

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Viviane de Senna

**ESTRATÉGIA METODOLÓGICA INOVADORA NA DETERMINAÇÃO
DO IMPACTO DE FATORES SUBJETIVOS EM MODELOS DE
PREVISÃO**

Santa Maria, RS
2024

Viviane de Senna

**ESTRATÉGIA METODOLÓGICA INOVADORA NA DETERMINAÇÃO DO
IMPACTO DE FATORES SUBJETIVOS EM MODELOS DE PREVISÃO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Maria (UFSM), como requisito parcial para a obtenção do título de **Doutor em Engenharia de Produção**.

Orientador: Dr. Adriano Mendonça Souza

Santa Maria
2024

Viviane de Senna

**ESTRATÉGIA METODOLÓGICA INOVADORA NA DETERMINAÇÃO DO
IMPACTO DE FATORES SUBJETIVOS EM MODELOS DE PREVISÃO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Maria (UFSM), como requisito parcial para a obtenção do título de **Doutor em Engenharia de Produção**.

Aprovado em 05 de fevereiro de 2024:

Adriano Mendonça Souza, Dr (UFSM) (Presidente/Orientador)

Ângela Isabel dos Santos Dullius, Dr. (UFSM)

Daniel Arruda Coronel, Dr. (UFSM)

Luciana Santos Costa Vieira da Silva, Dr. (UFSM)

Vinícius Costa da Silva Zonatto, Dr. (UFAL)

Wesley Vieira da Silva, Dr. (UFAL)

Santa Maria, RS
2024

de Senna, Viviane
ESTRATÉGIA METODOLÓGICA INOVADORA NA DETERMINAÇÃO DO
IMPACTO DE FATORES SUBJETIVOS EM MODELOS DE PREVISÃO /
Viviane de Senna.- 2024.
188 p.; 30 cm

Orientador: Adriano Mendonça Souza
Tese (doutorado) - Universidade Federal de Santa
Maria, Centro de Tecnologia, Programa de Pós-Graduação em
Engenharia de Produção, RS, 2024

1. Séries Temporais 2. Variáveis qualitativas 3. Vari-
áveis dummy 4. Modelos de previsão I. Mendonça Souza,
Adriano II. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, VIVIANE DE SENNA, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

RESUMO

ESTRATÉGIA METODOLÓGICA INOVADORA NA DETERMINAÇÃO DO IMPACTO DE FATORES SUBJETIVOS EM MODELOS DE PREVISÃO

AUTORA: Viviane de Senna
ORIENTADOR: Adriano Mendonça Souza

Os modelos de séries temporais tradicionais consideram apenas as observações quantitativas com relação a um determinado fenômeno a ser explicado. No entanto, existem situações que ocorrem em determinados cenários que são capazes de gerar interferências nas observações, mas nem sempre podem ser quantificadas, pois são variáveis qualitativas. O objetivo deste estudo foi desenvolver uma estratégia metodológica capaz de captar os efeitos de variáveis qualitativas é otimizar as previsões dos modelos tradicionais. A metodologia adotada para isso foi a *Design Science Research Methodology* – DSRM, que visa, através de um processo rigoroso de projetar artefatos para resolver problemas, avaliar resultados do projeto e comunicar as conclusões obtidas. As variáveis quantitativas selecionadas para aplicação da estratégia foram índices de bolsas de valores localizadas em todos os continentes, criptomoedas, e as variáveis qualitativas foram as frequências de focos de queimadas ocorridos nos países em que as bolsas estão localizadas. Foram ajustados os modelos ARIMA e extensões para todas as séries, como ARIMAX-GARCH. Esses modelos foram melhorados pela aplicação da estratégia da inserção das variáveis qualitativas na metodologia Box Jenkins, como exógenas do tipo *dummy* “0” ou “1”. As observações foram divididas em quartis e definidas como *dummies* “1” em todas as frequências posicionadas acima do terceiro quartil. As *dummies* inseridas nos modelos mais complexos, como ARIMAX-GARCH são estatisticamente significativas.

Palavras-chave: Séries Temporais. Variáveis qualitativas. Variáveis *dummy*. Modelos de previsão.

ABSTRACT

INNOVATIVE METHODOLOGICAL STRATEGY IN DETERMINING THE IMPACT OF SUBJECTIVE FACTORS IN FORECASTING MODELS

AUTHOR: Viviane de Senna
ADVISOR: Adriano Mendonça Souza

Traditional time series models consider only quantitative observations regarding a certain aspect to be explained. However, there are situations that occur in certain scenarios that can generate interference in observations, but cannot always be quantified, as they are qualitative variables. The objective of this study was to develop a methodological strategy capable of capturing the effects of qualitative variables and optimizing the integration of traditional models. The methodology adopted to do so was the Design Science Research Methodology – DSRM, which aims, through a rigorous process of designing projects to solve problems, to evaluate project results and communicate the conclusions obtained. The quantitative variables selected to apply the strategy were indices of stock exchanges located on all continents, cryptocurrencies, and the qualitative variables were the frequencies of wildfires that occurred in the countries where the exchanges are located. ARIMA models and extensions for all series were adjusted, such as ARIMAX-GARCH. These models were improved by applying the strategy of inserting qualitative variables in the Box Jenkins methodology, as exogenous dummy types “0” or “1”. The observations were divided into quartiles and defined as dummies “1” in all frequencies positioned above the third quartile. The dummies inserted in more complex models, such as ARIMAX-GARCH, are statistically significant.

Keywords: Time Series. Qualitative variables. Model. Forecast.

SUMÁRIO

1	INTRODUÇÃO	6
2	MATERIAIS E MÉTODOS	11
3	ARTIGO 1 - SÉRIES TEMPORAIS E VARIÁVEIS QUALITATIVAS: REVISÃO SISTEMÁTICA DE LITERATURA	20
4	ARTIGO 2 - AS CRIPTOMOEDAS, AS BOLSAS DE VALORES E SUAS RELAÇÕES: REVISÃO SISTEMÁTICA DE LITERATURA	41
5	ARTIGO 3 - IMPACTS OF SHORT AND LONG-TERM BETWEEN CRYPTOCURRENCIES AND STOCK EXCHANGE INDEXES.....	69
6	ARTIGO 4 - INFLUÊNCIA DAS CRIPTOMOEDAS NAS BOLSAS DE VALORES GLOBAIS	93
7	ARTIGO 5 - OTIMIZAÇÃO DAS PREVISÕES COM A INTEGRAÇÃO DE VARIÁVEIS QUALITATIVAS EM MODELOS DE SÉRIES TEMPORAIS.....	129
8	DISCUSSÃO	173
9	CONSIDERAÇÕES FINAIS.....	180
	REFERÊNCIAS	183

1 INTRODUÇÃO

Os modelos de séries temporais são utilizados para obter, de forma estruturada, uma visão da realidade por meio de uma representação de um sistema ou objeto, utilizando a linguagem matemática (CAUCHICK-MIGUEL et al., 2018). No entanto, é comum que esses modelos se concentrem principalmente em variáveis quantitativas, não considerando as influências de variáveis qualitativas. São consideradas variáveis qualitativas aquelas que não possuem quantidades a elas associadas, ou seja, são categorias ou classificações (CORRAR; PAULO; DIAS FILHO, 2014).

Muitas vezes as variáveis qualitativas podem melhorar os resultados preditivos gerados pelos modelos, como é o caso de Pecican (2010) que elaborou uma variante do modelo VAR, denominado VAR aberto, no qual incluiu um número limitado de variáveis exógenas ao preço ao consumidor, taxa de câmbio, salários, taxa de juros. Com a inserção das variáveis qualitativas como notícias, metas, eventos esperados, observou que na economia, as principais influências externas ocorrem na área de política, nas tentativas de manter o equilíbrio econômico.

Dueker (2005) acrescentou ao modelo VAR informações qualitativas e/ou discretas transformando-o Qual VAR capaz de prever recessões de negócios pelo acréscimo de variáveis qualitativas. O Qual VAR inclui informações sobre a variável qualitativa na forma de uma variável latente normal truncada. A aplicação foi feita para prever a recessão de negócios de 2001 fora da amostra e para analisar a medida narrativa de Blanchard et al. (1989) das contrações da política monetária como uma variável endógena em um VAR. O conjunto de variáveis macroeconômicas, X , no VAR de previsão incluiu a taxa de crescimento trimestral do PIB real ponderado em cadeia, a inflação trimestral no índice de preços ao consumidor, o *spread* de prazo entre os rendimentos de Títulos do Tesouro de 10 anos e Letras do Tesouro de 3 meses, e a taxa efetiva de fundos federais. O modelo previu o momento da recessão de 2001 muito bem em relação às probabilidades de recessão apresentadas na época por analistas profissionais.

Wang et al. (2012) utilizaram regressão múltipla com variáveis qualitativas e quantitativas para prever o vazamento dos gases da explosão para o meio ambiente. As variáveis qualitativas capazes de interferir no sistema foram consideradas a pressão do gás na cavidade e a permeabilidade do maciço rochoso, a incerteza do maciço

geológico. Elas foram quantificadas de acordo com a significância física, a teoria da quantificação, princípio de seleção de variáveis, avaliação de significância e teste de recorrência para estabelecer um modelo de previsão de quantificação. A partir do processo matemático efetuado com 15 amostras, do teste teórico e do teste amostral, este método é eficaz com as variáveis selecionadas, a previsão apresentou maior precisão. Com base nos sete modelos de variáveis estabelecidos, as amostras existentes foram submetidas ao cálculo de predição, e os erros são menores do que uma ordem de magnitude.

Em estudos econômicos é válido considerar eventos esportivos de grande porte como olimpíadas ou copas do mundo de futebol, campanhas políticas, escândalos envolvendo corrupção, notícias falsas, eventos culturais ou datas comemorativas, como carnaval, Páscoa, festas de final de ano, entre outros. A relevância destas variáveis para o estudo é definida pelo conhecimento de especialistas na área específica do estudo, este estudo é focado em Engenharia de Produção, na linha de pesquisa de Métodos Quantitativos para a Tomada de Decisão.

O problema de pesquisa deste estudo provém da seguinte questão: qual a estratégia metodológica capaz de captar o efeito das variáveis quantitativas e otimizar as previsões dos modelos de séries temporais tradicionais? A originalidade e a contribuição deste estudo estão na proposição de uma abordagem inovadora para aprimorar modelos de previsão ao incorporar variáveis qualitativas. Ao contrário dos métodos tradicionais que desconsideram esses aspectos, este estudo se diferencia por considerar o potencial das variáveis qualitativas para melhorar a precisão das previsões.

O estudo se destaca e diferencia por sua aplicação prática em diversas áreas, como finanças, economia, saúde pública e meio ambiente. Ao desenvolver uma estratégia metodológica robusta e aplicável para integrar variáveis qualitativas em modelos de previsão, o estudo oferece percepções valiosas e soluções tangíveis para problemas do mundo real. Ao reconhecer e integrar efetivamente variáveis qualitativas em modelos de previsão de séries temporais, há a contribuição significativa para o avanço do conhecimento e aprimoramento das estratégias de previsão e tomada de decisão em diversas áreas. Como hipótese, acredita-se que a inclusão de variáveis qualitativas em modelos de previsão de séries temporais resultará em previsões precisas e na compreensão mais abrangente dos fenômenos estudados.

O objetivo Geral do estudo é desenvolver uma estratégia metodológica capaz de captar os efeitos de variáveis qualitativas e otimizar as previsões dos modelos de séries temporais tradicionais. Para atingir o objetivo geral e desenvolver o estudo foram definidos os objetivos específicos:

- **Realizar um panorama sobre a situação científica com relação a aplicação de variáveis qualitativas em modelos de previsão de séries temporais;**
- **Estabelecer um conjunto de séries temporais adequadas para a modelagem, com relação de causalidade e que possibilite a aplicação de variáveis qualitativas;**
- **Identificar variáveis qualitativas que possam impactar o conjunto de séries em estudo;**
- **Avaliar o efeito de uma variável qualitativa em modelo de séries temporais para validar a estratégia proposta.**

Em suma, a estratégia desenvolvida deve ser capaz de inserir variáveis qualitativas em modelos de séries temporais com a finalidade de otimizar as previsões.

A justificativa do estudo decorre do fato de que as pessoas são o resultado dos estudos que realizam e se dedicam, professores que os orientam, livros que leem, viagens que fazem, e grupos sociais que convivem. Todavia, alguns dos exemplos interferem mais do que outros e considerando-os como variáveis qualitativas, quais possuem maior capacidade de influenciar na vida e carreira das pessoas? O estudo em questão existe e sofre influência direta do orientador da pesquisa, que de forma incomum tem a aptidão de impulsionar alguns dos seus acadêmicos a ir além do *status quo* atual. Esta razão foi determinante para a escolha da temática, dado que a opinião de um professor, bem como outros professores que compõem o departamento, interfere a ponto de modificar e impulsionar os acadêmicos a irem em busca do novo, do desenvolvimento intelectual que contribuirá para o incremento do conhecimento científico e, conseqüentemente, contribuindo para o avanço da sociedade em geral.

A academia é fundamental para a transformação dos acadêmicos, para estimular a autonomia intelectual, cultural e profissional. Em contrapartida ela depende da comunidade acadêmica para fomentar a pesquisa, evoluir na integração com a comunidade e disseminar o conhecimento. Com o avanço tecnológico a ampliação do

acesso à informação o conhecimento gerado em qualquer lugar do mundo tem a potencialidade de ser difundido e acessado por todos através dos meios de publicações. Por isso, o desenvolvimento dessa e outras pesquisas colaboram para o meio acadêmico como impulsionadoras do avanço e inovação das pesquisas na área da engenharia de produção.

O avanço das técnicas de previsão é uma necessidade, visto que variáveis qualitativas desempenham interferências capazes de gerar até mesmo *outliers*. A integração dessas variáveis em modelos de previsão representa uma abordagem inovadora e necessária para capturar nuances complexas que influenciam fenômenos. Este estudo busca preencher essa lacuna ao desenvolver uma estratégia metodológica combinando elementos dos modelos ARIMAX com GARCH e variáveis qualitativas para aprimorar a precisão das previsões.

Os dados selecionados para estudo do modelo são compostos por séries de índices de vinte e uma Bolsas de Valores e três criptomoedas. Essa definição foi tomada devido a disponibilidade de coleta de dados econômicos, bem como a possibilidade de organização de um sistema com mesma periodicidade e quantidade de observações. As criptomoedas foram incluídas ao sistema por serem novos tipos de ativos com transações efetuadas por meio diferente do tradicional (LIANG; LI; ZENG, 2018). A quantidade de séries selecionadas objetiva a verificação do impacto de uma variável qualitativa em séries com relação de causalidade, em destaque as unidirecionais, pois a relação é de uma variável A para a outra B apenas. A proposta é gerar um modelo que possa ser aplicado a outros tipos de séries, como por exemplo séries históricas de produção industrial.

As variáveis qualitativas são referentes aos focos de queimadas ocorridos nos países em que as bolsas de valores estão localizadas. A definição dessa variável decorre dos resultados obtidos no Artigo 2, no qual foram verificados os estudos que relacionaram bolsas de valores e criptomoedas. As queimadas, consequentes de atividades naturais ou antrópicas intencionais ou acidentais, geram a liberação de gases, como o gás carbônico, que são responsáveis pelo aumento do efeito estufa, que contribui para o aquecimento global. O aumento da temperatura média global resulta em mudanças climáticas que interferem na capacidade produtiva dos países em várias áreas,

incluindo agricultura, pesca, silvicultura e indústrias relacionadas, principalmente a de alimentos.

Quando ocorre muita emissão de gás carbônico na atmosfera, oriundo de um mesmo país, há o impacto negativo no desempenho dos índices das bolsas de valores decorrente do comportamento dos ativos que os compõe. As séries de frequências de focos foram transformadas em variáveis do tipo *dummy* “0” e “1”, para definir não ocorrência e a ocorrência, respectivamente.

Ao selecionar as séries temporais e identificar variáveis qualitativas impactantes, este estudo visa oferecer *insights* valiosos para profissionais financeiros, investidores e pesquisadores. A implementação dessa estratégia pode não apenas melhorar as previsões, mas também proporcionar uma compreensão mais profunda das dinâmicas de mercado, contribuindo assim para a eficácia das estratégias de tomada de decisão.

Além disso, a aplicação do modelo proposto a séries de índices de bolsas de valores e criptomoedas reflete a contemporaneidade do estudo, considerando a relevância das criptomoedas no cenário financeiro global. Essa abordagem inovadora visa não apenas avançar na compreensão teórica, mas também a oferecer ferramentas práticas e aplicáveis para profissionais que buscam otimizar suas estratégias de investimento e gestão de risco.

O presente estudo será estruturado por esta introdução, pela descrição dos materiais e métodos utilizados para a realização do estudo, por cinco artigos científicos, pela discussão, pelas considerações finais e pelas referências. O Artigo 1 contém a revisão sistemática sobre as séries temporais e variáveis qualitativas, o Artigo 2 uma revisão sistemática sobre os índices das Bolsas de Valores e as criptomoedas, o Artigo 3 que avalia a relação entre os índices das Bolsas e as criptomoedas, o Artigo 4 que define os modelos mais adequados para cada uma das séries que compõe o conjunto e o Artigo 5 que apresenta a estratégia utilizada para a inserção de uma variável qualitativa em modelos de séries temporais.

2 MATERIAIS E MÉTODOS

A classificação da pesquisa é indutiva quanto ao método científico, de natureza básica, bibliográfica no que se refere aos procedimentos técnicos e a abordagem do problema é quantitativa. O método científico indutivo consiste em basear o conhecimento na experiência, na generalização oriunda da observação de casos da realidade (GIL, 2008). O estudo buscou através da modelagem de várias séries verificar se a inserção de uma variável qualitativa pode melhorar o modelo.

Uma pesquisa de natureza básica visa descobertas e teorias que formam a base para futuras pesquisas e aplicações práticas. A pesquisa bibliográfica é aquela efetuada em fontes públicas, ou seja, livros, revistas, monografias, teses, artigos científicos, ou até mesmo em filmes e vídeos (MALHOTRA, 2006). Por esse tipo de pesquisa o pesquisador consegue aprofundar o conhecimento sobre determinado tema ou assunto de interesse. Foram feitas pesquisas, principalmente em artigos científicos, que serviram como base para a construção dessa.

Em uma pesquisa quantitativa os pesquisadores se valem de amplas amostras e de informações numéricas para chegar a conclusões (MARCONI; LAKATOS, 2018). É uma pesquisa que permite comprovar numericamente, através de experimentos e observações, os resultados (GIL, 2008). Esse estudo efetua uma análise e comparação numérica dos resultados obtidos.

O estudo foi estruturado tomando como base a metodologia o *Design Science Research Methodology* – DSRM, que consiste em um processo rigoroso de projetar artefatos para resolver problemas, avaliar resultados do projeto e comunicar as conclusões obtidas. A metodologia DSRM tem como origem na proposta de Simon, que em 1969, propôs a diferenciação entre ambientes naturais e artificiais (SIMON, 1996). A ciência natural tem como objetivo descrever o funcionamento dos fenômenos naturais, suas características e comportamentos. Os fenômenos artificiais ou as ciências artificiais precisam ser estudados na concepção de artefatos que realizem objetivos (SIMON, 1996).

A *Design Science*, ou Ciência de Projeto, visa identificar a concepção de “o que” e “como” são os fenômenos artificiais, ou seja, como as coisas devem funcionar para atingir determinados objetivos. Ela consiste em desenvolver conhecimento para a concepção e desenvolvimento de artefatos que contribuirão para o avanço das pesquisas

científicas. A *Design Science* admite a utilização de métodos mistos de pesquisa, com ênfase no desenvolvimento tecnológico aplicável a Engenharia de Produção, o que auxilia a desenvolver uma epistemologia da Engenharia (LACERDA et al., 2013).

A aplicação da metodologia pode direcionar o projeto de artefatos a apresentar melhores soluções para os problemas existentes. Os estudos relacionados a organizações devem incluir a *Design Science* e a *Design Science Research*, como formas de gerar conhecimento e realizar pesquisas científicas (ROMME, 2003). O conhecimento gerado pelo *Design Science* é multidisciplinar e focado em resolver problemas complexos que consideram o contexto e a aplicação dos resultados (BURGOYNE; JAMES, 2006). E a *Design Science Research* é o método que operacionaliza a construção do conhecimento através de um processo rigoroso de projeção de artefatos para resolver problemas, avaliar o projeto e comunicar os resultados obtidos (ÇAĞDAŞ; STUBKJÆR, 2011).

