Brasileira de Design da Informação*, 12(1), 93–110. doi: 10.51358/id.v12i1.341 50, 52
- Menger, K. (1892). On the origin of money. *The Economic Journal*, 2(6), 239–255. 27
- Mensi, W., Al-Yahyaee, K. H., Al-Jarrah, I. M. W., Vo, X. V., & Kang, S. H. (2020, November). Dynamic volatility transmission and portfolio management across major cryptocurrencies: Evidence from hourly data. *The North American Journal of Economics and Finance*, 54, 101285. doi: 10.1016/j.najef.2020.101285 60, 77, 146
- Mensi, W., Rehman, M. U., Al-Yahyaee, K. H., Al-Jarrah, I. M. W., & Kang, S. H. (2019, April). Time frequency analysis of the commonalities between Bitcoin and major Cryptocurrencies: Portfolio risk management implications. *The North American Journal of Economics and Finance*, 48, 283–294. doi: 10.1016/j.najef.2019.02.013 59, 60, 62, 143
- Merediz-Solà, I., & Bariviera, A. F. (2019). A bibliometric analysis of bitcoin scientific production. *Research in International Business and Finance*, 50, 294 – 305. doi: <https://doi.org/10.1016/j.ribaf.2019.06.008> 49
- Moreno, D., Antoli, M., & Quintana, D. (2022, December). Benefits of investing in cryptocurrencies when liquidity is a factor. *Research in International Business and Finance*, 63, 101751. doi: 10.1016/j.ribaf.2022.101751 60, 145
- Naeem, M., Farid, S., Balli, F., & Hussain Shahzad, S. (2020). Hedging the downside risk of commodities through cryptocurrencies. *Applied Economics Letters*. doi: 10.1080/13504851.2020.1739609 27

- Nakano, M., & Takahashi, A. (2020, December). A new investment method with AutoEncoder: Applications to crypto currencies. *Expert Systems with Applications*, 162, 113730. doi: 10.1016/j.eswa.2020.113730 41, 44, 62, 63, 67, 146
- Nguyen, L. H., Chevapatrakul, T., & Yao, K. (2020, September). Investigating tail-risk dependence in the cryptocurrency markets: A LASSO quantile regression approach. *Journal of Empirical Finance*, 58, 333–355. doi: 10.1016/j.jempfin.2020.06.006 60, 143
- Nkrumah-Boadu, B., Owusu Junior, P., Adam, A., & Asafo-Adjei, E. (2022, December). Safe haven, hedge and diversification for African stocks: cryptocurrencies versus gold in time-frequency perspective. *Cogent Economics & Finance*, 10(1), 2114171. doi: 10.1080/23322039.2022.2114171 35, 58, 59, 96, 145
- Okoli, C., Duarte, T. p. W. A., & Mattar, R. t. e. i. (2019, April). Guia Para Realizar uma Revisão Sistemática de Literatura. *EAD em Foco*, 9(1). doi: 10.18264/eadf.v9i1.748 50, 51, 53
- Omane-Adjepong, M., Ababio, K. A., & Alagidede, I. P. (2019, December). Time-frequency analysis of behaviourally classified financial asset markets. *Research in International Business and Finance*, 50, 54–69. doi: 10.1016/j.ribaf.2019.04.012 39, 59, 60, 146
- Omane-Adjepong, M., & Alagidede, I. P. (2020, December). Dynamic Linkages and Economic Role of Leading Cryptocurrencies in an Emerging Market. *Asia-Pacific Financial Markets*, 27(4), 537–585. doi: 10.1007/s10690-020-09306-4 27, 33
- Ozdurak, C., Umut, A., & Ozay, T. (2022, March). The Interaction of Major Crypto-assets, Clean Energy, and Technology Indices in Diversified Portfolios. *International Journal of Energy Economics and Policy*, 12(2), 480–490. doi: 10.32479/ijeeep.12888 60, 61, 65, 66, 145
- Pagani, R. N., João Luiz Kovaleski, & Luis Mauricio Martins de Resende. (2017, August). Avanços na composição da Methodi Ordinatio para revisão sistemática de literatura. *Ci.Inf.*, 46, 161–187. 51, 52
- Pagani, R. N., Kovaleski, J. L., & Resende, L. M. (2015, December). Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. *Scientometrics*, 105(3), 2109–2135. doi: 10.1007/s11192-015-1744-x 51, 52
- Panagiotis, A., Efthymios, K., Anastasios-Taxiarchis, K., & Athanasios, P. (2020, September). GARCH Modelling of High-Capitalization Cryptocurrencies' Impacts During Bearish Markets. *Journal of Central Banking Theory and Practice*, 9(3), 87–106. doi: 10.2478/jcbtp-2020-0038 42
- Peng, A., Ang, S. L., & Lim, C. Y. (2022, October). Automated Cryptocurrency Trading Bot Implementing DRL. *PERTANIKA JOURNAL OF SCIENCE AND TECHNOLOGY*, 30(4), 2683–2705. (Place: SERDANG, SELANGOR, 00000, MALAYSIA Publisher: UNIV PUTRA MALAYSIA PRESS Type: Article) doi: 10.47836/pjst.30.4.22 99, 100
- Petukhina, A., Trimborn, S., Härdle, W. K., & Elendner, H. (2021, November). Investing with

- cryptocurrencies – evaluating their potential for portfolio allocation strategies. *Quantitative Finance*, 21(11), 1825–1853. doi: 10.1080/14697688.2021.1880023 44, 46, 62, 71, 144
- Platanakis, E., Sutcliffe, C., & Urquhart, A. (2018, October). Optimal vs naïve diversification in cryptocurrencies. *Economics Letters*, 171, 93–96. doi: 10.1016/j.econlet.2018.07.020 62, 73, 143
- Platanakis, E., & Urquhart, A. (2019, April). Portfolio management with cryptocurrencies: The role of estimation risk. *Economics Letters*, 177, 76–80. doi: 10.1016/j.econlet.2019.01.019 59, 62, 63, 143
- Portelinha. (2021). *The impacts of cryptocurrencies in the performance of Brazilian stocks' portfolios*. 61, 68, 146
- Pradhan, A. K., Mittal, I., & Tiwari, A. K. (2021, September). Optimizing the market-risk of major cryptocurrencies using CVaR measure and copula simulation. *Macroeconomics and Finance in Emerging Market Economies*, 14(3), 291–307. doi: 10.1080/17520843.2021.1909828 38, 40, 62, 63, 146
- Raimundo Junior, G. D. S. (2022). *Essays On Herding* (Doutor em Administração de Empresas, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brazil). doi: 10.17771/PUCRio.acad.58789 27, 76
- Ren, R., Althof, M., & Härdle, W. K. (2022, September). Financial risk meter for cryptocurrencies and tail risk network-based portfolio construction. *The Singapore Economic Review*, 1–27. doi: 10.1142/S0217590822480010 61, 62, 145
- Ryan, J., Ulrich, J., Thielen, W., Teetor, P., & Bronder, S. (2013). *Quantitative financial modelling framework*. Aug. 82
- Saksonova, S., & Kuzmina-Merlino, I. (2019). Cryptocurrency as an Investment Instrument in a Modern Financial Market. *Vestnik Sankt-Peterburgskogo Universiteta-Ekonomika-St Petersburg University Journal Of Economic Studies*, 35(2), 269–282. doi: 10.21638/spbu05.2019.205 43, 44, 73, 76, 77
- Santos, G. C., Garruti, D. V. T., Barboza, F. L. d. M., Souza, K. G. d., Domingos, J. C., & Veiga, A. C. P. (2023). Management of investment portfolios employing reinforcement learning. *PeerJ Computer Science*. 120
- Schellinger, B. (2020, May). Optimization of special cryptocurrency portfolios. *The Journal of Risk Finance*, 21(2), 127–157. doi: 10.1108/JRF-11-2019-0221 62, 146
- Schnaubelt, M. (2022, February). Deep reinforcement learning for the optimal placement of cryptocurrency limit orders. *European Journal of Operational Research*, 296(3), 993–1006. doi: 10.1016/j.ejor.2021.04.050 76, 100
- Selmi, R., Mensi, W., Hammoudeh, S., & Bouoiyour, J. (2018). Is Bitcoin a hedge, a safe haven or a diversifier for oil price movements? A comparison with gold. *Energy Economics*, 74, 787–801. doi: 10.1016/j.eneco.2018.07.007 27