A *Design Science Research* consiste em seis etapas, por Peffers et al. (2007), da seguinte forma:

1. Identificação do problema e motivação. Nesta etapa é necessário definir um problema de pesquisa específico e justificar o valor da solução. Esta definição será utilizada para desenvolver um artifício que pode efetivamente indicar a solução para o problema. Os recursos necessários para essa etapa, o estado da arte e a relevância da solução.
2. Definição dos objetivos para a solução. Inferir os objetivos, que podem ser quantitativos ou qualitativos, para a solução do problema a partir da definição do que é possível e viável. Esses objetivos devem ser racionais a partir da especificação do problema.
3. Design e desenvolvimento. Criação do artefato e a determinação da funcionalidade e arquitetura.
4. Demonstração. Demonstrar o uso do artefato para resolver uma ou mais partes do problema, que pode ser experimentação, simulação, prova ou outra atividade apropriada. Serve de recurso para esta etapa o conhecimento de como usar o artefato para resolver o problema.
5. Avaliação. Observar e mensurar como o artefato atende a solução do problema em comparação aos objetivos propostos. Os resultados podem indicar a solução

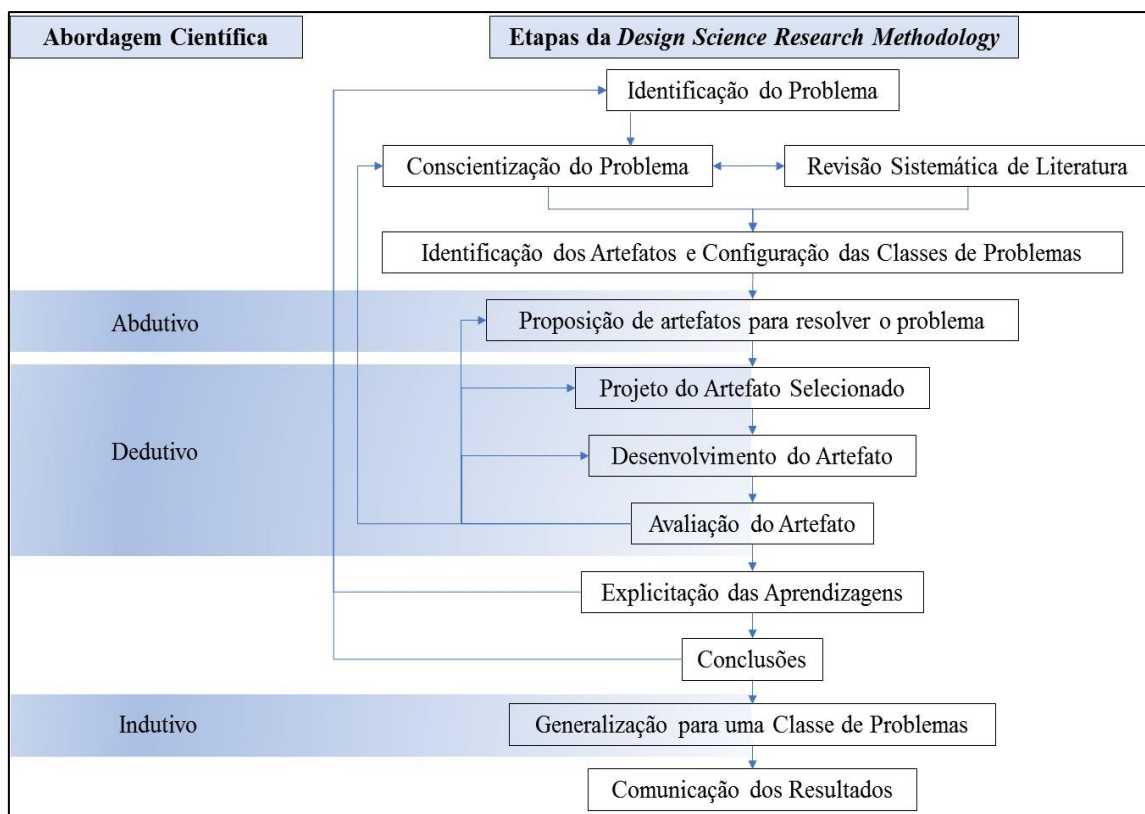
para os objetivos ou o retorno às etapas de definição dos objetivos ou de design do artefato.

6. Comunicação. Comunicar o problema, a relevância da proposta e a solução apresentando o artefato desenvolvido a utilidade e a novidade.

Apesar de existirem as etapas, não há a obrigatoriedade de cumprir a sequência indicada, mas é aconselhado. Em casos de sequência inversa, o artefato pode ser descoberto sem o formal pensamento sobre a solução, pode ter surgido de ideia análoga ou baseado na observação.

As etapas da *Design Science Research*, podem ser descritas com maior detalhamento conforme Figura 1 (LACERDA et al., 2013):

Figura 1 – Etapas da metodologia *Design Science Research*



Fonte: Adaptado de (LACERDA et al., 2013)

As etapas descritas na Figura 1 são apresentadas com maior detalhamento. Partindo da identificação do problema, teórico ou prático, é iniciado o procedimento de conscientização do problema. Devem ser analisadas as repercussões do problema diante da existência e persistência na organização e as metas necessárias para resolvê-lo de maneira satisfatória. Após a conscientização é iniciada a revisão sistemática na literatura

e o levantamento das soluções empíricas conhecidas, ou seja, a revisão empírica, que consiste na busca pela identificação dos artefatos.

Os artefatos podem ser constructos, modelos, métodos, instanciações ou objetos, mas não necessariamente precisam ser um objeto concreto (MARCH; SMITH, 1995). São objetos artificiais, funções ou adaptações, discutidos durante a concepção (SIMON, 1996), ou seja, a ferramenta que será gerada com o intuito de solucionar o problema. As instanciações podem se referir a um artefato ou à articulação de artefatos para a produção de um resultado em um contexto (LACERDA et al., 2013). Essas instanciações podem preceder a articulação do constructo e demonstrar a viabilidade e a eficácia dos modelos e métodos (MARCH; SMITH, 1995). Os artefatos são construídos para servir de interface entre o ambiente interno e o externo do sistema em estudo, consistem no produto resultante da *Design Science Research*.

As classes de problemas foram exemplificadas por Simon (1996), que não criou uma definição, mas pela interpretação consistem em uma organização para a trajetória de desenvolvimento do conhecimento em uma *Design Science*. Essas classes permitem que as soluções encontradas sirvam para resolução de mais problemas, não somente aquele em um determinado contexto. A *Design Science* se preocupa com o conhecimento que pode ser utilizado para projetar solução, não com a ação em si (VAN AKEN, 2004). Para Lacerda et al. (2013), classe de problemas é a organização de um conjunto de problemas práticos ou teóricos, com artefatos úteis para a ação nas organizações.

As soluções podem compartilhar características que permitam a organização de uma *Design Science* por classes de problemas, habilitando a generalização e o avanço do conhecimento. A generalização dos artefatos precisa ser extensiva para uma classe de problemas (VAN AKEN, 2004), a *Design Science* reconhece que os problemas que existem nas organizações costumam ser específicos, o que pode inviabilizar um conhecimento generalizável (LACERDA et al., 2013).

O procedimento de avaliação do artefato visa medir o comportamento deste para a solução do problema, comparar os resultados obtidos com os previstos dentro do contexto experimental. Ferramentas e procedimentos devem ser empregados para que a avaliação seja feita com rigor, como a observação, a análise, a experimentação e testes funcionais e estruturais. De posse dos resultados da avaliação as conclusões geradas e o

aprendizado obtido para a ser divulgado para servir de referência para outras pesquisas. É importante incluir decisões tomadas durante o processo que foram relevantes para chegar à conclusão, bem como as limitações encontradas.

As vantagens encontradas pela utilização do DSR são a estruturação da pesquisa pela divisão em etapas; a orientação para o problema, pois enfatiza a criação de artefatos ou soluções que abordem o problema; a iteração contínua entre o desenvolvimento do artefato e a avaliação de sua eficácia; e a flexibilidade dado que pode ser adaptado a vários contextos de pesquisa. As desvantagens que podem ser citadas são a complexidade, porque exige uma compreensão detalhada das etapas e processos envolvidos; a avaliação subjetiva da eficácia do artefato que muitas vezes depende da opinião de especialistas ou usuários finais, o que pode tornar a validação mais difícil; o processo iterativo do DSR pode ser demorado e exigir recursos substanciais, principalmente se envolver o desenvolvimento de protótipos ou soluções tecnológicas complexas; os resultados podem ter limitações em termos de generalização para outros contextos ou situações. Embora o método possa oferecer uma estrutura orientada para a solução de problemas, é importante considerar as vantagens e desvantagens ao decidir aplicá-lo.

Neste estudo as etapas do método *Design Science Research* foram divididas em introdução, materiais e métodos, cinco artigos científicos, discussão e considerações finais. Na **introdução**, texto anterior, constam a identificação e a conscientização do problema, os objetivos geral e específicos e a justificativa. O objetivo geral foi subdividido em objetivos específicos que resultaram em temas de artigos. Essa escolha foi feita visando explorar a temática e apresentar de forma organizada as metodologias adotadas separadamente.

No **Artigo 1** foi elaborada uma revisão sistemática de literatura sobre os modelos de séries temporais e variáveis qualitativas, com o objetivo de compreender o conhecimento que foi construído pela união dos modelos de séries temporais e variáveis qualitativas e assim, encontrar uma lacuna de conhecimento que apoio e embase o desenvolvimento deste estudo. O método seguido foi o protocolo de Thomé, Scavarda e Scavarda (2016), em que foi realizada a coleta de artigos científicos nas bases internacionais *Scopus* e *Web of Science*, com periodicidade livre e com o *String* ("*qualitative variable*" AND "*time series*") OR ("*qualitative variable*" AND *forecast**)

OR ("*qualitative variable*" AND "*Box*Jenkins*") OR ("*qualitative variable*" AND ARIMA). Foram coletados artigos científicos avaliados por pares e após a leitura dos resumos foi feita a exclusão daqueles com temática inadequada para o estudo, dos repetidos e dos indisponíveis. Nos demais artigos, considerados adequados para foi utilizado o *software* livre RStudio, pacote Bibliometrix (<https://www.bibliometrix.org>) (ARIA; CUCCURULLO, 2017) para a análise. O artigo foi publicado na revista científica Produção Online: revista científica eletrônica de engenharia de produção.

O **Artigo 2** é composto por uma revisão sistemática de literatura sobre produções científicas que relacionam criptomoedas e Bolsas de Valores. O intuito foi identificar estudos que unem esses temas e conhecer mais sobre o tipo de variáveis selecionadas para compor o banco de dados. Com esses dois artigos foi possível identificar a revisão teórica necessária para dar **embasamento às discussões, bem como reforço para a conscientização da relevância do estudo**. O estudo foi desenvolvido considerando o protocolo de Thomé, Scavarda e Scavarda (2016), com base na coleta do *String* (*Cryptocurrenc** AND "*Stock Exchanges*") OR (*Crypto-asset* AND "*Stock Exchange*") OR ("*Digital Stocks*" AND "*Stock Exchange*") OR ("*Digital Currenc**" AND "*Stock Exchange*") OR ("*Virtual currenc**" AND "*Stock Exchange*"). A coleta foi efetuada nas bases internacionais *Scopus* e *Web of Science*, com periodicidade livre, e foram selecionados os artigos científicos avaliados por pares. Após a leitura do resumo desses artigos permaneceram no estudo os que se relacionaram com a temática, não repetidos e disponíveis para a consulta. A análise foi feita com apoio do pacote Bibliometrix (<https://www.bibliometrix.org>) (ARIA; CUCCURULLO, 2017) do *software* livre RStudio. Este artigo foi publicado na revista RAE-Revista de Administração de Empresas | FGV EAESP.

Para o desenvolvimento do **Artigo 3** foram coletadas as séries temporais de índices de vinte e uma Bolsas de Valores e três criptomoedas. As variáveis que fizeram parte do estudo foram coletadas no site Yahoo Finanças (<https://br.financas.yahoo.com/>) do período compreendido entre os dias 23/10/2014 e 30/12/2020, totalizando 1.562 observações de cada série, conforme estão descritas na Tabela 1.

Tabela 1 – Séries temporais selecionadas para desenvolver o estudo.

Código	Nome do Índice	Bolsa de Valores	País
159903.SZ	China SZSE Component Index Fund/ETF	Shenzhen	China
AXAT	Austrália S&P/ASX ALL Australian 200	Austrália	Austrália
BSESN	Índia Bombay S&P BSE Sensex	Bombaim	Índia

FTSE	London FTSE 100	Londres	Inglaterra
HSI	Hang Seng Index	Hong Kong	China
KLSE	FTSE Bursa Malaysia KLCI	Malásia	Malásia
KS11	Korea KOSPI Composite Index	Coreia do Sul	Coreia do Sul
MERV	MERVAL	Buenos Aires	Argentina
N100	EURONEXT 100	Paris	França
N225	Nikkei 225 Osaka	Tokyo	Japão
NSEI	Índia NIFTY 50	Índia	Índia
SSE180	SSE 180 Index	Shanghai	China
SSMI	Suíça SMI	Suíça	Suíça
STI	FTSE Straits Times Singapore	Singapura	Singapura
TWII	FTSE MIB Index	Milão	Itália
DAX	Frankfurt Global X DAX Germany ETF	Frankfurt	Alemanha
FNCMX	Fidelity NASDAQ Composite Index	Nasdaq	Estados Unidos
IBOV	IBOVESPA	B3, Brasil Bolsa Balcão	Brasil
IMOEX.ME	MOEX Russia Index	Moscow	Rússia
JSE.JO	JSE Limited	Johannesburg	África do Sul
TA35.TA	TA-35	Tel Aviv	Israel
BTC	Bitcoin		
XRP	Ripple		
LTC	Litecoin		

Fonte: Autores

As variáveis indicadas na Tabela 1 foram selecionadas com o intuito de representar séries de países e continentes diferentes, mas correlacionadas entre si. As criptomoedas são constituídas de forma diferente das Bolsas de Valores, por isso foram selecionadas para compor o conjunto de séries, pois disputam mercado. Estas variáveis são secundárias, abertas de fácil disponibilidade e podem representar Bolsas de Valores localizadas em países distintos de forma global e em setores mercadológicos diferentes. A escolha das Bolsas listadas na Tabela 1 baseou-se na disponibilidade de publicações com a mesma periodicidade e pelo mesmo período. Nos casos em que faltaram observações, essas foram incluídas pela aplicação de média móvel das observações mais próximas.

No **Artigo 3** foram aplicados os modelos VAR/VEC com o intuito de verificar a existência de causalidade entre as variáveis, bem como as relações de curto e longo prazo do sistema. Essas características são pré-requisitos para a estruturação do modelo em estudo. Para tanto foram avaliadas as séries indicadas na Tabela 1, com auxílio do *software* RStudio quanto à Estacionariedade pelos testes de Augmented Dickey Fuller – ADF (1981), teste não-paramétrico de Phillips e Perron – PP (1988) e teste Kwiatkowski, Phillips, Schmidt and Shin – KPSS (1992); a causalidade pelo teste de Granger (1986), o modelo de autorregressão vetorial VAR (SIMS, 1980), a cointegração

pelo Método de Johansen (1988), Modelo de Correção de Erros – VEC (ENGLE; GRANGER, 1987). Por este artigo pretendeu-se iniciar a fase de identificação do artefato e classes de problemas descritas na DSR. Este artigo foi publicado na revista *Quality & Quantity*.

O **Artigo 4** teve como objetivo a identificação dos modelos ARMAX das séries do sistema. O intuito foi conhecer os modelos baseados na metodologia Box Jenkins com a inserção das criptomoedas como variáveis exógenas para avaliar o comportamento das séries das Bolsas de Valores. As séries utilizadas para esse artigo foram as mesmas utilizadas no Artigo 3, no entanto a periodicidade das séries foi semanal do período compreendido entre a primeira semana de maio de 2013 até a última semana do mês de agosto de 2023, totalizando 539 observações. Essa alteração foi necessária devido a impossibilidade de encontrar modelos adequados para as séries. A característica de volatilidade das séries dificultou o desenvolvimento de modelos diários e, após vários testes e transformações com insucessos sucessivos, a periodicidade das séries foi alterada. Com periodicidade semanal os índices das bolsas e as criptomoedas apresentaram menor variação o que possibilitou a geração dos modelos.

A sequência metodológica do artigo será foi a verificação da estacionariedade das séries descritas na Tabela 1, mas com periodicidade semanal, pelos testes de *Augmented Dickey-Fuller* – ADF (1981), *Phillips-Perron* – PP (1988) e Kwiatkowski-Phillips-Schmidt-Shin – KPSS (1992), aplicação do modelo *Vector Autoregression* – VAR (SIMS, 1980), do teste de causalidade de Granger (1986), dos modelos *AutoRegressive Integrated Moving Average* – ARIMA(p,d,q) (MORETTIN; TOLOI, 2004) e extensões e dos modelo *AutoRegressive Moving Average with eXogenous inputs* – ARMAX (FRANSES, 1991), efetuados no *software* RStudio.

O **Artigo 5** utilizou como base modelos encontrados no Artigo 4 para a inserção da variável qualitativa como exógena. A variável exógena selecionada foi a de focos de queimadas, que foram coletados no site do Instituto Nacional de Pesquisas Espaciais – INPE (“BDQueimadas - Programa Queimadas - INPE”, [s.d.]). Para utilizá-las como variáveis qualitativas foram coletadas as séries referentes aos países em que estão localizadas as bolsas de valores. O critério de seleção foi o somatório de todos os focos acontecidos no país de referência durante a semana e registrado em todos os satélites. Essa frequência de focos ocorridos foi dividida em quartis e, para a transformação em

dummy do tipo “0” ou “1”, foram identificadas como “1” as quantidades de focos posicionadas acima do terceiro quartil.

No artigo 5 não foram efetuados os modelos para as séries dos índices STI - FTSE Straits Times Singapore de Singapura e TA35.TA - TA-35Tel Aviv de Israel, em função da indisponibilidade das respectivas variáveis qualitativas, visto que, apesar de constarem no site do INPE, ambas séries estão com valor zero para todos os períodos. Após a aplicação da variável qualitativa em cada modelo foram efetuados os Gráficos de Controle da Soma Cumulativa – CUSUM modificado nos resíduos para a análise e comparação dos modelos.

Neste Artigo o intuito foi completar a fase de Proposição do artefato e demais etapas da metodologia *Design Science Research*. Os artigos 4 e 5 ainda estão em fase de submissão junto às revistas científicas.

3 ARTIGO 1 - SÉRIES TEMPORAIS E VARIÁVEIS QUALITATIVAS: REVISÃO SISTEMÁTICA DE LITERATURA



SÉRIES TEMPORAIS E VARIÁVEIS QUALITATIVAS: REVISÃO SISTEMÁTICA DE LITERATURA¹²

TIME SERIES AND QUALITATIVE VARIABLES: SYSTEMATIC LITERATURE REVIEW

Viviane de Senna* E-mail: vivianedsenna@hotmail.com

Adriano Mendonça Souza* E-mail: amsouza.sm@gmail.com

Renan Mitsuo Ueda* E-mail: renan.mitsuo@hotmail.com

Universidade Federal de Santa Maria (UFSM), Santa Maria, Rio Grande do Sul (RS), Brasil.

Resumo: As variáveis qualitativas possuem características de influenciar variáveis quantitativas. As séries temporais são exemplo de variáveis quantitativas que podem ser modificadas por alterações abruptas de variáveis qualitativas. O objetivo desta pesquisa é identificar uma lacuna de conhecimento entre modelos de previsão de séries temporais e variáveis qualitativas por meio de uma revisão sistemática de literatura aplicada em artigos científicos publicados em bases internacionais. Foram encontrados 37 artigos que unem séries temporais e variáveis qualitativas no período de 1985 a 2020, nos quais novos modelos foram criados utilizaram as variáveis qualitativas como entradas de informação para a geração de previsões. A lacuna encontrada foi em aproximados 57% dos casos a capacidade de melhoria dos modelos criados e a aplicação em outros sistemas, e em 19% a possibilidade de melhorar a previsão de outras variáveis do sistema. Os resultados indicaram que a inclusão de variáveis qualitativas em modelos quantitativos auxilia na qualidade da precisão das previsões geradas.

Palavras-chave: Séries Temporais. Variáveis Qualitativas. Modelos de Previsão. Revisão Sistemática. Modelagem.

Abstract: Qualitative variables have characteristics of influencing quantitative variables. Time series are an example of quantitative variables that can be modified by abrupt changes in qualitative variables. The objective of this research is to identify a knowledge gap between time series forecasting models and qualitative variables through a systematic review of applied literature in scientific articles published in international databases. We found 37 articles that unite time series and qualitative variables in the period from 1985 to 2020, in which new models were created that used qualitative variables as information inputs for the generation of forecasts. The gap found was in approximately 57% of cases the ability to improve the models created and their application in other systems and in 19% the possibility of improving the prediction of other system variables. The results indicated that the inclusion of qualitative variables in quantitative models helps in the quality of the precision of the generated forecasts.