- Sharpe, W. F. (1966). Mutual Fund Performance. *The Journal of Business*, 39(1), 119–138. (Publisher: University of Chicago Press) 36
- Siddaway, A. (2014). What is a systematic literature review and how do I do one. *University of Stirling*, 1, 1–13. 53
- Smales, L. A. (2021, October). Volatility Spillovers among Cryptocurrencies. *Journal of Risk and Financial Management*, 14(10), 493. doi: 10.3390/jrfm14100493 42
- Souza, K. G., Barboza, F., & Garruti, D. V. T. (2023). A discourse analysis of tweets and its implications for cryptocurrency prices and trade volumes. *Computational Economics*. 120
- Stolfi, P., Bernardi, M., & Vergni, D. (2022, December). Robust estimation of time-dependent precision matrix with application to the cryptocurrency market. *Financial Innovation*, 8(1), 47. doi: 10.1186/s40854-022-00355-4 60, 145
- Stosic, D., Stosic, D., Ludermit, T. B., & Stosic, T. (2018, October). Collective behavior of cryptocurrency price changes. *Physica A: Statistical Mechanics and its Applications*, 507, 499–509. doi: 10.1016/j.physa.2018.05.050 61, 62, 143
- Sucupira, G., Saab, F., Demo, G., & Bermejo, P. H. (2019, February). Innovation in public administration: Itineraries of Brazilian scientific production and new research possibilities. *Innovation & Management Review*, 16(1), 72–90. doi: 10.1108/INMR-03-2018-0004 55
- Susilo, D., Wahyudi, S., Pangestuti, I. R. D., Nugroho, B. A., & Robiyanto, R. (2020, October). Cryptocurrencies: Hedging Opportunities From Domestic Perspectives in Southeast Asia Emerging Markets. *SAGE Open*, 10(4), 215824402097160. doi: 10.1177/2158244020971609 30
- Swensen, D. F. (2009). *Pioneering portfolio management: An unconventional approach to institutional investment, fully revised and updated*. Simon and Schuster. 73
- Syuhada, K., & Hakim, A. (2020, December). Modeling risk dependence and portfolio VaR forecast through vine copula for cryptocurrencies. *PLOS ONE*, 15(12), e0242102. doi: 10.1371/journal.pone.0242102 46, 60, 146
- Szczygielski, J., Karathanasopoulos, A., & Zaremba, A. (2019). One shape fits all? A comprehensive examination of cryptocurrency return distributions. *Applied Economics Letters*. doi: 10.1080/13504851.2019.1697420 42
- Tavares, R. d. S., Caldeira, J. F., & Raimundo Júnior, G. d. S. (2022, January). It's all in the timing again: simple active portfolio strategies that outperform naïve diversification in the cryptocurrency market. *Applied Economics Letters*, 29(2), 118–122. doi: 10.1080/13504851.2020.1859446 61, 68, 72, 145
- Terentiev, O., Prosiiankina-Zharova, T., Savastiyarov, V., Lakhno, V., & Kolmakova, V. (2021, July). The Features of Building a Portfolio of Trading Strategies Using the SAS OPTMODEL Procedure. *Computation*, 9(7), 77. doi: 10.3390/computation9070077 62, 71, 72, 146
- Tomić, B., Žiković, S., & Jovanović, L. (2022, December). Crypto portfolio optimization through