¹ o texto é inédito, não foi financiado, e é parte integrante de tese de doutorado em andamento.

² Revista Produção Online. Florianópolis, SC, v. 22, n. 1, p. 2349-1369, 2022.

Keywords: Time Series. Qualitative Variables. Forecast Models. Systematic Review. Modeling.

INTRODUÇÃO

Fatos, acontecimentos, eventos, opiniões podem influenciar as pessoas e o mercado econômico, mas a capacidade de interferências que variáveis qualitativas possuem é difícil de mensurar. As variáveis qualitativas ou categóricas descrevem características nominais ou ordinais não quantificáveis. São oriundas de uma pesquisa não estruturada com o objetivo de alcançar um entendimento das razões e motivações subjacentes que resultam em uma compreensão inicial (MALHOTRA, 2006).

Séries temporais são coleções de observações feitas sequencialmente ao longo do tempo aplicadas aos métodos econométricos utilizadas para entender as relações entre variáveis econômicas. As séries podem sofrer influência de fontes distintas, como de variáveis qualitativas. Modelos como alisamento exponencial simples, linear de Brow de Holt-Winters, são automáticos, ou seja, não exigem intervenção para a aplicação. Os modelos não automáticos exigem intervenção para decidir qual o mais adequado para produzir a melhor previsão, como os métodos Box-Jenkins (MORETTIN; TOLOI, 2004). Existem métodos apropriados para modelar séries temporais e pesquisas que visam integrá-los com as variáveis qualitativas.

Para verificar como os estudos colaboram para o desenvolvimento do conhecimento científico sobre séries temporais e variáveis qualitativas a revisão sistemática de literatura é o método adequado. Pela revisão sistemática é possível analisar e sintetizar informações de estudos existentes, gerar novos resultados (THOMÉ; SCAVARDA; SCAVARDA, 2016) e encontrar lacunas a serem desenvolvidas. O problema a ser resolvido é qual o conhecimento gerado que integra variáveis qualitativas e modelos de séries temporais?

A importância de conhecer os estudos que já foram efetuados com relação às modelagens é na identificação de como as variáveis qualitativas foram tratadas nos modelos, os tipos de modelos quantitativos explorados nos procedimentos de união de variáveis e, a partir do conhecimento do que já foi proposto é possível avançar no incremento de modelos precisos, complexos e de fácil aplicabilidade. A identificação de autores que já são considerados referência por suas pesquisas acadêmicas desenvolvidas e citadas potencializa a qualidade de novas pesquisas sobre a

temática, bem como serve de impulsionador para o incremento de novos conhecimentos a partir do que já foi criado e testado.

O objetivo do estudo é identificar uma lacuna de conhecimento entre modelos de previsão de séries temporais e variáveis qualitativas através de uma revisão sistemática de literatura aplicada em artigos científicos publicados em bases internacionais. Identificar como o conhecimento sobre determinada temática evoluiu pode contribuir para o desenvolvimento de pesquisas distintas das já efetuadas. A ciência avança em velocidade rápida acompanhando a tecnologia, por isso se faz necessário seguir essa

evolução para que a pesquisa seja colaborativa, aplicada a realidade e atinja a expectativa condizente com meio vivenciado. O uso de modelos de séries temporais para a geração de previsão de séries econômicas serve de embasamento para a tomada de decisões de gestores em diversas áreas mercadológicas, que são influenciadas por variáveis categóricas inesperadas com a capacidade de alterar o cenário vigente.

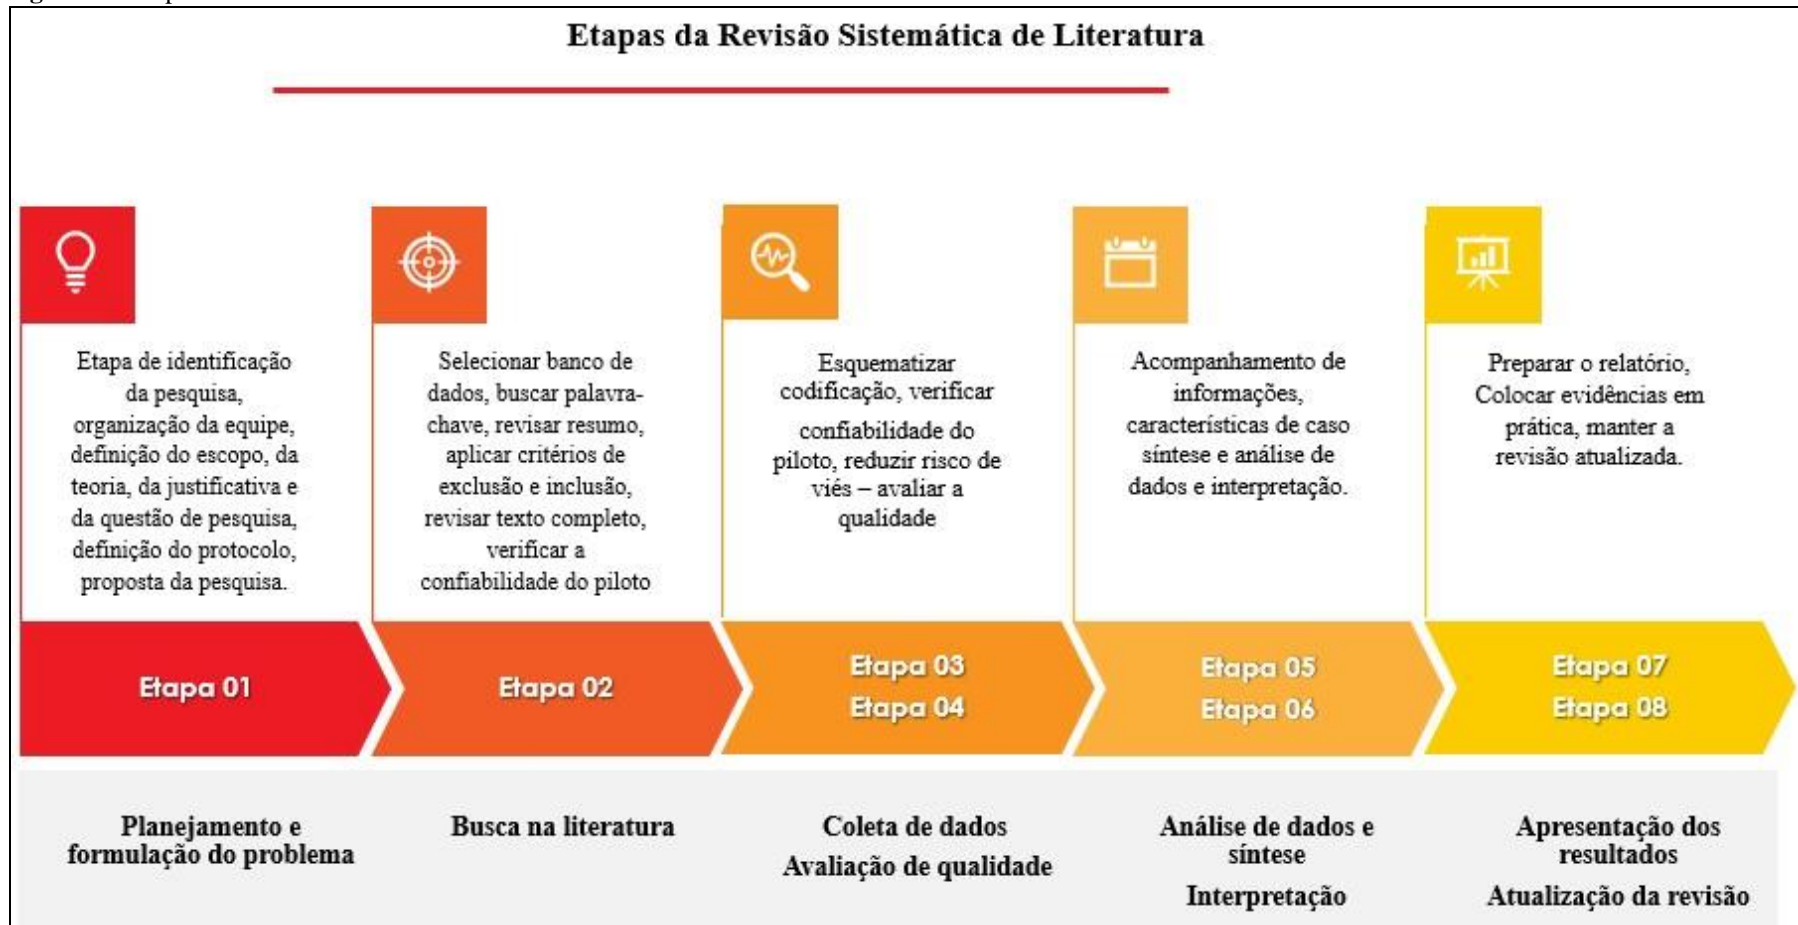
O estudo está estruturado em três tópicos, esta introdução, no tópico 2 a metodologia utilizada, os resultados e as discussões, no tópico 3 as considerações finais e, por fim as referências.

2. METODOLOGIA

A revisão sistemática foi baseada no protocolo de Thomé, Scavarda e Scavarda (2016) que foi desenvolvido para efetuar revisões sistemáticas na área de gestão de operações. Foi embasado no protocolo de Cochrane, amplamente utilizado na medicina e na psicologia (COLLABORATION, 2014; HIGGINS; GREEN, 2008).

O protocolo prevê oito etapas que tem por função tentar reduzir os vieses da pesquisa (THOMÉ, SCAVARDA, SCAVARDA, 2016). Na Figura 1 são apresentadas mais informações sobre essas etapas.

Figura 1 – Etapas do método de Revisão Sistemática de Literatura



Fonte: Adaptado de Thomé; Scavarda; Scavarda (2016) .

A Etapa 1 descrita na Figura 1, consta a Introdução anterior à metodologia. A Etapa 2 se refere a seleção do banco de dados fonte da pesquisa, as bases foram definidas pelos critérios rigorosos para a indexação das revistas e por serem internacionais de ampla abrangência. A pesquisa foi realizada na *Scopus – Elsevier* e *Web of Science*, devido a quantidade e diversidade de artigos vinculados e pela compatibilidade da exportação dos resultados com o *software* livre RStudio.

A data da pesquisa foi 21/01/2022, o período de coleta das informações das bases foi aberto. A *String* foi confeccionada com as palavras ("*qualitative variable*" AND "*time series*") OR ("*qualitative variable*" AND *forecast**) OR ("*qualitative variable*" AND "*Box*Jenkins*") OR ("*qualitative variable*" AND ARIMA). A *String* busca as palavras nos títulos, palavras-chave e resumos dos artigos. Como critério de inclusão, foram selecionados artigos científicos revisados por pares, excluídos os livros e relatórios e periodicidade livre.

Efetuada a coleta, conforme a Etapa 3, para a análise utilizou-se o *software* RStudio o pacote Bibliometrix (ARIA; CUCCURULLO, 2017). A Etapa 4 inicia com a leitura inicial do título e resumo, os artigos mantidos relacionam de alguma forma as séries temporais e variáveis qualitativas, foram excluídos os duplicados na coleta. Após a leitura dos artigos foram coletados o objetivo do trabalho, métodos e modelos utilizados ou propostos e os resultados encontrados. As Etapas 5 a 8 são desenvolvidas a partir dos resultados e discussões.

3 RESULTADOS E DISCUSSÕES


O protocolo (THOMÉ; SCAVARDA; SCAVARDA, 2016) define oito etapas, a Etapa 1 foi atendida durante a definição do escopo do estudo, planejamento do objetivo, problema de pesquisa e metodologia. A segunda Etapa é contemplada no tópico 2 em que são abordados as variáveis qualitativas e os modelos de séries temporais. Na etapa três foi efetuada a seleção dos bancos de dados *Scopus* e *Web of Science*, a coleta e exportação dos resultados da pesquisa da *String*. As bases possuem dois tipos de palavras-chave, as definidas como autor, em que são selecionadas as palavras definidas pelos autores dos artigos e as palavras-chave *Plus* que são definidas pelas bases.

O resultado da coleta identificou 37 artigos na *Scopus* e 6 na *Web of Science*, que já estavam contidos no resultado da *Scopus*. Os 37 artigos foram escritos por 104 autores, 11 possuíam um único autor responsável pela publicação e 93 publicaram em conjunto, com média de 2,8 autores por artigo. As palavras-chave dos autores somaram 188 e as Palavras-chave *Plus* somam 345. Foram identificadas 1.353 referências distintas que serviram de base para teórica para os estudos. O primeiro registro data de 1985 e os últimos foram 2020.

A etapa 4 inicia com a análise das publicações por países descrita na Figura

2.

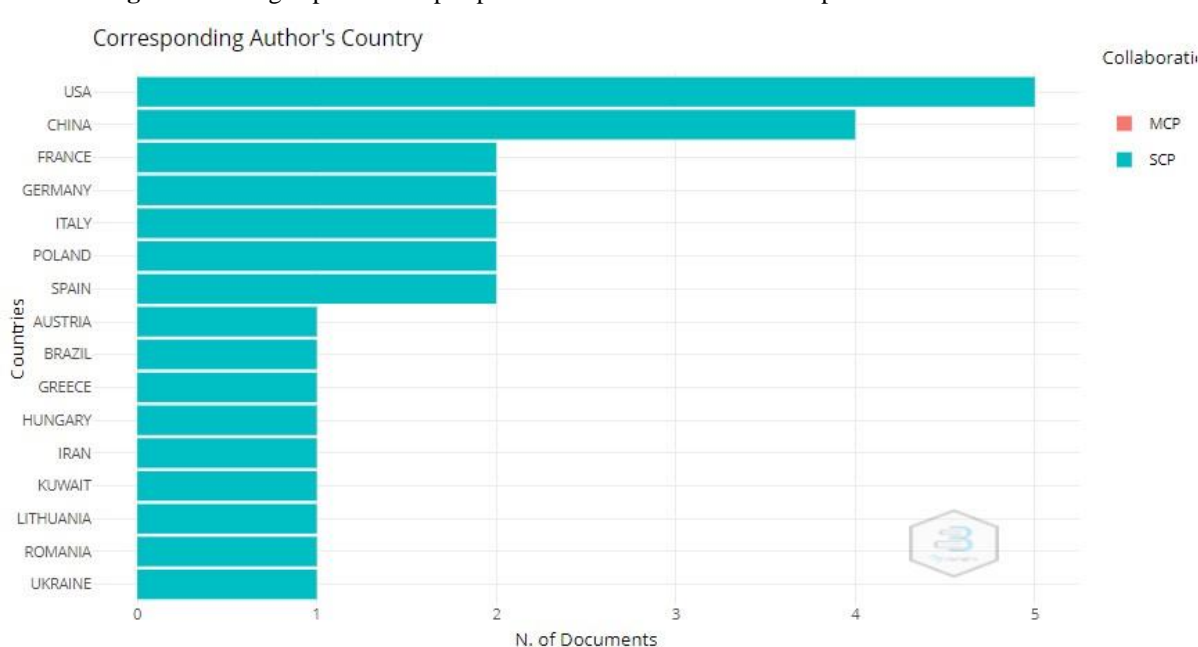
Figura 2 – Artigos publicados por ano de 1985 a 2020



Fonte: Autores (2022).

A Figura 2 indica que em 2016 foram publicados 5 artigos e em 2020 foram 4, os dois anos com maior produção. Foram indicadas publicações durante o período de 35 anos, entretanto mais de 50% delas foram divulgadas nos últimos 8 anos, ou seja, de 2012 a 2020. Entre os anos de 1991 à 1995 e 1999 à 2002 não foram feitas publicações de artigos nos periódicos indexados nas bases pesquisadas. A Figura 3 indica os países de origem dos autores correspondentes.

Figura 3 – Artigos publicados por país considerando o autor correspondente de 1985 a 2020




Fonte: Autores (2022).

SCP: Single Country Publications, MCP: Multiple Country Publication.


A Figura 3 apresenta a nacionalidade dos autores, a legenda identifica que os artigos representados em azul foram produzidos por autores do mesmo país, e em vermelho os autores pertencem a países diferentes (SCP: *Single Country Publications* e MCP: *Multiple Country Publications*). Os dois países com maior produtividade são a China e os Estados Unidos e as pesquisas são desenvolvidas por autores da mesma nacionalidade. Não foram encontradas pesquisas desenvolvidas por autores de múltiplas nacionalidades, o que indica a inexistência de contribuição de grupos de pesquisas entre os países, para os artigos coletados sobre esta temática. O Brasil foi representado por um artigo publicado.

A organização das palavras-chave Plus mais frequentes em grupos por correspondência múltipla está disposta na Figura 4, na qual é possível identificar a estrutura conceitual dos termos.

Figura 4 – Dendrograma de palavras-chave Plus dos artigos sobre a temática da pesquisa de 1985 a 2020

Fonte: Auto res (202 2).

Na Figura 4 o dendrograma divide as palavras-chave *Plus* em dois agrupamentos. O agrupamento azul é denominado “*mortality*”, os termos “*female*”, “*male*” e “*mortality*” são os que possuem ligação mais forte. Em vermelho o agrupamento “*models*” é composto por termos relacionado a modelos, as duas palavras com ligação mais forte são “*prediction*” e “*quantitative variables*”. As relações mais fortes indicam pesquisas focadas em modelos de previsão, com precisão e a inserção de variáveis qualitativas, pois os termos que estão relacionados com ligações mais próximas são, na maioria sinônimos. A densidade e centralidade das palavras são apresentadas na Figura 5.

Figura 5 – Mapa Temático de palavras-chave Plus referente aos artigos coletados

Fonte: Autores (2022).

Na Figura 5 os temas motores estão posicionados no quadrante direito superior, possuem alta densidade e forte centralidade. Destacam-se os termos

“*qualitative analysis*”, “*quantitative factors*” e “*prediction*” que concordam com o *String* da pesquisa. Esse quadrante é indicativo de temáticas com alto potencial de desenvolvimento, objetos de pesquisas atuais. Os temas de importância marginal estão no quadrante superior esquerdo, são muito especializados, mas com caráter periférico, as palavras nesse quadrante são “*comparative study*”. Esse quadrante indica temas importantes, mas com enfoque secundário se comparados com o primeiro quadrante.

Os temas emergentes ou desaparecidos são localizados no quadrante inferior esquerdo, compostos por temas de baixa densidade e baixa centralidade. Neste quadrante não constam os termos para os resultados desse estudo. Os temas incluídos nesse quadrante, em geral, são os que já foram explorados e estão em queda com relação ao conjunto de artigos selecionados. Os temas transversais e gerais, importantes, mas não desenvolvidos estão no quadrante inferior direito. Neste constam os temas como “*priority journal*” e “*probability*”. Este pode ser um indicativo da necessidade de desenvolvimento e publicação de mais estudos de modelos probabilísticos que unam as análises qualitativas e quantitativas, ou seja, os temas motores.

Posicionados sobre o eixo que divide os quadrantes inferiores estão os termos “*forecasting*”, “*data mining*” e “*calibration*”. Os temas identificados apontam para o uso de modelos quantitativos de previsão e análises qualitativas que auxiliem na tomada de decisão. Esse eixo é considerado indicador de centralidade, ou seja, isso indica que esses termos são necessários para a compreensão do cenário pesquisado. O posicionamento dos temas nos quadrantes primeiro e quarto indicam a potencialidade do desenvolvimento de pesquisas na área. Apesar de modelos apenas quantitativos bastante precisos sempre há capacidade de melhoria se observadas as mudanças que variáveis categóricas possuem de interferência nos sistemas.

A *String* da pesquisa tem como foco da pesquisa os artigos que unem variáveis qualitativas e modelos de previsão quantitativos. Os resultados indicaram a aplicação dessas palavras como ferramentas para a geração de resultados em outras áreas de conhecimento. Pela análise conjunta das Figuras 4 e 5 é possível inferir que há potencial para o desenvolvimento de

modelos de previsão com a inclusão de variáveis/fatores qualitativos que auxiliem na geração de previsões mais precisas que sirvam de apoio à tomada de decisão.

Para ampliar a compreensão sobre os estudos foi efetuada a verificação dos estudos por ordem de relevância. A quantidade de citações em cada artigo pesquisado está especificada na Tabela 1, que apresenta os periódicos, o ano e DOI.