- lens of tail risk and variance measures. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu/Proceedings of Rijeka Faculty of Economics: Journal of Economics and Business*, 40(2), 297–312. doi: 10.18045/zbefri.2022.2.297 62, 146
- Tran, M., Pham-Hi, D., & Bui, M. (2023, January). Optimizing Automated Trading Systems with Deep Reinforcement Learning. *ALGORITHMS*, 16(1). (Place: ST ALBAN-ANLAGE 66, CH-4052 BASEL, SWITZERLAND Publisher: MDPI Type: Article) doi: 10.3390/a16010023 95
- Trimborn, S., & Härdle, W. K. (2018, December). CRIX an Index for cryptocurrencies. *Journal of Empirical Finance*, 49, 107–122. doi: 10.1016/j.jempfin.2018.08.004 57, 61, 62, 143
- Trimborn, S., & Li, M. (2020). Investing with Cryptocurrencies—a Liquidity Constrained Investment Approach. *Journal of Financial Econometrics*. 61, 68, 143
- Troster, V., Tiwari, A., Shahbaz, M., & Macedo, D. (2019). Bitcoin returns and risk: A general GARCH and GAS analysis. *Finance Research Letters*, 30, 187–193. doi: 10.1016/j.frl.2018.09.014 42
- Trucíos, C., Tiwari, A. K., & Alqahtani, F. (2020, May). Value-at-risk and expected shortfall in cryptocurrencies’ portfolio: a vine copula-based approach. *Applied Economics*, 52(24), 2580–2593. doi: 10.1080/00036846.2019.1693023 38, 59, 60, 74, 143
- Wajdi, M., Nadia, B., & Ines, G. (2020, September). Asymmetric effect and dynamic relationships over the cryptocurrencies market. *Computers & Security*, 96, 101860. doi: 10.1016/j.cose.2020.101860 34, 75, 77
- Wang, M., & Ku, H. (2022, July). Risk-sensitive policies for portfolio management (R). *EXPERT SYSTEMS WITH APPLICATIONS*, 198. (Place: THE BOULEVARD, LANGFORD LANE, KIDLINGTON, OXFORD OX5 1GB, ENGLAND Publisher: PERGAMON-ELSEVIER SCIENCE LTD Type: Article) doi: 10.1016/j.eswa.2022.116807 99, 100, 104
- Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research. 43, 76, 80
- Yoo, K., Bae, K., Park, E., & Yang, T. (2019, October). Understanding the diffusion and adoption of Bitcoin transaction services: The integrated approach. *Telematics and Informatics*, 101302. doi: 10.1016/j.tele.2019.101302 27
- Yu, X., Wu, W., Liao, X., & Han, Y. (2023, January). Dynamic stock-decision ensemble strategy based on deep reinforcement learning. *APPLIED INTELLIGENCE*, 53(2), 2452–2470. (Place: VAN GODEWIJCKSTRAAT 30, 3311 GZ DORDRECHT, NETHERLANDS Publisher: SPRINGER Type: Article) doi: 10.1007/s10489-022-03606-0 99, 100, 101, 120
- Zhang, W., Li, Y., Xiong, X., & Wang, P. (2021, December). Downside risk and the cross-section of cryptocurrency returns. *Journal of Banking & Finance*, 133, 106246. doi: 10.1016/j.jbankfin.2021.106246 36, 37, 60, 143
- Zhang, W., Wang, P., Li, X., & Shen, D. (2018). Some stylized facts of the cryptocurrency market. *Applied Economics*, 50(55), 5950–5965. doi: 10.1080/00036846.2018.1488076 42

- Zitis, P. I., Contoyiannis, Y., & Potirakis, S. M. (2022, November). Critical dynamics related to a recent Bitcoin crash. *International Review of Financial Analysis*, 84, 102368. doi: 10.1016/j.irfa.2022.102368 60, 61, 145
- Čuljak, M., Tomić, B., & Žiković, S. (2022, April). Benefits of sectoral cryptocurrency portfolio optimization. *Research in International Business and Finance*, 60, 101615. doi: 10.1016/j.ribaf.2022.101615 61, 145

Apêndices

**APÊNDICE A – Resultado final da seleção de artigos após a aplicação da Etapa 7 da
Methodi Ordinatio**

N	Autor (ano)	Título dos artigos selecionados	Cita- ções	Fator de Im- pacto	InOrdi- natio
1	Bouri, Gupta, e Roubaud (2019)	Herding behaviour in cryptocurrencies	148	2.007	180.01
2	G. M. Caporale e Zekokh (2019)	Modelling volatility of cryptocurrencies using Markov-Switching GARCH models	66	1.043	97.04
3	Begušić et al. (2018)	Scaling properties of extreme price fluctuations in Bitcoin markets	66	0.891	91.89
4	Brauneis e Mestel (2019)	Cryptocurrency-portfolios in a mean-variance framework	59	2.007	91.01
5	Trimborn e Härdle (2018)	CRIX an Index for cryptocurrencies	64	1.196	90.20
6	Akhtaruzzaman et al. (2020)	The influence of Bitcoin on portfolio diversification and design	49	2.007	86.01
7	Platanakis e Urquhart (2019)	Portfolio management with cryptocurrencies: The role of estimation risk	55	0.683	85.68
8	Platanakis et al. (2018)	Optimal vs naive diversification in cryptocurrencies	59	0.683	84.68
9	Mensi et al. (2019)	Time frequency analysis of the commonalities between Bitcoin and major Cryptocurrencies: Portfolio risk management implications	46	0.709	76.71
10	Stosic et al. (2018)	Collective behavior of cryptocurrency price changes	43	0.891	68.89
11	Aslan e Sensoy (2020)	Intraday efficiency-frequency nexus in the cryptocurrency markets	31	2.007	68.01
12	Trimborn e Li (2020)	Investing with Cryptocurrencies-a Liquidity Constrained Investment Approach	21	1.625	57.63
13	Nguyen et al. (2020)	Investigating tail-risk dependence in the cryptocurrency markets: A LASSO quantile regression approach	21	1.196	57.20
14	Hsu et al. (2021)	Risk spillovers between cryptocurrencies and traditional currencies and gold under different global economic conditions	16	0.709	56.71
15	Trucíos et al. (2020)	Value-at-risk and expected shortfall in cryptocurrencies' portfolio: a vine copula-based approach	21	0.563	56.56
16	Zhang et al. (2021)	Downside risk and the cross-section of cryptocurrency returns	14	1.466	55.47

(Continua na próxima página)

Tabela 29 Resultado final da seleção de artigos. (Continuação)