Tabela 1 – Os artigos e periódicos por relevância

(continua)

Primeiro Autor	Ano	Periódico	DOI	Total de citações
Alfaro E	2008	Decis Support Syst	10.1016/j.dss.2007.12.002	180
Harvey AC	1989	J Bus Econ Stat	10.1080/07350015.1989.10509750	149
Brauers WKM	2011	Technol Econ Develop Econ	10.3846/20294913.2011.580566	86
Dueker M	2005	J Bus Econ Stat	10.1198/073500104000000613	69
Hassler U	2003	J R Stat Soc Ser D Stat	10.1111/1467-9884.00365	34
Figini S	2011	J Oper Res Soc	10.1057/jors.2010.41	32
Kuo RJ	2016	J Intell Manuf	10.1007/s10845-014-0944-1	31
Cao S	2017	Sci Total Environ	10.1016/j.scitotenv.2016.10.088	25
Helbok R	2005	Am J Trop Med Hyg	10.4269/ajtmh.2005.72.150	23
Christensen R	1986	Int J Gen Syst	10.1080/03081078608934938	18
Billio M	1998	J Stat Plann Inference	10.1016/S0378-3758(97)00136-5	15
Niedbala G	2019	Appl Sci	10.3390/app9142773	15
Séverin E	2010	Neurocomputing	10.1016/j.neucom.2009.12.024	13
Spooner J	1990	Acad Med	10.1097/00001888-199003000-00011	12
Pecican ES	2010	Rom J Econ Forecast	NA	10
Anagnostis A	2020	Sustainability	10.3390/SU12166409	8
Ramírez MD	1998	North Am J Econ Financ	10.1016/S1062-9408(99)80080-1	7
Jurasz J	2016	Prz Elektrotech	10.15199/48.2016.04.32	7
Annarelli A	2018	J Clean Prod	10.1016/j.jclepro.2018.07.220	6
Costa NR	2016	Cienc Saude Coletiva	10.1590/1413-812320152110.18292016	6
Ramirez MD	1996	Atl Econ J	10.1007/BF02298433	6
Sattari MT	2020	Environ Monit Assess	10.1007/s10661-020-08577-8	6
Qu S	2017	Int J Environ Res Public Health	10.3390/ijerph14111276	5
Elwakil E	2014	Can J Civ Eng	10.1139/cjce-2014-0153	5
Kokodey TA	2012	J Int Food Agribus Mark	10.1080/08974438.2012.691815	3
M'hallah R	2019	Appl Soft Comput J	10.1016/j.asoc.2018.10.009	3
Jakubowski J	2014	Arch Min Sci	10.2478/amsc-2014-0049	2
Wang XZ	2012	Transp Porous Media	10.1007/s11242-012-0037-6	2
Farhadi R	2020	Int J Food Eng	10.1515/ijfe-2019-0110	2
Victory W	2016	Intern J Eng Technol	10.21817/ijet/2016/v8i5/160805233	1
Dohnal M	2015	Int J Bifurcation Chaos	10.1142/S0218127415501734	1
Pérez-Rodríguez JV	2011	Quant Financ	10.1080/14697681003685555	1
Varga T	2008	Comput Aided Chem Eng	10.1016/S1570-7946(08)80179-4	1
Herrmann R	1989	J Agric Econ	10.1111/j.1477-9552.1989.tb01095.x	1
Alberti TS	2020	Pesqui Vet Bras	10.1590/1678-5150-PVB-6406	0
Boada A	2016	Opcion	NA	0
Borgegard LE	1985	Espace-Populations Societes	10.3406/espos.1985.996	0
Total				785

Fonte: Autores (2022).

Os artigos apresentados na Tabela 1 estão identificados pelo sobrenome do primeiro autor. Destacam-se os dois primeiros artigos que, pelo número de citações são considerados os mais relevantes pelas bases científicas. O artigo de Alfaro et al.; (2008) foi citado em outros 180 estudos. Os autores criaram o AdaBoost, método alternativo para previsão de falências corporativas que consiste em um algoritmo de aprendizagem de conjunto que constrói classificadores de base usando diferentes conjuntos de dados. O método foi comparado a redes neurais artificiais e aplicado em um conjunto de empresas europeias, em variáveis de previsão, como índices financeiros, e em variáveis qualitativas, como tamanho da empresa, atividade e estrutura jurídica. Os resultados indicaram que a estratégia AdaBoost, que combina árvores únicas atingiu uma redução de 30% no erro de teste em comparação com a rede neural individual, com isso as empresas falidas são diferenciadas das empresas saudáveis.

O segundo artigo mais citado, com 149 citação, foi escrito por Harvey e Fernandes (1989) que desenvolveram um modelo que, com a série em nível, gera observações que mudam ao longo do tempo. O modelo serve para dados de contagem e pode incluir variáveis planificatórias, as inclinações não estocásticas, os componentes sazonais, as análises de intervenção, as variáveis explicativas, as variáveis qualitativas, baseadas em distribuição binomial ou multinomial. A seleção do modelo segue os moldes de modelos utilizados para séries temporais estruturais gaussianas. Os testes foram feitos nos resultados dos jogos internacionais de futebol disputados entre a Inglaterra e a Escócia e uma avaliação do efeito da lei britânica do cinto de segurança nos condutores de veículos de mercadorias.

O artigo mais antigo é datado em 1985 (Borgegard Haggstrom, 1985) que descreve um modelo de micro simulação por Holm e Oberg de migração relacionada à ligação entre os níveis micro e macro. A ênfase foi descrever o modelo de migração entre a Finlândia e a Suécia desde a Segunda Guerra Mundial. O objetivo do modelo é tentar integrar variáveis quantitativas e qualitativas. Um ponto forte é que inclui mudanças sociais e não se limita a uma perspectiva de curto prazo. A desvantagem é a natureza geral do modelo e a impossibilidade de usá-lo para fins de previsão, esta pode ser a razão pela baixa relevância do estudo, em comparação com os demais.

Para identificar os métodos aplicados nos estudos foi desenvolvida a Tabela 2.

Tabela 2 – Principais resultados obtidos pela aplicação de variáveis qualitativas em modelos quantitativos de séries temporais

Modelo utilizado	Nº artigos que usaram o modelo		Autores
Criação de modelo	16	43,24%	(Dueker, 2005) (Figini Giudici, 2011) (Helbok et al.; 2005) (Billio Monfort, 1998) (Pecican, 2010) (Ramírez, 1998) (Costa et al.; 2016) (Qu Zhou, 2017) (Ramirez, 1996) (Hallah Aboukhamseen, 2019) (Sattari et al.; 2020) (Farhadi et al.; 2020) (Victory Ali Ahmed, 2016) (Varga et al.; 2008) (Herrmann, 1989) (Boada, 2016)
Rede neural	8	21,62%	(Alfaro et al.; 2008) (Kuo et al.; 2016) (Séverin, 2010) (Niedbała et al.; 2019) (Jurasz Mikulik, 2016) (Anagnostis et al.; 2020) (Jakubowski Tajduś, 2014) (Pérez-Rodríguez, 2011)
Modelo Fuzzy	4	10,81%	(Brauers et al.; 2011) (Christensen, 1986) (Elwakil Zayed, 2015) (Dohnal Doubravsky, 2015)
Análise de regressão	3	8,11%	(Cao et al.; 2017) (Kokodey, 2012) (Wang et al.; 2012)
Análise de correlação	2	5,41%	(Annarelli et al.; 2018) (Hassler Thadewald, 2003)
Revisão de literatura	2	5,41%	(Spooner, 1990) (Borgegard Haggstrom, 1985)
Análises qualitativas e quantitativas separadas	1	2,70%	(Alberti et al.; 2020)
Variável qualitativa como série exógena	1	2,70%	(Harvey Fernandes, 1989)
Total Geral	37	100,00%	

Fonte: Autores (2022).

De acordo com os resultados indicados pela Tabela 2, em 43,24%, ou seja, 16 dos estudos os autores desenvolveram novos modelos para incluir variáveis qualitativas em quantitativos. Dois estudos utilizaram as qualitativas de forma binária, para estimar um modelo de crescimento linear derivado de uma função de produção neoclássica modificada que incorpora um número de variáveis *dummy* quantitativas e qualitativas relevantes. As variáveis qualitativas foram aumentos nos gastos de investimento público e privado e movimentos positivos nos termos de troca (Ramirez, 1996), e aumentos nos gastos com investimentos nos setores público e privado (Ramírez, 1998).

Nos 14 artigos as variáveis qualitativas foram representadas por números definidos pelos autores tomando por base a expertise obtida pelo estudo das temáticas. Os números têm a função de indicar os pesos que cada variável possui em função da capacidade de influenciar no sistema de variáveis qualitativas definidas nos estudos. O destaque é análise subjetiva aplicada que pode ser contestada ou receber avaliação distinta daquela dada pelos autores se for submetida a outro especialista.

Destaca-se o modelo Qual VAR (Dueker, 2005) permite incorporar informações qualitativas ou discretas em autorregressões vetoriais, foi usado para prever recessão de negócios em 2001. O modelo permite a inclusão de variável qualitativa que pode melhorar a qualidade de previsões de densidade das demais variáveis do sistema.

Outro metodologia relevante é a fusão de dados em modelos longitudinais e de duração de sobrevivência usando variáveis quantitativas e qualitativas separadamente na função de verossimilhança e combinaram as pontuações linearmente por um peso, para obter a probabilidade de inadimplência correspondente para Pequenas e Médias Empresas (Figini Giudici, 2011).

Para quantificar a relação entre variáveis foi utilizada a correlação de Spearman, o teste U de Mann-Whitney foi usado para comparar o *multi-organ dysfunction score* – MODS, score de disfunção de múltiplos órgãos de pacientes com malária *P. falciparum* grave da população do estudo (Helbok et al.; 2005). A pontuação encontrada pode fornecer um valor preditivo para a morbidade na malária *P. falciparum*.

O modelo geral de comutação de espaço de estados, uma combinação do filtro de Kalman parcial e de técnicas de amostragem para calcular a função de verossimilhança e métodos de redução de variância com base em abordagens sequencialmente ideais (Billio Monfort, 1998). As abordagens são computacionalmente mais simples se a série for uma variável qualitativa, leva apenas um número finito de valores.

Para prever a evolução dos principais preços (preço ao consumidor, taxa de câmbio, salários, taxa de juros), foram elaboradas variantes do modelo VAR e foi mantida uma, modelo VAR aberto, que inclui um número limitado de variáveis exógenas que expressam abordagens como teoria econômica e o papel da política econômica (Pecican, 2010). As previsões de curto prazo são mais adequadas e recomenda-se a atualização constante.

Foram utilizadas redes neurais em 21,62% dos estudos, dentre os mais relevantes tem-se a rede neural difusa, utilizada para capturar o conhecimento sobre fatores qualitativos, foi combinada a série temporal por uma rede neural de retropropagação baseada no sistema imunológico artificial (Kuo et al.; 2016). A aplicação de redes neurais com topologia MLP (*perceptron* multicamadas) originou três modelos multicritério para a previsão e simulação da produtividade do trigo de inverno, com base em variáveis quantitativas e qualitativas que podem ser usados na agricultura de grandes áreas e servir de sistema de apoio à tomada de decisão

(Niedbala et al.; 2019).

O algoritmo de Kohonen aplicado em redes neurais com variáveis qualitativas que permitem questionar os modelos de pontuação permitiu uma melhor percepção dos fatores capazes de explicar o financiamento de leasing (Séverin, 2010). Anagnostis et al. (2020) exploram três tipos de abordagens de rede neural, a artificial *perceptron* simples, a de memória de longo prazo e a rede neural profunda proposta com a inclusão das variáveis qualitativas que regem o comportamento humano. Os resultados indicaram que terceira rede supera as demais.

Modelos Fuzzy compuseram a base de 10,81% do resultado. A teoria fuzzy foi usada para o método MULTIMOORA (*Multiplicative and Multi-Objective Ratio Analysis*), que consiste em três partes, Sistema de Razões, Ponto de Referência e Forma Multiplicativa Completa. As partes são sintetizadas em três conjuntos de classificação, mas permaneceu o problema de resumir os resultados com matrizes de resposta grandes (Brauers et al.; 2011). Christensen (1986) verificou as aplicações da entropia minimax abrangem padrões discretos em espaços multidimensionais de variáveis quantitativas e qualitativas mistas e padrões contínuos que empregam conceitos de funções potenciais e entropias fuzzy.

Entre os estudos que utilizaram análise de regressão destaca-se a aplicação de modelos de interpolação espacial, incluindo krigagem ordinária e krigagem de regressão com variável auxiliar para medir a melhoria na precisão do mapeamento da distribuição espacial do cádmio em solos usando métodos geoestatísticos combinados com fatores auxiliares, especialmente variáveis qualitativas (Cao et al.; 2017). A comparação dos modelos indicou que a introdução de variáveis qualitativas melhorou a precisão da previsão, e enfraqueceu o efeito de fatores quantitativos.

A análise de correlação foi empregada em 5,41% dos estudos. Para examinar se o comportamento de dois grupos heterogêneos é distinto, mesmo que o coeficiente de correlação seja aproximadamente o mesmo. A heterogeneidade dos grupos pode ser interpretada como uma variável qualitativa oculta e os resultados podem ser quantificados a

partir de uma fórmula assintótica para o coeficiente de correlação da amostra combinada (Hassler Thadewald, 2003).

Dos 34 artigos que produziram modelos três usaram as variáveis qualitativas como entradas binárias e trinta e um com valores numéricos atribuídos pelos autores. Em comparação cronológica os modelos fuzzy foram utilizados até 2015, modelos de correlação e regressão até 2018, modelos de redes neurais foram utilizados de 2008 a 2020 e, em destaque, os modelos desenvolvidos pelos autores, baseados em modelos de séries temporais que perpassam pela maior parte do período pesquisado de 1989 a 2020.

Ficam evidenciados na Tabela 2 a aplicação de outros métodos quantitativos que foram combinados com variáveis qualitativas para melhorar a precisão da previsão. Além dos métodos foram verificadas as lacunas de conhecimento geradas após a conclusão dos estudos. Na Tabela 3 estão descritas as lacunas identificadas nos artigos coletados.

Tabela 3 – Principais lacunas identificadas pelos autores dos artigos coletados (continua)

Lacunas identificadas	Nº de artigos	Autores
A metodologia foi proposta para integração de risco que pode ser generalizada para prestadores de serviços financeiros.	2	5,41% (Figini Giudici, 2011) (Boada, 2016)
O modelo aumenta a precisão da e pode ser aplicado para estudar o desenvolvimento de transportadoras intermunicipais	1	2,70% (Victory Ali Ahmed, 2016)
O modelo deve ser aplicado em amostras maiores para sua confirmação.	1	2,70% (Helbok et al.; 2005)
O modelo pode melhorar a qualidade das previsões de outras variáveis do sistema	7	18,92% (Dueker, 2005) (Billio Monfort, 1998) (Sattari et al.; 2020) (Wang et al.; 2012) (Jakubowski Tajduś, 2014) (Farhadi et al.; 2020) (Herrmann, 1989)
O modelo pode ser ampliado e/ou utilizado com outros objetivos	21	56,75% (Alfaro et al.; 2008) (Harvey Fernandes, 1989) (Brauers et al.; 2011) (Hassler Thadewald, 2003) (Kuo et al.; 2016) (Christensen, 1986) (Cao et al.; 2017) (Niedbała et al.; 2019) (Séverin, 2010) (Pecican, 2010) (Anagnostis et al.; 2020) (Jurasz Mikulik, 2016) (Costa et al.; 2016) (Annarelli et al.; 2018) (Elwakil Zayed, 2015) (Qu Zhou, 2017) (Kokodey, 2012) (Hallah Aboukhamseen, 2019) (Varga et al.; 2008) (Pérez-Rodríguez, 2011) (Dohnal Doubra-vsky, 2015)

Tabela 3 – Principais lacunas identificadas pelos autores dos artigos coletados (conclusão)

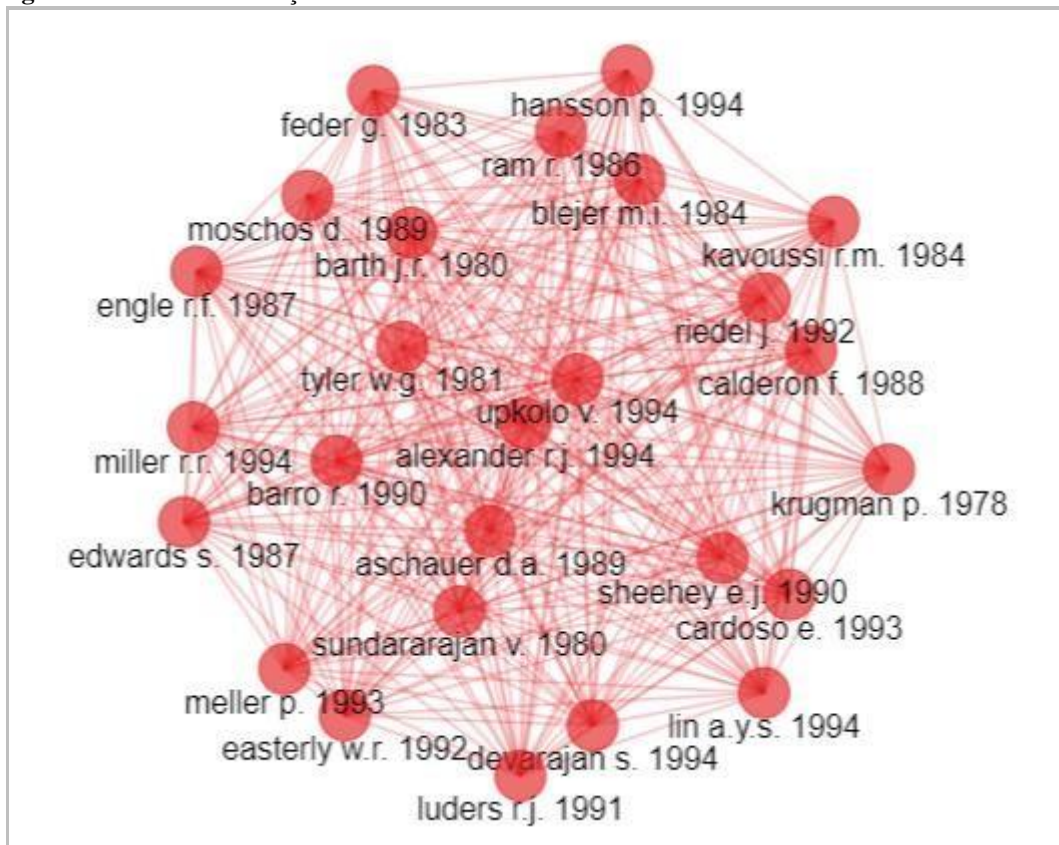
Lacunas identificadas	Nº de artigos		Autores
Os métodos qualitativo e quantitativo foram analisados de forma separada.	1	2,70%	(Alberti et al.; 2020)
Os resultados questionam a tendência entre os países latino-americanos de reduzir os gastos do governo e a futura fonte de renda e crescimento do emprego	2	5,41%	(Ramírez, 1998) (Ramirez, 1996)
Uma revisão de literatura para analisar as descobertas	2	5,41%	(Spooner, 1990) (Borgegard Haggstrom, 1985)
Total Geral	37	100%	

Fonte: Autores (2022).

O resultado que mais se destaca na Tabela 3 é a possibilidade identificada de ampliação do modelo que foi criado pelos autores, bem como a utilização com outros tipos de dados, com 56,75%. Os modelos de séries temporais já consolidados possuem como característica a possibilidade de aplicação em séries de sistemas distintos, baseados em um ciclo iterativo, parcimônia e que apresentem ruído branco nos resíduos (Box et al.; 1994). No entanto, a diferença entre os modelos indicados é a inclusão de variáveis qualitativas, e a ampla possibilidade de aprimoramento para a melhoria da qualidade das previsões geradas.

Outro destaque é a indicação de que o modelo criado pode melhorar a qualidade das previsões de outras variáveis do sistema, com 18,92%. Neste caso, as descrições dos autores variaram entre a alteração de variáveis qualitativas para aprimorar as previsões do sistema e a geração de previsões de outras séries vinculadas ao mesmo sistema estudado. A aplicação do modelo para outros tipos de sistema não foi mencionada, mas sua aplicação não é deve ser descartada sem prévio teste.

Os demais autores indicaram a possibilidade de uso dos modelos criados nas mesmas áreas de conhecimento aos quais foram aplicados com a diferença da adoção de séries de outras localidades geográficas. As referências utilizadas para desenvolver esses artigos estão brevemente apresentados na Figura 7, que contém a rede de co-citações, ou seja, o embasamento teórico utilizado para a geração dos estudos.

Figura 7 – Rede de co-citações

Fonte: Autores (2021).

A Figura 7 representa a relação de citações das 50 referências citadas com maior frequência entre os artigos da pesquisa. A rede indica as ocorrências relacionadas e o tamanho do nó representa a quantidade de citações de cada autor. Neste caso, as 50 referências indicaram uma rede interligada com quantidades semelhantes de citações para cada autor, visto que os círculos possuem tamanhos similares. Essa característica indica a proximidade conceitual e metodológica das pesquisas coletadas pelo estudo devido a identificação dos artigos basilares que dão sustentação aos artigos.