N	Autor (ano)	Título dos artigos selecionados	Cita- ções	Fator de Im- pacto	InOrdi- natio
17	Kumah e Mensah (2022)	Are cryptocurrencies connected to gold? A wavelet-based quantile-in-quantile approach	9	-	54.00
18	Maghsoodi (2023)	Cryptocurrency portfolio allocation using a novel hybrid and predictive big data decision support system	0	2.741	52.74
19	Chemkha et al. (2021)	Connectedness between cryptocurrencies and foreign exchange markets: Implication for risk management	11	0.867	51.87
20	Petukhina et al. (2021)	Investing with cryptocurrencies - evaluating their potential for portfolio allocation strategies	11	0.865	51.87
21	T. Cui et al. (2023)	Portfolio constructions in cryptocurrency market: A CVaR-based deep reinforcement learning approach	0	1.065	51.07
22	Bedi e Nashier (2020)	On the investment credentials of Bitcoin: A cross-currency perspective	15	1.043	51.04
23	Khaki et al. (2023)	Re-evaluating portfolio diversification and design using cryptocurrencies: Are decentralized cryptocurrencies enough?	0	1.043	51.04
24	Hatemi-J et al. (2022)	The Benefits of Diversification Between Bitcoin, Bonds, Equities and the US Dollar: A Matter of Portfolio Construction	5	0.319	50.32
25	Kurosaki e Kim (2022)	Cryptocurrency portfolio optimization with multivariate normal tempered stable processes and Foster-Hart risk	3	2.007	50.01
26	Ma et al. (2020)	Portfolio optimization in the era of digital financialization using cryptocurrencies	12	2.336	49.34
27	Demiralay e Bayracı (2021)	Should stock investors include cryptocurrencies in their portfolios after all? Evidence from a conditional diversification benefits measure	9	-	49.00
28	James (2022)	Evolutionary correlation, regime switching, spectral dynamics and optimal trading strategies for cryptocurrencies and equities	3	0.905	48.91
29	Kosc et al. (2019)	Momentum and contrarian effects on the cryptocurrency market	18	0.891	48.89
30	Babaei et al. (2022)	Explainable artificial intelligence for crypto asset allocation	1	2.007	48.01
31	Kaya e Mostowfi (2022)	Low-volatility strategies for highly liquid cryptocurrencies	1	2.007	48.01
32	Haryanto et al. (2020)	Disposition effect and herding behavior in the cryptocurrency market	12	0.846	47.85
33	Aggarwal (2022)	Optimum investor portfolio allocation in new age digital assets	2	0.562	47.56

(Continua na próxima página)

Tabela 29 Resultado final da seleção de artigos. (Continuação)

N	Autor (ano)	Título dos artigos selecionados	Cita- ções	Fator de Im- pacto	InOrdi- natio
34	Chu et al. (2020)	High frequency momentum trading with cryptocurrencies	11	1.043	47.04
35	Lucarelli e Borrotti (2020)	A deep Q-learning portfolio management framework for the cryptocurrency market	12	-	47.00
36	J. Cui e Maghyereh (2022)	Time-frequency co-movement and risk connectedness among cryptocurrencies: new evidence from the higher-order moments before and during the COVID-19 pandemic	1	0.937	46.94
37	Zitis et al. (2022)	Critical dynamics related to a recent Bitcoin crash	0	1.833	46.83
38	Nkrumah-Boadu et al. (2022)	Safe haven, hedge and diversification for African stocks: cryptocurrencies versus gold in time-frequency perspective	1	0.411	46.41
39	Mba e Mwambetania Mwambi (2022)	Crypto-assets portfolio selection and optimization: a COGARCH-Rvine approach	1	0.383	46.38
40	Čuljak et al. (2022)	Benefits of sectoral cryptocurrency portfolio optimization	0	1.043	46.04
41	Moreno et al. (2022)	Benefits of investing in cryptocurrencies when liquidity is a factor	0	1.043	46.04
42	Stolfi et al. (2022)	Robust estimation of time-dependent precision matrix with application to the cryptocurrency market	0	0.937	45.94
43	Białkowski (2020)	Cryptocurrencies in institutional investors' portfolios: Evidence from industry stop-loss rules	10	0.683	45.68
44	X. Huang et al. (2022)	The diversification benefits of cryptocurrency asset categories and estimation risk: pre and post Covid-19	0	0.578	45.58
45	Bae e Kim (2022)	Observing Cryptocurrencies through Robust Anomaly Scores	0	0.553	45.55
46	Börner et al. (2022)	Bitcoin: like a satellite or always hardcore? A core-satellite identification in the cryptocurrency market	0	0.466	45.47
47	Tavares et al. (2022)	It's all in the timing again: simple active portfolio strategies that outperform naive diversification in the cryptocurrency market	0	0.4	45.40
48	Contreras-Valdez et al. (2022)	Bitcoin in Portfolio Selection: A Multivariate Distribution Approach	0	0.399	45.40
49	Ozdurak et al. (2022)	The Interaction of Major Crypto-assets, Clean Energy, and Technology Indices in Diversified Portfolios	0	0.38	45.38
50	Ren et al. (2022)	FINANCIAL RISK METER FOR CRYPTOCURRENCIES AND TAIL RISK NETWORK-BASED PORTFOLIO CONSTRUCTION	0	0.298	45.30

(Continua na próxima página)

Tabela 29 Resultado final da seleção de artigos. (Continuação)

N	Autor (ano)	Título dos artigos selecionados	Cita- ções	Fator de Im- pacto	InOrdi- natio
51	Tomić et al. (2022)	Crypto portfolio optimization through lens of tail risk and variance measures [Optimizacija portfelja kriptovaluta koristeći mjere rizika repa distribucije i varijancu]	0	0.214	45.21
52	Hashemkhani Zolfani et al. (2022)	An asymmetric PROMETHEE II for cryptocurrency portfolio allocation based on return prediction	0	-	45.00
53	Burggraf (2021)	Beyond risk parity - A machine learning-based hierarchical risk parity approach on cryptocurrencies	2	2.007	44.01
54	Chaudhari e Crane (2020)	Cross-correlation dynamics and community structures of cryptocurrencies	7	0.991	42.99
55	Mensi et al. (2020)	Dynamic volatility transmission and portfolio management across major cryptocurrencies: Evidence from hourly data	7	0.709	42.71
56	Mba e Mwambi (2020)	A Markov-switching COGARCH approach to cryptocurrency portfolio selection and optimization	7	0.319	42.32
57	Pradhan et al. (2021)	Optimizing the market-risk of major cryptocurrencies using CVaR measure and copula simulation	2	0.156	42.16
58	Nakano e Takahashi (2020)	A new investment method with AutoEncoder: Applications to crypto currencies	5	2.07	42.07
59	Fantazzini e Zimin (2020)	A multivariate approach for the simultaneous modeling of market risk and credit risk for cryptocurrencies	6	0.846	41.85
60	Castro et al. (2020)	Crypto-assets portfolio optimization under the omega measure	6	0.301	41.30
61	Terentiev et al. (2021)	The Features of Building a Portfolio of Trading Strategies Using the SAS OPTMODEL Procedure	0	0.389	40.39
62	Portelinha (2021)	The impacts of cryptocurrencies in the performance of Brazilian stocks' portfolios	0	0.239	40.24
63	Batista e Alves (2021)	Analysis of Bitcoin's Impact on the Efficiency of a Diversified Portfolio for Brazilian Investors	0	-	40.00
64	Hordei et al. (2021)	Optimization of the Investment Portfolio in the Environment of Table Processor MS Excel	0	-	40.00
65	Syuhada e Hakim (2020)	Modeling risk dependence and portfolio VaR forecast through vine copula for cryptocurrencies	4	0.852	39.85
66	Ababio et al. (2020)	Optimisation of mixed assets portfolio using copula differential evolution: A behavioural approach	4	0.411	39.41
67	Schellinger (2020)	Optimization of special cryptocurrency portfolios	4	0.365	39.37
68	Ha e Moon (2018)	Finding attractive technical patterns in cryptocurrency markets	13	1.344	39.34
69	Omane-Adjepong et al. (2019)	Time-frequency analysis of behaviourally classified financial asset markets	6	1.043	37.04

(Continua na próxima página)

Tabela 29 Resultado final da seleção de artigos. (*Continuação*)

N	Autor (ano)	Título dos artigos selecionados	Cita- ções	Fator de Im- pacto	InOrdi- natio
70	Mba et al. (2018)	A differential evolution copula-based approach for a multi-period cryptocurrency portfolio optimization	11	0.319	36.32
71	Bondar et al. (2020)	Efficiency of using cryptocurrencies as an investment asset	1	-	36.00