A análise da rede de cocitações possibilita a compreensão dos trabalhos mais influentes e o que já foi estudado sobre a relação entre modelos quantitativos e variáveis qualitativas. De acordo com os resultados extraídos, essas fontes de referência não geraram uma rede de citações direta histórica. Essa rede consiste em um mapa cronológico das citações relevantes resultantes do conjunto bibliográfico em estudo. Os estudos coletados são independentes entre si a nível de referências, um estudo não utiliza o outro como fonte, tampouco para a evolução da temática.

O conhecimento gerado pelos estudos é a união de modelos quantitativos e a inserção de variáveis qualitativas como entrada em formato quantitativo. O valor atribuído para as variáveis qualitativas foi definido de várias formas, como pelo uso da probabilidade e das distribuições, aplicação de ponderações devido a conhecimento prévio dos especialistas ou frequências absoluta ou relativa. Os artigos analisados adaptam e integram variáveis qualitativas aos modelos quantitativos para gerar previsões ou apoiar tomadas de decisões. Na maior parte deles os autores criaram um algoritmo, modelaram equações, nas quais as principais características identificadas nos cenários foram inseridas como uma entrada de informação e influenciaram no resultado, na previsão. Também foram utilizados modelos fuzzy, redes neurais, regressão simples e múltipla, correlação, árvore de decisão entre outros,

para compor novos modelos de previsões. Não foram encontradas avaliações do impacto das variáveis nas séries ao longo do tempo, o que foi considerada uma lacuna no conhecimento possível de ser explorada.

CONSIDERAÇÕES FINAIS

Através da revisão sistemática de literatura pode-se verificar o conhecimento que já foi gerado sobre determinada temática e, a partir disso, pesquisar para sua evolução. O resultado obtido da inserção da *String* nas bases científicas foi de 37 artigos. Da análise desses artigos identificou-se a união de variáveis qualitativas e quantitativas para a criação de modelos gerados a partir de modelos quantitativos adaptados em 33 deles. Nesses casos as variáveis qualitativas receberam ponderações ou alguma forma de transformação para torná-las quantitativas. Foram identificadas as inserções de variáveis qualitativas como variáveis quantificadas por ponderações ou por frequência juntamente com modelos Fuzzy, VAR, regressão, correlação entre outros. Em outros dois casos as variáveis qualitativas foram tratadas como binárias. Os modelos foram aplicados em diversas áreas como economia, saúde, ecologia, energia, comportamento humano, entre outros.

Os modelos quantitativos servem de apoiadores a tomada de decisões e para geração de conhecimento com relação ao comportamento das variáveis em estudo. A integração de variáveis qualitativas e quantitativas auxilia na exploração ampla da complexidade do campo de estudo e incentiva o desenvolvimento da modelagem e do conhecimento como um todo. A importância de estudos como este se dá em função da demonstração da relevância da integração de conhecimentos qualitativos e quantitativos que já foram efetuados e de incentivo ao aprofundamento das pesquisas e engrandecimento das conclusões, pois característica não mensuráveis podem ter tanto impacto quanto às mensuráveis.

A aplicação das variáveis qualitativas foi efetuada de forma quantificada ou como entrada de informação. Não foram encontradas análises da interferência ou influência dessas variáveis para as séries temporais. Nas comparações de aplicação dos modelos com ou sem entradas qualitativas os autores relataram melhoria da precisão das previsões geradas em modelos com qualitativas inclusas.

A lacuna identificada em 56,75% dos estudos foi a capacidade de melhoria dos modelos criados, assim como aplicação de outros sistemas de dados. E em aproximadamente 19% dos estudos os autores identificaram a possibilidade de melhoria da qualidade das previsões de outras variáveis do mesmo sistema. Esses resultados indicam que, mesmo com a alta precisão dos modelos quantitativos previsão, é possível desenvolver modelos de previsão mais precisos através da inclusão de variáveis qualitativas.

O mapa temático resultante das análises indicou como temáticas potenciais as análises qualitativas e quantitativas e erro quadrático médio, que indica a união dos modelos com o foco na redução de erros. Esse resultado indica que há potencial para a criação de modelo que unam essas variáveis em modelos mais precisos para serem usados como apoio a tomada de decisão. O baixo nível de contribuição entre grupos de pesquisa de países diferentes também pode ser destacado, e serve de indicativo de desafios a superar para o avanço colaborativo da temática.

Os resultados encontrados não têm a pretensão de esgotar a temática. A limitação encontrada foi a publicação de artigos em que os modelos obtiveram sucesso nas análises propostas. A não publicação de estudos em que os modelos não sugerem melhorias efetivas anula a possibilidade de verificação de reversão desses resultados, bem como pode gerar viés no estudo e a perda de eficiência na geração do conhecimento científico, pois se resultados negativos forem expostos caminhos dúbios permanecem ocultos e sem desenvolvimento de

discussões e melhorias. Sugere-se para outras pesquisas que o estudo seja aplicado para outras bases científicas, que podem acrescentar informações relevantes aos resultados encontrados.

REFERÊNCIAS

ALBERTI, T. S.; BRUHN, F. R. P.; ZAMBONI, R.; VENANCIO, F. R.; SCHEID, H. V.; RAFFI, M. B.; SCHILD, A. L.; SALLIS, E. S. V. (2020). Epidemiological analysis of bovine tuberculosis in the southern region of Rio Grande do Sul from 2000 to 2015. **Pesquisa Veterinária Brasileira**, v. 40, n. 2, p. 77–81. DOI <https://doi.org/10.1590/1678-5150-PVB-6406>

ALFARO, E.; GARCÍA, N.; GÁMEZ, M.; ELIZONDO, D. Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. **Decision Support Systems**, v. 45, n. 1, p. 110–122, 2008. DOI DOI <https://doi.org/10.1016/j.dss.2007.12.002>

ANAGNOSTIS, A.; PAPAGEORGIOU, E.; BOCHTIS, D. Application of artificial neural networks for natural gas consumption forecasting, **Sustainability** (Switzerland), v. 12, n. 16, p. 6409, 2020. DOI <https://doi.org/10.3390/SU12166409>

ANNARELLI, A.; BATTISTELLA, C.; BORGIANNI, Y.; NONINO, F. Estimating the value of servitization: A non-monetary method based on forecasted competitive advantage. **Journal of Cleaner Production**, 200, p. 74–85, 2018. DOI <https://doi.org/10.1016/j.jclepro.2018.07.220>

BILLIO, M.; MONFORT, A. Switching state-space models Likelihood function, filtering and smoothing. **Journal of Statistical Planning and Inference**, v. 68, n. 1, p. 65–103, 1998. DOI [https://doi.org/10.1016/S0378-3758\(97\)00136-5](https://doi.org/10.1016/S0378-3758(97)00136-5)

BOADA, A. “Sistema Forecast”. **Predicción automatizada en empresas de venta directa**, v. 32, n. 11, p. 121–142, 2016.

BORGEARD, L. E.; HAGGSTROM, N. Migration and social development in a household perspective: an attempt to develop an integrated model of migration. **Espace-Populations-Societes**, v. 1985, n. 1, p. 26–32, 1985. DOI <https://doi.org/10.3406/espos.1985.996>

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 3 ed. 1994. Disponível em: <https://books.google.com.br/books?id=sRzvAAAAMAAJ>

BRAUERS, W. K. M.; BALEŽENTIS, A.; BALEŽENTIS, T. Multimoora for The Eu Member States Updated With Fuzzy Number Theory. **Technological and Economic Development of Economy**, v. 17, n. 2, p. 259–290, 2011. DOI <https://doi.org/10.3846/20294913.2011.580566>

CAO, S.; LU, A.; WANG, J.; HUO, L.; BARCELO, D. Modeling and mapping of cadmium in soils based on qualitative and quantitative auxiliary variables in a cadmium contaminated

area. **Science of the Total Environment**, v. 580, p. 430–439, 2017. DOI <https://doi.org/10.1016/j.scitotenv.2016.10.088>

CHRISTENSEN, R. Entropy minimax multivariate statistical modeling—II: Applications. **International Journal of General Systems**, v. 12, n. 3, p. 227–305, 1986. DOI <https://doi.org/10.1080/03081078608934938>

COSTA, N. DO R.; MARCELINO, M. A.; DUARTE, C. M. R.; UHR, D. Proteção social e pessoa com deficiência no Brasil. **Ciência Saúde Coletiva**, v. 21, n. 10, p. 3037–3047, 2016. DOI <https://doi.org/10.1590/1413-812320152110.18292016>

DOHNAL, M.; DOUBRAVSKY, K. Qualitative upper and lower approximations of complex nonlinear chaotic and nonchaotic models. **International Journal of Bifurcation and Chaos**, v. 25, n. 13, 1550173, 2015. DOI <https://doi.org/10.1142/S0218127415501734>

DUEKER, M. Dynamic Forecasts of Qualitative Variables. **Journal of Business Economic Statistics**, v. 23, n. 1, p. 96–104, 2005. DOI <https://doi.org/10.1198/073500104000000613>

ELWAKIL, E.; ZAYED, T. Construction knowledge discovery system using fuzzy approach. **Canadian Journal of Civil Engineering**, v. 42, n. 1, p. 22–32, 2015. <https://doi.org/10.1139/cjce-2014-0153>

FARHADI, R.; AFKARI-SAYYAH, A. H.; JAMSHIDI, B.; MOUSAPOUR GORJI, A. Prediction of internal compositions change in potato during storage using visible/near-infrared (Vis/NIR) spectroscopy. **International Journal of Food Engineering**, v. 16, n. 4, 2020. DOI <https://doi.org/10.1515/ijfe-2019-0110>

FIGINI, S.; GIUDICI, P. Statistical merging of rating models. **Journal of the Operational Research Society**, v. 62, n. 6, p. 1067–1074, 2011. DOI <https://doi.org/10.1057/jors.2010.41>

HALLAH, R. M.; ABOUKHAMSEEN, S. Cross-calibration of categorical variables: An evaluation of the genetic algorithm approach. **Applied Soft Computing Journal**, 74, p. 154–166, 2019. DOI <https://doi.org/10.1016/j.asoc.2018.10.009>

HARVEY, A. C.; FERNANDES, C. Time Series Models for Count or Qualitative Observations. **Journal of Business Economic Statistics**, v. 7, n. 4, p. 407–417, 1989. DOI <https://doi.org/10.1080/07350015.1989.10509750>

HASSLER, U.; THADEWALD, T. Nonsensical and Biased Correlation Due to Pooling Heterogeneous Samples. **Source: Journal of the Royal Statistical Society. Series D (The Statistician)**, v. 52, n. 3, p. 367–379, 2003. Disponível em: <https://about.jstor.org/terms>

HELBOK, R.; KRUDSOOD, S.; WILAIRATANA, P.; LACKNER, P.; TREEPRASERTSUK, S.; DENT, W.; NACHER, M.; SILACHAMROON, U.;

SCHMUTZHARD, E.; LOOAREESUWAN, S. The use of the Multi-organ-Dysfunction Score to discriminate different levels of severity in severe and complicated Plasmodium falciparum malaria. *The American Journal of Tropical Medicine and Hygiene*, v. 72, n. 2, p. 150–154, 2005. DOI <https://doi.org/10.4269/ajtmh.2005.72.150>

HERRMANN, R. Agricultural Price Protection, Import Dependence and Economic Development: The Case of Wheat. *Journal of Agricultural Economics*, v. 40, n. 2, p. 152–167, 1989. DOI <https://doi.org/10.1111/j.1477-9552.1989.tb01095.x>

JAKUBOWSKI, J.; TAJDUŚ, A. Predictive Regression Models of Monthly Seismic Energy Emissions Induced by Longwall Mining. *Archives of Mining Sciences*, v. 59, n. 3, p. 705–720, 2014. DOI <https://doi.org/10.2478/amsc-2014-0049>

JURASZ, J.; MIKULIK, J. **Day ahead electric power load forecasting** by WT-ANN. *PRZEGLĄD ELEKTROTECHNICZNY*, v. 1, n. 4, p. 154–156, 2016. DOI <https://doi.org/10.15199/48.2016.04.32>

KOKODEY, T. A. A Composite Technique for Modeling and Projecting Food Consumer Behavior. *Journal of International Food Agribusiness Marketing*, v. 4, n. 3, p. 231–249, 2012. DOI <https://doi.org/10.1080/08974438.2012.691815>

KUO, R. J.; TSENG, Y. S.; CHEN, Z.-Y. Integration of fuzzy neural network and artificial immune system-based back-propagation neural network for sales forecasting using qualitative and quantitative data. *Journal of Intelligent Manufacturing*, v. 27, n. 6, p. 1191–1207, 2016. DOI <https://doi.org/10.1007/s10845-014-0944-1>

NIEDBAŁA, G.; NOWAKOWSKI, K.; RUDOWICZ-NAWROCKA, J.; PIEKUTOWSKA, M.; WERES, J.; TOMCZAK, R. J.; TYKSIŃSKI, T.; ÁLVAREZ PINTO, A. Multicriteria Prediction and Simulation of Winter Wheat Yield Using Extended Qualitative and Quantitative Data Based on Artificial Neural Networks. *Applied Sciences*, v. 9, n. 14, 2773, 2019. DOI <https://doi.org/10.3390/app9142773>

PECICAN, E. S. Forecasting Based on Open VAR Model. *Romanian Journal of Economic Forecasting-1*, 1, p. 59–69, 2010.

PÉREZ-RODRÍGUEZ, J. V. Probability of an incoming order signal. *Quantitative Finance*, v. 11, n. 6, p. 901–916, 2011. DOI <https://doi.org/10.1080/14697681003685555>

QU, S.; ZHOU, Y. A Study of The Effect of Demand Uncertainty for Low-Carbon Products Using a Newsvendor Model. *International Journal of Environmental Research and Public Health*, v. 14, n. 11, 1276, 2017. DOI <https://doi.org/10.3390/ijerph14111276>

RAMIREZ, M. D. Public and private Investment in Mexico and Chile: An empirical test of the complementarity hypothesis. *Atlantic Economic Journal*, v. 24, n. 4, p. 301–320, 1996. DOI <https://doi.org/10.1007/BF02298433>

RAMÍREZ, M. D. **Does Public Investment Enhance Labor Productivity Growth in Chile? A Cointegration Analysis**. 1998.

SATTARI, M. T.; MIRABBASI, R.; JARHAN, S.; SHAKER SUREH, F.; AHMAD, S. Trend and abrupt change analysis in water quality of Urmia Lake in comparison with changes in lake water level. **Environmental Monitoring and Assessment**, v. 192, n. 10, p. 1–16, 2020. DOI <https://doi.org/10.1007/s10661-020-08577-8>

SÉVERIN, E. Self organizing maps in corporate finance: Quantitative and qualitative analysis of debt and leasing. **Neurocomputing**, v. 73, n. 10–12, p. 2061–2067, 2010. DOI <https://doi.org/10.1016/j.neucom.2009.12.024>



Artigo recebido em: 10/02/2022 e aceito para publicação em: 30/08/2022

DOI: <https://doi.org/10.14488/1676-1901.v22i1.4575>³

³ O artigo foi importado para este documento conforme foi publicado pela revista.


4 ARTIGO 2 - AS CRIPTOMOEDAS, AS BOLSAS DE VALORES E SUAS RELAÇÕES: REVISÃO SISTEMÁTICA DE LITERATURA

RAE-Revista de Administração de Empresas | FGV EAESP

ARTIGOS

Submetido 24-02-2022. Aprovado 20-01-2023

Avaliado pelo sistema double blind review. Editor Associado *ad hoc*: Eduardo de Rezende Francisco

Parceiristas: Jonatas Dutra Sallaberry , Universidade Federal do Paraná, Departamento de Ciências Contábeis, Curitiba, PR, Brasil. Um dos revisores não autorizou a divulgação de sua identidade e seu relatório de revisão por pares. Relatório de revisão por pares: o relatório de revisão por pares está disponível neste link Versão original | DOI: <http://dx.doi.org/10.1590/S0034-759020230403>

CRIPTOMOEDAS E SISTEMA FINANCEIRO: REVISÃO SISTEMÁTICA DE LITERATURA

Cryptocurrency and financial system: systematic literature review.

Criptomonedas y sistema financiero: revisión sistemática de la literatura

Viviane de Senna¹ | vivianedsenna@hotmail.com | ORCID: 0000-0003-2924-5813

Adriano Mendonça Souza¹ | amsouza.sm@gmail.com | ORCID: 0000-0002-1562-2246

*Corresponding author

¹Universidade Federal de Santa Maria, Programa de Pós-graduação em Engenharia de Produção, Santa Maria, RS, Brasil

RESUMO

As criptomoedas são ativos com transações gerenciadas por novos métodos se comparados a transações tradicionais mediadas pelas bolsas de valores. A inserção desses ativos pode modificar o sistema econômico. O objetivo do estudo é analisar um conjunto de artigos publicados em bases de dados internacionais de conteúdo científico sobre criptomoedas e as relações com as bolsas de valores para compreender a evolução da temática ao longo do tempo. A consulta foi realizada nas bases Scopus e Web of Science. Foram analisados 196 artigos que indicaram como evolução temática algoritmos de aprendizagem, negociação eletrônica, mercado financeiro e digital. Os principais estudos focaram a investigação do comportamento das criptomoedas diante de variáveis mercadológicas, criptomoedas como porto seguro ou diversificação, análise dos preços e do impacto do valor emocional nas criptomoedas. Os artigos mais relevantes, a rede de citações e cocitações possibilitaram o conhecimento dos autores Baur et al., 2018; Ji et al., 2020; Peng et al., 2018; Symitsi & Chalvatzis, 2019; Urquhart, 2017.

Palavras-chave: revisão de literatura, criptomoeda, bolsas de valores, sistema financeiro, moeda virtual.

ABSTRACT

Cryptocurrencies are assets with transactions managed by new methods compared to traditional transactions mediated by Stock Exchanges. The insertion of these assets can change the economic system. The objective of the study is to analyze a set of articles published in international databases of scientific content on cryptocurrencies and the relations with the Stock Exchanges to understand the evolution of the theme over time. The consultation was carried out in the Scopus and Web of Science databases, where 196 articles were analyzed, these indicated learning algorithms, electronic trading, financial and digital markets thematic evolution. The main studies focused on investigating the behavior of cryptocurrencies in the face of market variables, cryptocurrencies as a safe haven or diversification, analysis of prices and the impact of emotional value on cryptocurrencies. The most relevant articles, the citations and co-citations network of these, provided insights into not yet known literature, such authors are Baur et al., 2018; Ji et al., 2020; Peng et al., 2018; Symitsi & Chalvatzis, 2019; Urquhart, 2017.

Keywords: literature review, cryptocurrency, stock exchanges, financial system, virtual currency.

RESUMEN

Las criptomonedas son activos con transacciones gestionadas por nuevos métodos en comparación con las transacciones tradicionales mediadas por bolsas de valores. La inserción de estos activos puede cambiar el sistema económico. El objetivo del estudio es analizar un conjunto de artículos publicados en bases de datos internacionales de contenido científico sobre las criptomonedas y las relaciones con las bolsas de valores para comprender la evolución del tema a lo largo del tiempo. La consulta se realizó en las bases de datos Scopus y Web of Science, donde se analizaron 196 artículos que señalaron como evolución temática algoritmos de aprendizaje, comercio electrónico, mercados financieros y digitales. Los principales estudios se centraron en investigar el comportamiento de las criptomonedas ante las variables del mercado, las criptomonedas como refugio o diversificación, análisis de precios e impacto del valor emocional en las criptomonedas. Los artículos más relevantes, la red de citas y cocitaciones proporcionaron conocer literatura aún no conocida, los autores Baur et al., 2018; Ji et al., 2020; Peng et al., 2018; Symitsi & Chalvatzis, 2019; Urquhart, 2017.

Palabras clave: revisión de la literatura, criptomoneda, bolsas de valores, sistema financiero, monedas virtuales.

INTRODUÇÃO

A revisão sistemática de literatura é um método de pesquisa que pode ser aplicado a vários campos de estudo (Thomé et al., 2016). Pela aplicação dessa metodologia, pode-se analisar as informações existentes sobre determinada temática e gerar novos resultados, bem como encontrar lacunas de conhecimento a serem exploradas.

O conhecimento sobre economia e mercado possui teorias consolidadas e importantes para a compreensão da dinâmica entre as variáveis. No entanto, novas variáveis surgem a todo momento, dados o dinamismo mercadológico e a globalização, e é possível acompanhar as influências na cadeia produtiva e resultados gerados por elas por meio da tecnologia em várias áreas. Com a mesma velocidade do mercado, a ciência evolui, portanto conhecer novas pesquisas, conceitos e interpretações é importante para alavancar o meio acadêmico, o mercado e a sociedade.

No ano de 2009, foi criada a primeira criptomoneda, o Bitcoin, que é um sistema de caixa eletrônico que liga um ponto a outro e permite o envio de pagamentos diretos sem passar por instituições financeiras (Nakamoto, 2008). Por essa definição, criptomoneda é uma moeda alternativa, entretanto é um híbrido de moeda mercadoria e moeda fiduciária, determinado por uma regra determinística automática cumprida pela mineração competitiva semelhante ao dinheiro *commodity*, como o ouro, mas sem valor intrínseco (Baur et al., 2018). Uma criptomoneda pode ser usada como um ativo, o que lhe atribui um propósito diferente, como uma reserva de valor.

As criptomonedas representam para o mercado financeiro novos tipos de ativos e novos métodos de gerenciamento de transações com potencial de substituir a moeda fiduciária tradicional (Liang et al., 2018). Um ativo pode representar ações de empresas ou títulos que pessoas compram ou vendem, denominadas investidores, ou que realizam transações, chamados corretores, com o intuito de obter lucro (Bhandarkar et al., 2019). Milhões de negociações são realizadas nas bolsas de valores, que são altamente informatizadas para serem

capazes de sustentar a grande quantia de negociações em curto espaço de tempo com garantia de segurança pelo método tradicional.

O comportamento mercadológico pode mudar em função de acontecimentos como eleições, (des)organização de grupos econômicos e (des)valorização de moedas fortes ou uma pandemia (Ji et al., 2020). Acompanhar a evolução das variáveis, como criptomoedas, é importante para que seja possível interpretar e antecipar mudanças no mercado, os impactos para o sistema econômico e para a geração de conhecimento na área. Estudar a relação de um novo ativo inserido junto ao mercado tradicional é importante porque pode gerar informação sobre como o mercado se comporta perante novos ativos. Novos tipos de ativos podem surgir a qualquer momento; como eles vão se comportar diante do mercado já consolidado e qual a influência que esse mercado pode sofrer são incógnitas importantes de serem acompanhadas para a evolução das teorias econômicas envolvidas e para melhorar a tomada de decisão por parte de investidores. O problema da pesquisa é: Como evoluíram as pesquisas sobre as criptomoedas e as bolsas de valores no mercado?

O objetivo do estudo é analisar um conjunto de artigos publicados em bases de dados internacionais de conteúdo científico sobre criptomoedas e as relações com as bolsas de valores para compreender a evolução da temática ao longo do tempo. Este estudo está organizado nesta introdução, na metodologia, nos resultados e discussões, nas considerações finais e, por fim, nas referências utilizadas.

METODOLOGIA

Desenvolver uma revisão de literatura consiste em encontrar todos ou o máximo possível de trabalhos publicados sobre determinado assunto. Já uma revisão sistemática de literatura é uma modalidade de pesquisa que visa entender e gerar uma lógica oriunda de um *corpus* documental, de acordo com um contexto, e por meio da utilização de protocolos específicos para a seleção e organização desses documentos (Galvão & Ricarte, 2019). Por esse tipo de revisão, é possível encontrar uma solução para os conflitos de resultados, bem como para a definição das questões importantes que permanecem sem resposta ou que possuam resultados mais confiáveis que embasem as tomadas de decisões práticas (Siddaway et al., 2019).

As interpretações dos resultados podem ser geradas pela aplicação da metanálise, da narrativa e da metassíntese. A metanálise consiste em resumir os parâmetros das variáveis trabalhadas e os efeitos gerados pela aplicação de testes e/ou comparações (Siddaway et al., 2019). A narrativa dos resultados é aplicada para conectar os estudos e dar uma reinterpretação que desenvolva ou avalie uma nova teoria ou para fornecer um relato histórico das pesquisas desenvolvidas sobre o tema (Baumeister & Leary, 1997). Pela metassíntese, os resultados são sintetizados sobre um tópico, conceito ou tema-chave capaz de explicar o fenômeno estudado (Thorne et al., 2004). A aplicação das técnicas tem o objetivo de extração de novas conclusões a partir da interpretação dos estudos já realizados.

Essa revisão sistemática de literatura tem como base o protocolo de Thomé et al. (2016). O protocolo é alicerçado no protocolo Cochrane, amplamente utilizado em áreas como medicina e tecnologia (Higgins & Green, 2008; The Campbell Collaboration, 2014), mas foi adaptado

para desenvolver revisões sistemáticas em gerenciamento de operações. São oito etapas a serem seguidas com o intuito de reduzir vieses na pesquisa e colaborar para a geração de conhecimento.

Etapa 1: planejamento e formulação do problema. Nesta etapa, é efetuado o planejamento da pesquisa, definidos o problema, a justificativa e o protocolo. As bases selecionadas para a pesquisa são a *Scopus* (Elsevier) e a *Web of Science*, devido à ampla quantidade de publicações e à criteriosa seleção de revistas para a indexação que garante a qualidade dos estudos publicados, dada a necessidade da revisão por pares. Essas bases científicas possuem a capacidade de exportação dos resultados das pesquisas, bem como ampla quantidade de informação sobre os periódicos.

Etapa 2: busca na literatura. Significa efetuar a definição das palavras-chave que criarão o *string* da pesquisa e as bases. O *string* para coleta conta com as palavras “*Cryptocurrenc** AND “*Stock Exchanges*” OR “*Crypto-asset* AND “*Stock Exchange*” OR ““*Digital Stocks*” AND “*Stock Exchange*”” OR ““*Digital Currenc**” AND “*Stock Exchange*”” OR ““*Virtual currenc**” AND “*Stock Exchange*”””, que devem aparecer nos títulos, palavras-chave e resumos dos documentos.

Etapa 3: coleta de dados. A coleta é feita de acordo com os critérios de inclusão e exclusão. A coleta foi efetuada no dia 16 de dezembro de 2021, e os critérios de inclusão são artigos científicos, revisados por pares, com periodicidade a partir de 2009, que contenham pesquisas as quais relacionem criptomoedas e bolsas de valores. Os documentos que não são artigos científicos, que tratam de um dos temas apenas, artigos não disponibilizados integralmente ou sem acesso integral dos pesquisadores e os duplicados na coleta são excluídos.

Etapa 4: avaliação de qualidade. São feitos esquemas e análises do conteúdo coletado com o objetivo de reduzir possíveis vieses. Os artigos coletados passam por uma leitura prévia do resumo para verificar se atendem aos critérios de seleção.

Etapa 5: análise de dados e síntese. Os dados são organizados para facilitar a interpretação. Após a seleção os artigos serão analisados com auxílio do *software* livre RStudio, pacote Bibliometrix (<https://www.bibliometrix.org>) (Aria & Cuccurullo, 2017). Esta etapa é baseada em uma abordagem indutiva para a análise das principais informações dos resultados.

Etapa 6: interpretação. Decorre da leitura completa dos documentos selecionados. Serão verificadas a relevância das pesquisas pelas citações e cocitações e a estrutura do campo de pesquisa pela análise copalavra (Cobo et al., 2011), ou seja, é nesta etapa que são aplicadas a metanálise, a narrativa e a metassíntese.

Etapa 7: apresentação dos resultados. Organização de relatório com as evidências encontradas. A partir dessas informações, são desenvolvidas as etapas 6 e 7, interpretação e apresentação dos resultados.

Etapa 8: atualização da revisão. É importante manter a revisão atualizada, pois constantemente são publicados novos artigos com avanços da pesquisa em todas as áreas.

RESULTADOS E DISCUSSÕES


As primeiras etapas da revisão sistemática foram a definição do escopo efetuada no objetivo do estudo e o planejamento do problema na metodologia. Para a investigação na literatura,

foram selecionadas as bases *Scopus* e *Web of Science*, que, após a busca pelas palavras-chave, indicaram respectivamente 131 e 141 artigos revisados por pares; excluindo os 76 repetidos, permaneceram 196, conforme a Etapa 4.

Os 196 artigos selecionados foram publicados em periódicos revisados por pares de 2009 a dezembro de 2021. A quantidade de palavras-chave é de 739 palavras e a de palavras-chave *Plus* é de 924. São consideradas palavras-chave *Plus* aquelas associadas aos artigos pela base científica que podem ser diferentes daquelas definidas pelos autores e que representam o tema geral pesquisado. Foram identificados 564 autores, dos quais 39 foram os únicos autores dos artigos e 525 auxiliaram na autoria múltipla de artigos com, em média, três coautores por artigo.

Os quatro primeiros artigos publicados datam de 2009, mas a maioria das publicações foi feita no ano de 2020, 51 artigos, conforme a Figura 1.

Figura 1. Produção científica anual de 2009 a dezembro de 2021



Fonte: *Software* RStudio.

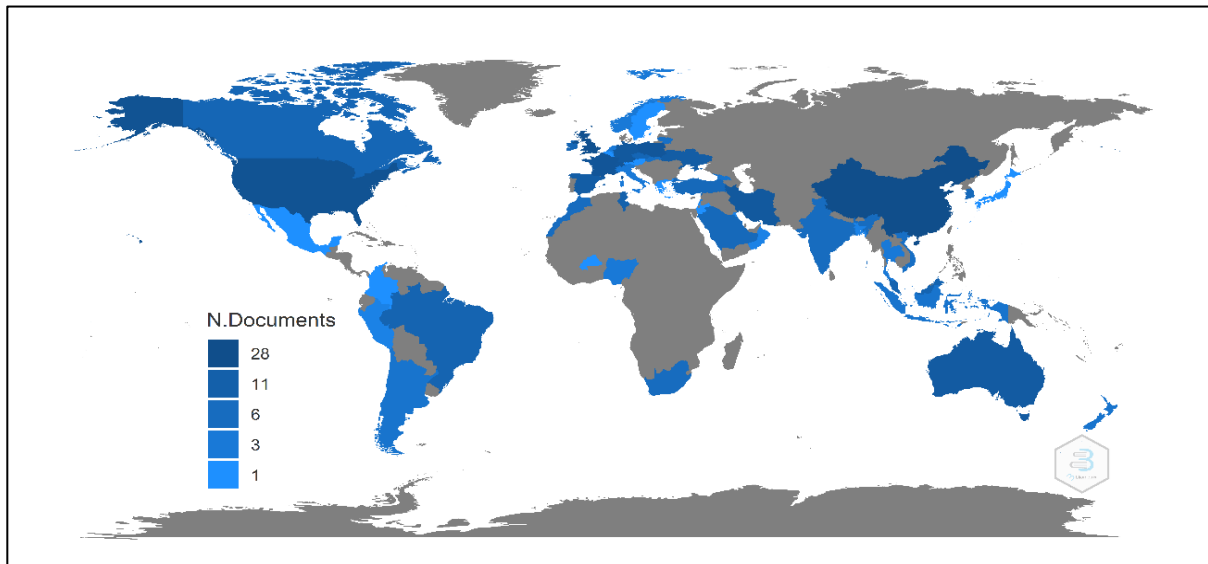
Na Figura 1, destaca-se a quantidade de artigos produzidos sobre a temática nos anos de 2020 e 2021, respectivamente 51 e 49. A definição da periodicidade a partir de 2009 foi efetuada devido à criação das criptomoedas e início de comercialização no mercado.

Os artigos pesquisados foram produzidos em 53 países, identificados na Figura 2.

Figura 2. Produção científica por países de 2009 a dezembro de 2021



Fonte: *Software RStudio*.




Fonte: *Software RStudio*.

Conforme a legenda da Figura 2, quanto mais escuro é o tom de cinza, maior é a quantidade de artigos produzidos. A China apresenta a maior produção, 28 artigos, seguida pelo Reino Unido, com 24, Estados Unidos, com 22 artigos, França, com 19, e Polônia e Suíça possuem 18 produções. No Brasil, foram nove artigos produzidos no período de coleta do estudo.


A temática das pesquisas sofreu modificações com o passar do tempo, a inclusão das criptomoedas e o armazenamento digital acompanham a evolução da sociedade e do mercado. Para identificar a estrutura conceitual do tema, foi aplicada a análise copalavra, que permite descobrir os principais conceitos e as interações entre os diferentes campos de pesquisa científica e descrevê-los (Cobo et al., 2011). Por essa análise, as palavras-chave que identificam os artigos são divididas em subgrupos, por períodos consecutivos. Em cada subgrupo, são verificados os temas, que, detectados ao longo do tempo, indicam a evolução de

um tema “A” para um tema “B” se estes estiverem associados, ou seja, as palavras-chave que constam nos diferentes subgrupos são consideradas um nexos temático ou conceitual. A evolução dos temas pesquisados é representada pela Figura 3, que indica em forma de rede quais os termos mais usados em cada período.

Figura 3. Evolução dos temas de pesquisas realizadas entre 2009 e dezembro de 2021



Fonte: Software RStudio.

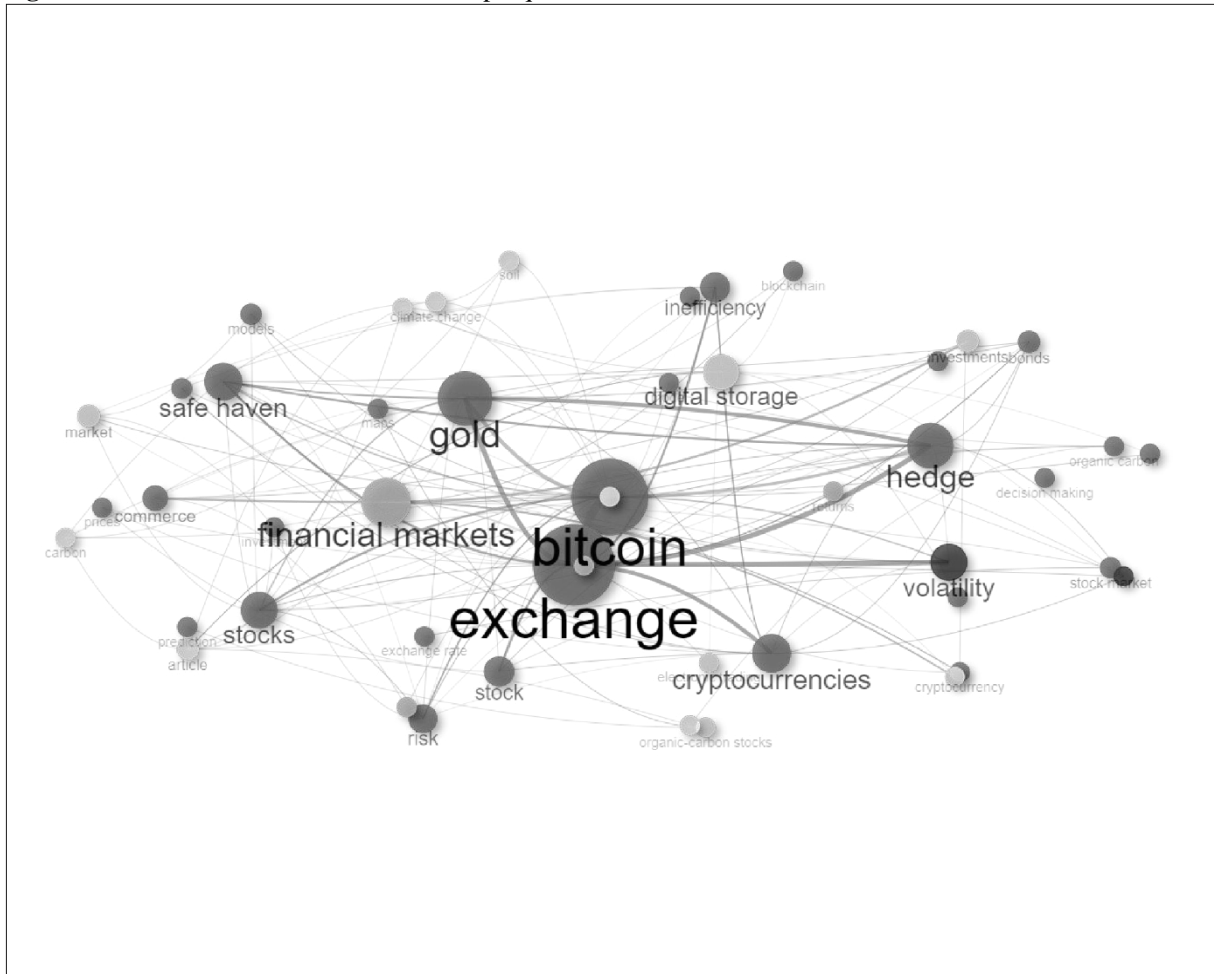


Fonte: Software RStudio.

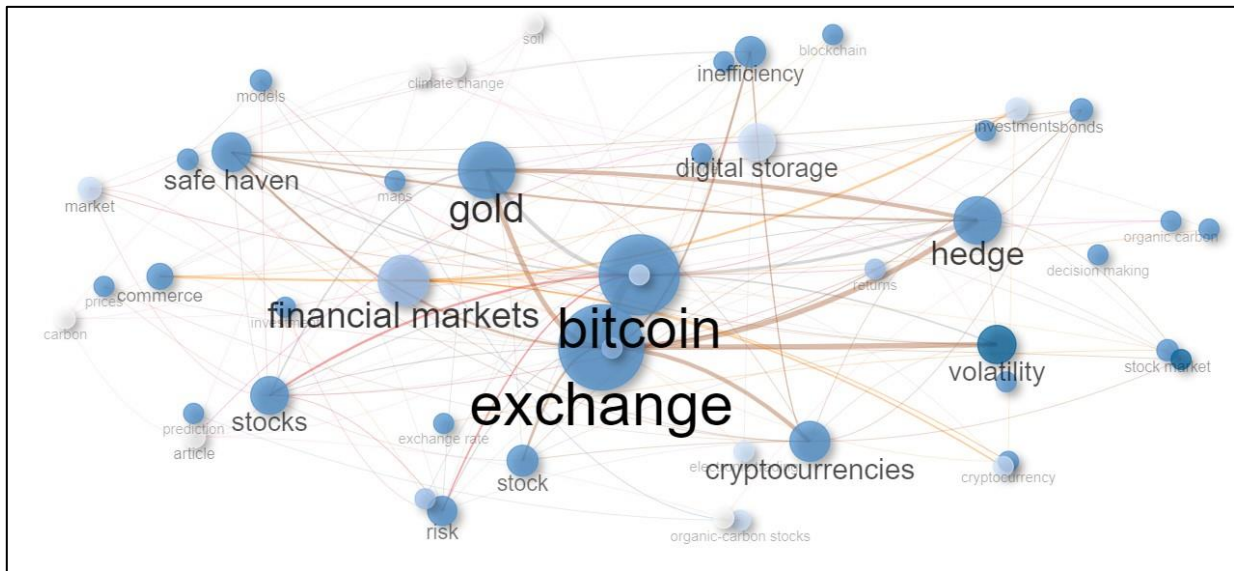
A Figura 3 foi gerada a partir da verificação de cinco mil palavras com frequência mínima de agrupamento de cinco por mil documentos pelo índice de inclusão ponderado por ocorrência de palavras. Foram utilizadas as palavras-chave *Plus*, pois indicaram maior variação temática do que as palavras-chave indicadas pelos autores. Foram testados outros períodos de corte que não indicaram variação das temáticas, por isso a Figura 3 demonstra o corte em 2019, visto que o ano de 2020 caracteriza-se pela maior quantidade de artigos produzidos. O tema mais indicado até 2019 foi o mercado financeiro, que, a partir de 2020, passou a ser dividido em mercado financeiro, criptomoedas, custos, mercado de ações e armazenamento digital. O tema estoque de carbono orgânico evoluiu para as temáticas envolvendo índices, câmbio e previsão. Outro destaque é a diversificação dos temas indicados pelo corte da Figura 3, visto que passaram de cinco para nove principais.

Para expandir a avaliação dos temas, foi desenvolvida a rede de coocorrência, que é desenhada pela palavras-chave e as interconexões. A rede é identificada pela palavra-chave mais importante, central com relação ao tema associado, que é interligada a palavras representadas por esferas proporcionais ao índice de equivalência da palavra central. Na Figura 4, consta a rede de coocorrência deste estudo.

Figura 4. Rede de coocorrência de temas de pesquisas realizadas entre 2009 e dezembro de 2021



Fonte: *Software RStudio.*



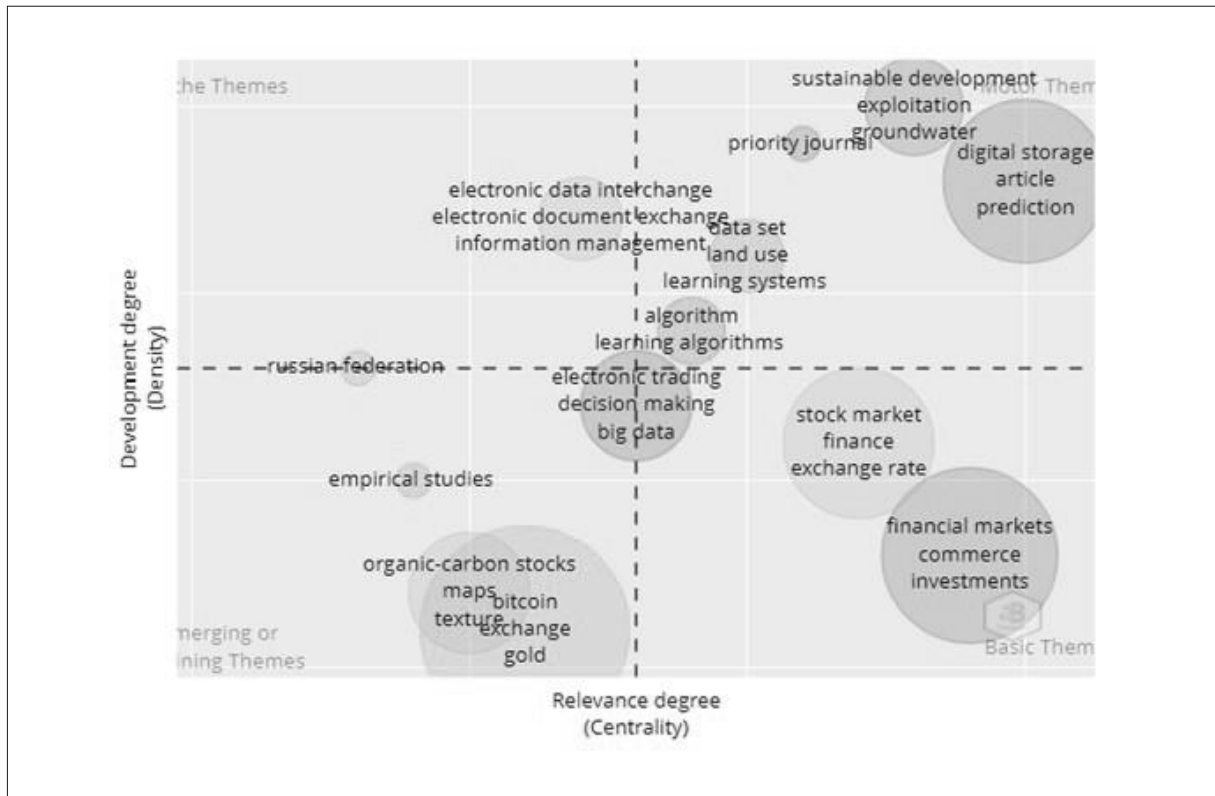
Fonte: *Software RStudio*.

A rede foi configurada pelas palavras-chave Plus, os agrupamentos, ordenados pelos autovalores principais dos 50 nós principais. Foram gerados quatro agrupamentos indicados na Figura 4, as palavras-chave centrais obtidas pela coleta da pesquisa foram “*bitcoin*”, “*exchange*” e “*gold*”, que estão interligadas à rede principal, representada na Figura 4 pela cor mais escura.

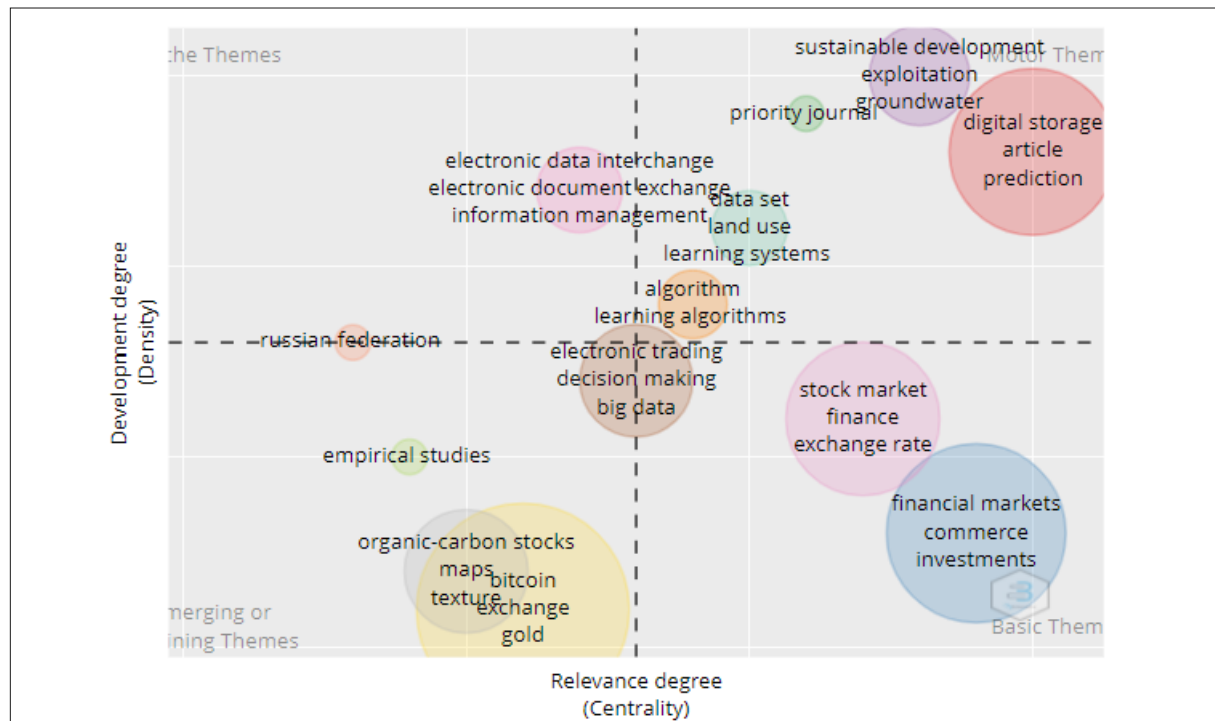
Relacionadas aos termos “*financial markets*”, estão interligadas as palavras que possuem relação com a área econômica, como “*commerce*”, “*investments*”, “*stock market*” e “*cryptocurrency*”. Essa rede é indicada na Figura 4 pela segunda cor mais escura. A rede cinza claro, indicada pelas palavras “*digital storage*”, contém palavras como “*climate change*”, “*organic carbon*”, “*carbon*”, “*soil*” e “*environmental monitoring*”. Essa rede relaciona temáticas ligadas a mudanças climáticas, carbono e monitoramento ambiental. A rede em cinza mais claro tem menores índices de equivalência aos temas centrais do estudo. As palavras-chave apresentadas são “*organic-carbon stocks*”, “*prediction*” e “*maps*”, temáticas que dão suporte para as pesquisas e o funcionamento dos sistemas.

A análise de copalavras, ou seja, a análise dos termos mais frequentes nos artigos, é usada para mapear os grupos temáticos, as interconexões e o grau de aproximação, que são caracterizados pela densidade e centralidade. Os valores médios desses parâmetros podem ser usados para classificar os temas em quatro grupos (Cobo et al., 2011). O mapa temático da Figura 5 é um espaço bidimensional construído de acordo com a centralidade e classificação de densidade dos temas que formam um conjunto de temas de pesquisa.

Figura 5. Mapa temático de temas de pesquisas realizadas entre 2009 e dezembro de 2021



Fonte: *Software RStudio.*



Fonte: *Software RStudio.*

Para a geração da Figura 5, foram selecionadas cinco mil palavras *Plus* citadas nos artigos com frequência mínima de cinco por mil documentos. O quadrante direito superior indica os temas motores, pois apresenta alta densidade e forte centralidade. Os principais temas motores indicados foram “*digital storage*”, “*prediction*”, “*sustainable development*”, “*exploitation*”, “*groundwater*”, “*data set*”, “*land user*” e “*learning systems*”. De acordo com os temas relacionados, pode-se presumir que os estudos em destaque em períodos futuros estarão relacionados à criação ou utilização de sistemas de informação, modelos e algoritmos que possuam a capacidade de prever e auxiliar o desenvolvimento sustentável e a preservação da natureza.

O quadrante superior esquerdo tem importância marginal, os temas que o compõem são muito especializados, mas de caráter periférico, como é o caso dos termos “*eletronic data interchange*”, “*eletronic document Exchange*” e “*information management*”. A gestão da informação e o acesso aos dados são fundamentais para a criação de modelos e algoritmos, pois sem os dados não há a possibilidade do avanço desse tipo de estudo baseado em fenômenos naturais. Entretanto, esses temas são utilizados como base metodológica para o avanço dos temas motores. Apesar das infinitas possibilidades de avanço do conhecimento, já estão disponíveis formas confiáveis e consolidadas de intercâmbio e gestão de dados.

O quadrante inferior esquerdo é composto por temas de baixa densidade e baixa centralidade, por isso os temas são emergentes ou desaparecidos. No caso dos temas que estão nesse quadrante,

“*empirical studies*”, “*organic-carbon stocks*”. “*maps*”, “*bitcoin*”, “*exchange*” e “*gold*” são temas bastante explorados. As temáticas muito exploradas tendem ao esgotamento em função do conhecimento por elas já gerado. Contudo, como estão próximas ao eixo da centralidade, podem ser consideradas emergentes no que tange a acompanhar esta pesquisa. Estudos empíricos são fonte de conhecimento muito disseminada no meio acadêmico, bem como os estudos que envolvem cotações do ouro e do Bitcoin podem ser bastante explorados diante das demais

variáveis do mercado.

O quadrante inferior direito indica temas importantes para a pesquisa, mas que não são desenvolvidos, ou seja, são temas transversais e gerais. Nesse quadrante, constam os temas “*stock market*”, “*finance*”, “*exchange rate*”, “*financial markets*”, “*commerce*”, “*investments*”. Todos os temas possuem envolvimento com a temática principal da pesquisa e são necessários para a compreensão do cenário que os compõe.


Centralizados no mapa temático, estão os termos “*learning algorithms*”, “*eletronic trading*”, “*decision making*” e “*big data*”. Esses termos possuem a capacidade de indicar o avanço de modelos que auxiliem a tomada de decisão e a geração de conhecimento agregadas a todas as temáticas citadas no estudo e adaptáveis a outros temas.

A estrutura conceitual das palavras-chave pode ser identificada pela análise do dendrograma de palavras-chave *Plus*, conforme indica a Figura 6.


Os parâmetros que definem o dendrograma são as 50 palavras-chave *Plus* que representam os artigos resultantes da pesquisa pela frequência de ocorrência delas. A análise gerou dois agrupamentos indicados na Figura 6 pela linha pontilhada que define o corte do dendrograma. O agrupamento superior, indica as palavras com ligação mais forte, ou seja, menor distância entre as palavras e o eixo zero são “*prediction*” e “*texture*”. Esse eixo reúne

temas relacionados a carbono orgânico e tratamento de dados, visto que surgem as palavras “*soil organic matter*” e “*digital storage*”. Os artigos relacionados a essas palavras descrevem formas de interferência do carbono no mercado, que podem ser considerados temas capazes de interferir no objetivo da pesquisa, mas indiretamente.

Figura 6. Dendrograma das palavras-chave Plus dos artigos pesquisados entre 2009 e dezembro de 2021



Fonte: *Software* RStudio.



Fonte: Software RStudio.

O agrupamento inferior contém mais palavras do que o superior e possui relação direta com o objetivo da pesquisa. Esse agrupamento possui clara subdivisão em que, na parte central da Figura 6, constam elementos comuns ao mercado financeiro tradicional; as ligações mais fortes são para as palavras “volatility” e “stock”, “cryptocurrencies” e “inefficiency”, “investment” e “returns”, respectivamente. A união desses termos remete ao mercado de ações tradicional, que é volátil, e que inicialmente considerou os novos ativos como uma promessa ineficiente diante do mercado previamente estabelecido.

Na parte inferior, as características são mais próximas dos novos ativos financeiros, representados pelas criptomoedas. São mais fortes as ligações das palavras “*blockchain*” e “*eletronic trading*”, “*investment*” e “*cryptocurrencies*”, “*stock returns*” e “*model*”. Esses agrupamentos temáticos indicam afinidade entre as tecnologias que envolvem os registros de operações de criptomoedas e as negociações eletrônicas, bem como os investimentos e os retornos das ações relacionados a modelos. O uso de tecnologia de informação e novos modelos faz parte da essência das criptomoedas.

A subdivisão do agrupamento inferior indica que, apesar de ser um único grupo, ou seja, de existir uma ligação entre esses temas, os dois subgrupos possuem características que os diferem. As criptomoedas são uma nova forma de ativos disponíveis, e as bolsas de valores são, tradicionalmente, formadas por ativos tradicionais; o que as relaciona, de acordo com a Figura 6, é que são tipos de ativos presentes no mesmo mercado financeiro.

Analisando as Figuras 3 a 6, tem-se que, na Figura 3, o estudo do tema mercado financeiro, que se destacava até 2019, vem se subdividindo nele mesmo: criptomoedas, custo e previsão. Esses temas fazem parte, principalmente, da segunda rede contida na Figura 4, que possui destaque secundário, e do quarto quadrante da Figura 5, temas importantes, mas não foco do estudo. Para a definição do objeto deste estudo, essas palavras fazem parte do cenário no qual os termos que organizam o *String* estão inseridos, são base para a compreensão do sistema econômico, presentes de várias formas nas pesquisas, mas não são a temática principal. Para compreensão do que são as criptomoedas e as influências que seu surgimento causou para a economia, é necessário o conhecimento prévio do mercado financeiro tradicional.

Os estudos sobre criptomoedas comumente citam o Bitcoin, por ser sido a principiante e estar consolidada no mercado. Na Figura 3, o termo é substituído, a partir de 2019, por “*exchange*”; ambos compõem a rede principal, nas Figuras 4 e 6, e estão situados nos quadrantes inferiores na Figura 5. Entende-se que, por essa composição de resultados, são temas com bastante potencial de exploração de estudos, as interferências que o Bitcoin pode causar junto ao mercado decorrem da sua comercialização e uso como moeda virtual de troca. Apesar de não ser a única criptomoeda existente, pesquisada e com capacidade de modificar o mercado, é a mais comum encontrada nos estudos.

O “*organic carbon stocks*” migra, a partir de 2019, conforme a Figura 3, para termos como taxas e previsão. Esses termos aparecem na rede secundária das Figuras 4 e 6, com menor representatividade entre as demais, e no terceiro quadrante da Figura 5. As reservas de carbono são importantes para temas relacionados a economia e a sustentabilidade global, contido




com menor relevância para o *String* deste estudo, por isso são visualizadas nas posições com menor destaque. A relevância do surgimento desses termos dá-se devido à possibilidade de desenvolvimento de outros estudos que contemplem temáticas de relevância mercadológica juntamente com as criptomoedas.

O tema “*digital storage*” pode ser considerado o meio para a comercialização das criptomoedas. Na Figura 3, há a subdivisão para estudos vinculados às criptomoedas; na Figura


4, surge na rede em roxo, terceira em relevância, mas com termos como “*commerce*” e “*eletronic Money*”, e, nas Figuras 5 e 6, com “*predcition*”. Entretanto, na Figura 5, está no

primeiro quadrante, o que torna a temática com visibilidade e importante para o desenvolvimento de estudos. Sobre armazenamento digital, há um vasto campo a ser explorado, visto que dados são a base para a geração do conhecimento, e como armazená-los de maneira segura é um desafio.

Criptomoeda, pela Figura 3, é um tema que pode ser mais explorado; Bitcoin e Ouro são parte da mesma rede, juntamente com volatilidade e câmbio, Figura 4. Os mesmos termos surgem na Figura 5 no terceiro quadrante, que indica temas bastante explorados. Os temas do primeiro quadrante sugerem estudos com enfoque voltado para armazenamento digital, previsão e desenvolvimento sustentável, servindo de base para o desenvolvimento dos temas centrais, que são algoritmos de aprendizagem, negociação eletrônica e tomada de decisão. Na Figura 7, foi gerada a linha de tendência dos tópicos abordados nos artigos selecionados pelo estudo **Figura 7**. Tendência de tópicos pesquisados pelos estudos coletados de 2009 a dezembro de 2021



Fonte: *Software RStudio*.




Fonte: Software RStudio.

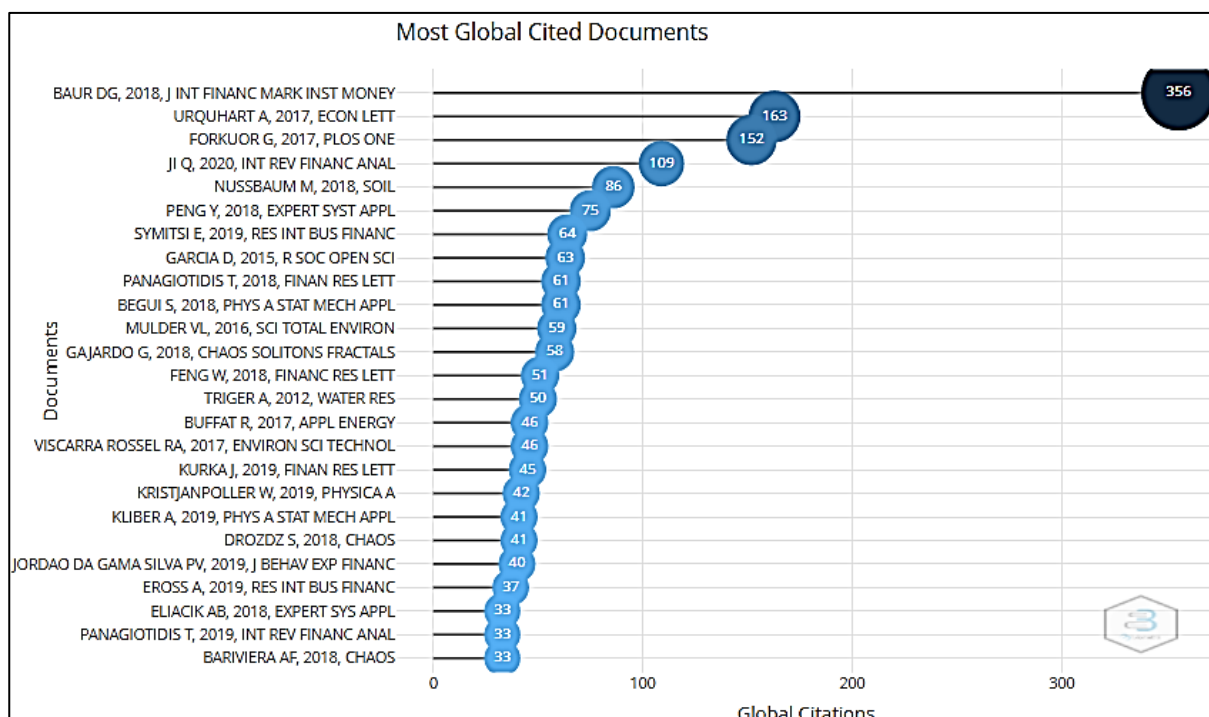
Os termos considerados tendência dos estudos selecionados, demonstrados na Figura 7, indicam frequência maior para “exchange” e Bitcoin, seguidos por “gold”, “financial markets” e “digital storage”. O resultado obtido pela tendência de temas pesquisados corrobora a análise das Figuras 3 a 6 referente às temáticas.

Foram examinados os principais autores pela quantidade de citações, da rede de citações e cocitações. A quantidade de citações indica a influência deste artigo para o campo da pesquisa científica, e a cocitação é usada para analisar a estrutura desse campo (Cobo et al., 2011). Os artigos mais citados são apresentados na Figura 8 entre os coletados pelo *String* do estudo.

Figura 8. Os artigos mais citados entre os coletados pelo String do estudo de 2009 a dezembro de 2021



Fonte: *Software* RStudio.



Fonte: Software RStudio.

Na Figura 8, constam os artigos mais citados por relevância, que é dada pela quantidade de citações que cada artigo recebe. Essa ordenação pode ser modificada de acordo com a data da coleta da pesquisa e com a periodicidade definida pela coleta. Na primeira linha, consta o artigo mais citado, de Baur et al. (2018), que analisam se o Bitcoin é um meio de troca ou um ativo, qual o uso atual e o uso que prevalecerá no futuro. A principal descoberta foi que o Bitcoin não está correlacionado com as tradicionais classes de ativos, é usado como um investimento especulativo, e não como moeda ou meio de troca alternativo.

O segundo artigo mais citado é o de Urquhart (2017), que verificou o comportamento dos preços do Bitcoin por agrupamento, o benefício comercial e os determinantes do agrupamento. Foram encontradas evidências de agrupamentos em torno de números inteiros com mais de 10% dos preços terminando com dígitos decimais de 00 em comparação com outras variações, mas não há um padrão significativo de retornos após o número redondo. Os resultados indicam que quando os preços e o volume aumentam, o *cluster* também aumenta (Harris, 1991; Ikenberry & Weston, 2007).

Nos dois artigos mais citados, foram verificadas características comportamentais da criptomoeda e o comportamento dos preços desta, duas categorias distintas dos objetivos dos artigos coletados. Os objetivos dos artigos mais relevantes, com foco na relação das criptomoedas e bolsas de valores, foram organizados e indicados na Tabela 1.

Tabela 1. Objetivos dos artigos mais relevantes sobre a temática de 2009 a dezembro de 2021

Objetivos dos artigos	Quantidade de artigos	Total de citações	Autores
Comportamento/propriedades das criptomoedas	17	982	(Begušić et al., 2018; Drożdż et al., 2018; Eross et al., 2019; Feng et al., 2018; Gajardo et al., 2018; Ji et al., 2020; Kristjanpoller & Bouri, 2019; Kurka, 2019; Mensi et al., 2019; Panagiotidis et al., 2019; Peng et al., 2018; Silva et al., 2018; Silva et al., 2019; Stosic et al., 2019; Symitsi & Chalvatzis, 2019; Tiwari et al., 2019)

Criptomoeda como porto seguro ou diversificação	3	429	(Baur et al., 2018; Bouri et al., 2020; Kliber et al., 2019)
Preço da criptomoeda	3	62	(Bariviera et al., 2018; Poyser, 2019; Urquhart, 2017)
Valor emocional (<i>tweets</i>) e criptomoedas	2	96	(Eliacik & Erdogan, 2018; Garcia & Schweitzer, 2015)
Total geral	25	1569	

Fonte: Autores (2021).

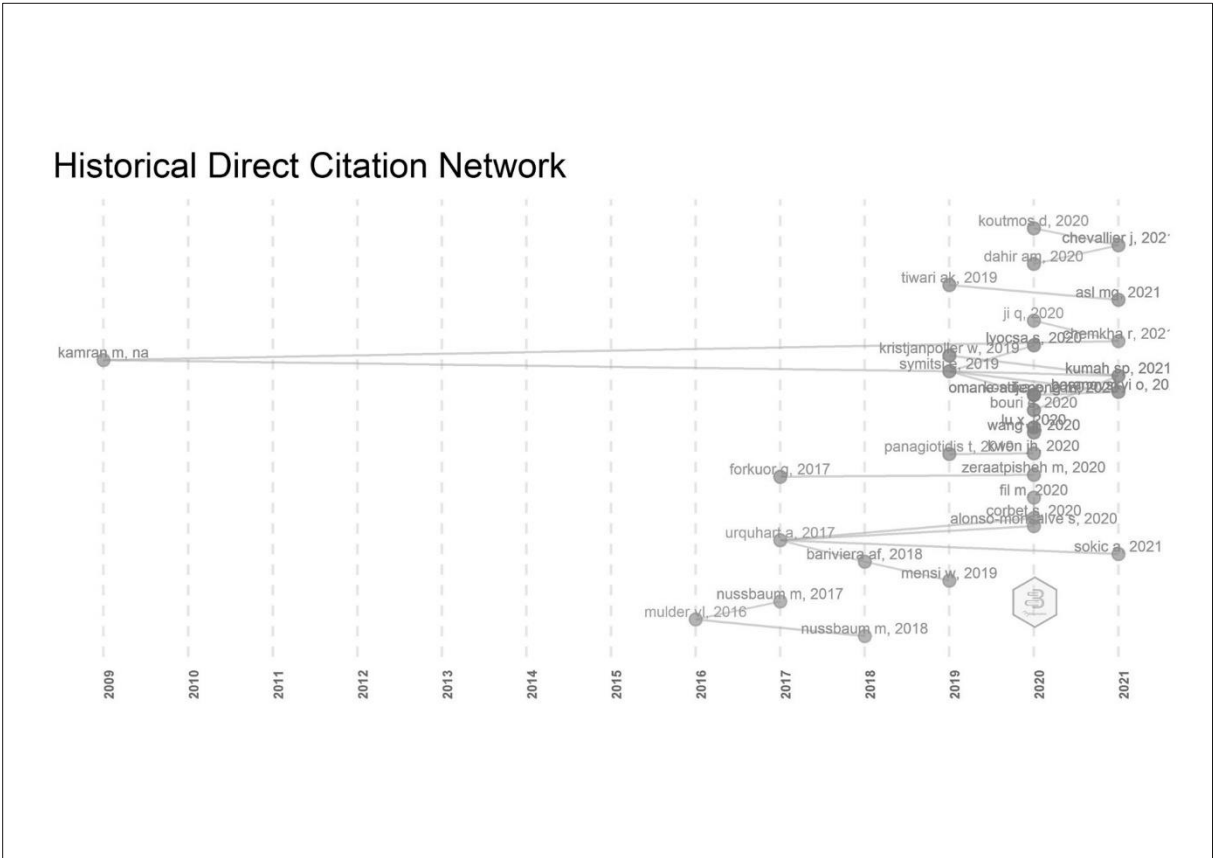
A Tabela 1 é composta por quatro colunas, na primeira estão definidos os objetivos, que foram de maneira generalista indicados por “Comportamento/propriedades das criptomoedas”. Nessa linha, estão indicados os artigos em que os autores selecionaram um conjunto de variáveis e um método estatístico para analisar o comportamento dessas variáveis, e das criptomoedas, de acordo com os resultados gerados. Destaca-se que quanto maior for a aceitação e o uso da criptomoeda, seu desempenho e movimentação em relação a outros ativos provavelmente mudará (Gajardo et al., 2018). A falta de supervisão dos mercados de criptomoedas, como a falta de leis regulatórias e de supervisão das autoridades regulatórias, é razão potencial para a existência de negociações informadas, o que pode ser relevante para os reguladores globais (Feng et al., 2018). O comportamento das variáveis pode mudar, os investidores não podem ignorar as forças motrizes da turbulência do mercado, como períodos eleitorais do Brexit e dos EUA, por exemplo (Ji et al., 2020; Mensi et al., 2019).

Na segunda linha, constam os artigos que verificaram “criptomoeda como porto seguro ou diversificação”, ou seja, a possibilidade de utilização desse tipo de ativo como uma segurança para momentos de instabilidade mercadológica. Para Baur et al. (2018), se a aceitação de moedas virtuais aumentasse significativamente em nível global, poderia afetar o valor das principais moedas fiduciárias e alterar a relevância da política monetária.

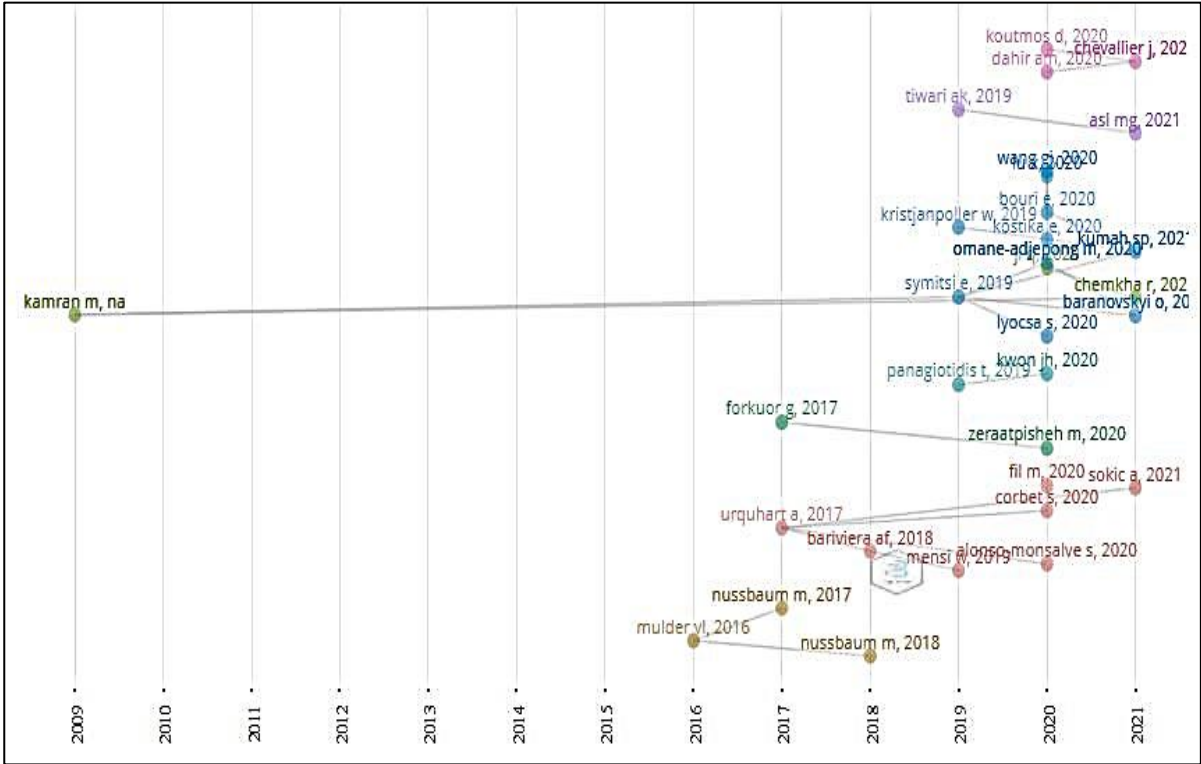
Na terceira linha, têm-se os artigos que focaram o estudo do “preço da criptomoeda”. Os objetivos são a associação entre o preço de mercado do Bitcoin e um conjunto de fatores internos e externos (Poyser, 2019), a dinâmica dos preços intradiários das criptomoedas (Bariviera et al., 2018) e o agrupamento de preços (Urquhart, 2017). A última linha da Tabela 1 indica os artigos que investigaram “valor emocional (*tweets*) e criptomoedas”, em que foram verificados, pela coleta de dados do Twitter, como o humor dos usuários da comunidade social financeira pode interferir na variação do Bitcoin no mercado.

As citações efetuadas pelos artigos coletados geraram subgrupos ou redes de citação, e a Figura 9 apresenta essa rede.

Figura 9. Historiográfico – rede de citações diretas históricas de 2009 a dezembro de 2021



Fonte: *Software RStudio.*



Fonte: *Software RStudio.*

A rede de citações diretas históricas, ou o fluxo de citação dos artigos, ou estrutura intelectual resultante da pesquisa, iniciou em 2016. Essa rede, identificada na Figura 9, consiste em um mapa cronológico das citações relevantes resultantes do conjunto bibliográfico coletado. O

aspecto de interesse nesses casos é a abertura de debate no campo científico com relação ao tópico de interesse.

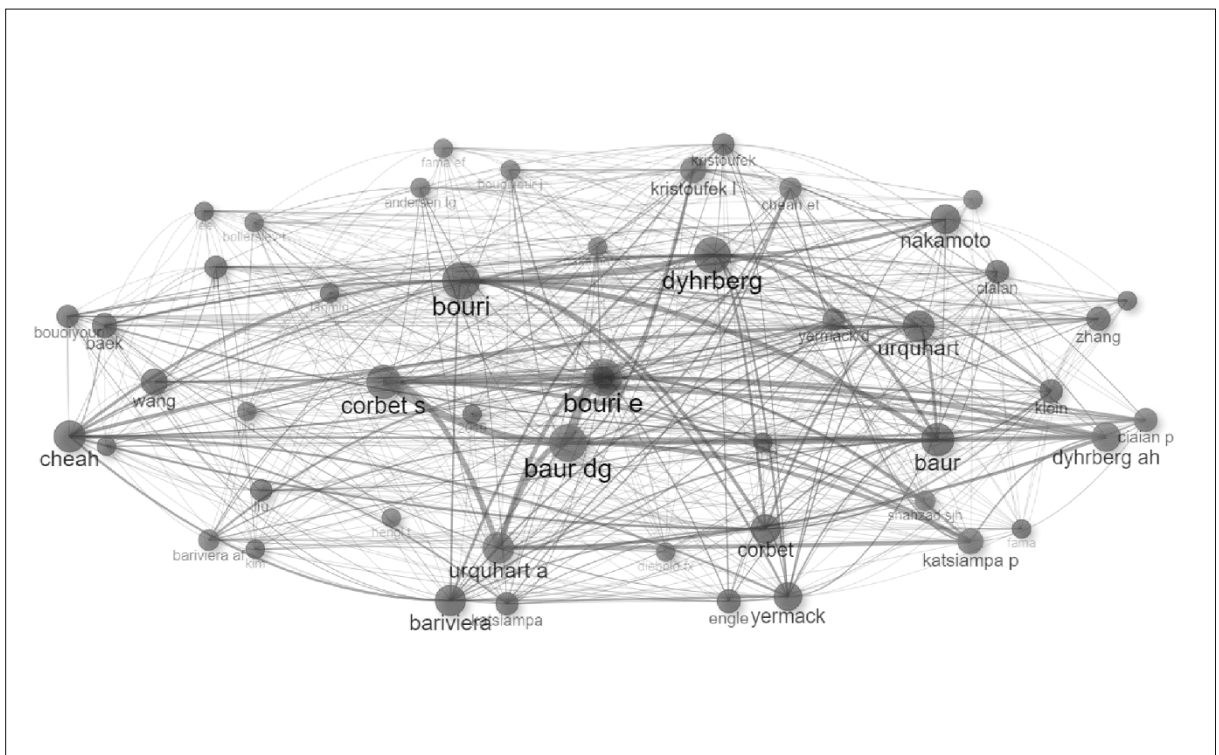
A Figura 9 indica pelo menos oito estruturas intelectuais, a maior cita Urquhart (2017), que estuda o comportamento dos preços do Bitcoin por agrupamento, o benefício comercial e os determinantes do agrupamento.

Na outra rede, os autores citados efetuaram análise da diversificação de carteiras de ativos com a inclusão do Bitcoin (Symitsi & Chalvatzis, 2019), do comportamento das principais criptomoedas (Bitcoin, Litecoin, Ripple, Monero e Dash) e das principais moedas convencionais (franco suíço, euro, libra esterlina, iene e dólar australiano), e da propriedade de porto seguro do Bitcoin em relação aos principais índices de ações australianos durante as duas primeiras ondas da pandemia da Covid-19 (Kamran et al., 2022).

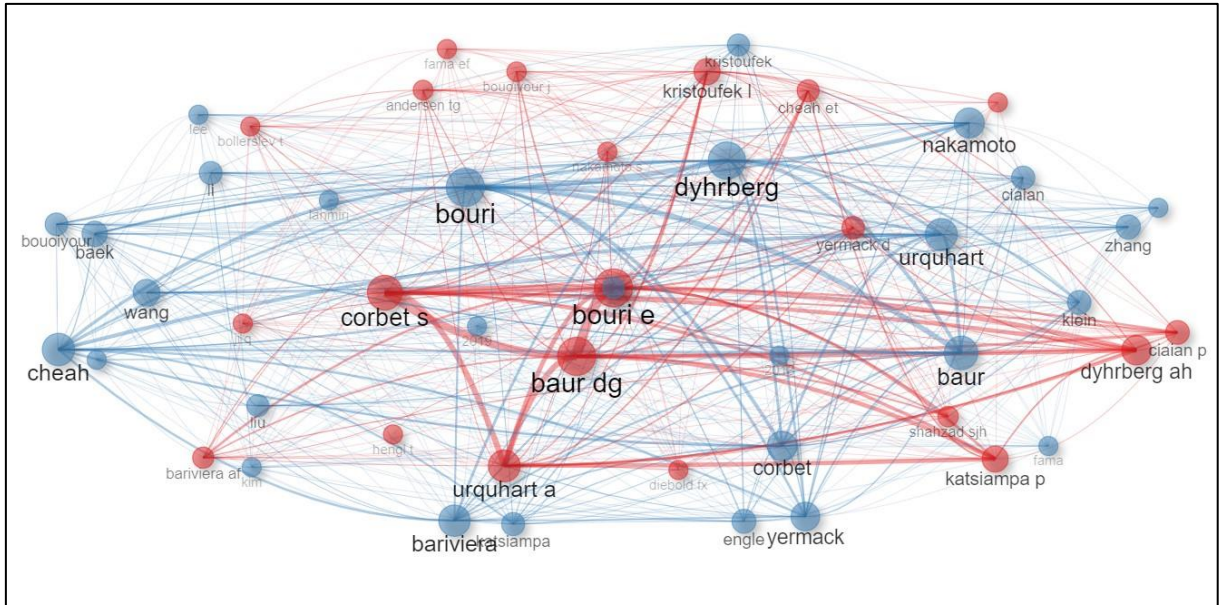
Na iniciada por Tiwari et al., (2018), os temas que geram debate são o teste de multifractalidade, a eficiência do índice de preços Bitcoin e as variações temporais no nível de eficiência do mercado, em que a eficiência do Bitcoin muda ao longo do tempo e é marcada por um fenômeno persistente de memória longa (Tiwari et al., 2018). Os outros autores não indicaram seguimento nos estudos da área, contudo é possível que outras publicações tenham sido feitas, mas não estejam indexadas nas bases consultadas.

Na Figura 10, consta a rede de cocitação, em que está representada a relação de citações das 50 referências citadas com maior frequência entre os artigos da pesquisa. Esse tipo de rede indica o número de vezes que dois artigos são citados juntos por um outro artigo, o tamanho do nó indica o número de citações e as linhas relacionam as ocorrências.

Figura 10. Rede de cocitações sobre o tema de 2009 a dezembro de 2021



Fonte: *Software* RStudio.



Fonte: *Software* RStudio.

A Figura 10 indica dois grupos identificados pelas cores cinza e cinza escuro. O destaque é a participação dos autores Baur, Bouri, Corbet, Dyhrberg, Urquhart, entre outros, em ambos os grupos. Esse resultado indica a importância desses autores para a temática, pois são indicados nos dois grupos e, conseqüentemente, são os mais citados. O parâmetro definido para a seleção das referências usadas de base para a criação dos artigos resultantes dessa coleta foi de 50 autores com, pelo menos, mais de uma repetição. Para esse pressuposto, retornaram 39 referenciados que descreveram suas teorias no período compreendido entre 2002 (Engle, 2002) e 2020 (Bouri, 2020); para essas duas datas em específico, apenas um autor/trabalho foi indicado.

A quantidade mais expressiva de autores indicados foi 25,6% no ano de 2017, seguida por 17,95% no ano de 2015, 15,3% no ano de 2016 e 12,8% em 2019. De acordo com a Figura 3, o ano de 2019 pode ser considerado o período de corte para a evolução temática dos artigos coletados, contudo as referências utilizadas para a construção deles são do período 2009-2019, à exceção do autor Bouri (2020). Essa característica indica que, apesar do uso de referências, com maior concentração no período de 2015 a 2019, ocorreu a evolução temática das pesquisas a partir de 2020, bem como a ampliação da quantidade de estudos.

As análises dos artigos mais citados, da rede de citações e de cocitações possibilitam a compreensão dos trabalhos mais influentes e do que já foi estudado sobre a relação entre criptomoedas, bolsas de valores e o mercado financeiro no qual estão inseridas. Compreendendo o conhecimento existente, é possível evoluir na temática e agregar mais conhecimento científico para o meio acadêmico e que auxilie o desenvolvimento do mercado.

Os temas-tendência obtidos como resultado dessa coleta, em destaque na Figura 7, são *exchange, Bitcoin, gold, criptocurrencies, financial markets*. As relações que esses temas possuem entre si, tomando como base os artigos estudados, são de coexistência no mesmo meio e, em função disso, as interferências e possível causalidade.

O mercado financeiro possui como principal estrutura para desenvolvimento de negócios as bolsas de valores, que comportam negociações, principalmente, compostas por ativos tradicionais, como o ouro. As criptomoedas, em destaque o Bitcoin, são consideradas novos ativos, com negociações recentes e que podem ou não utilizar o meio tradicional para seu desenvolvimento e negociação. Essa característica distinta e inovativa torna esse ativo uma fonte de interesse para a compreensão do seu comportamento diante do mercado consolidado

e, conseqüentemente, do mercado perante as propriedades de resposta do ativo às variações mercadológicas. Esse argumento pode ser justificado pela Tabela 1, que indica a busca da maior parte dos estudos coletados.

O segundo tema de destaque da Tabela 1 é a verificação de a capacidade da criptomoeda ser utilizada como um ativo de diversificação de capital ou ativo porto seguro. Nesse caso, o destaque é a tentativa de desvinculação do mercado de ativos tradicional, por parte dos investidores, por meio do investimento em um ativo que não é regulado pelos sistemas financeiros. Essa estratégia é estudada com o intuito de verificar se esta pode ser uma alternativa ao mercado tradicional, uma nova via para um mercado independente que pode se tornar uma garantia ou uma forma de diluição do risco.

As análises de precificação e resposta emocional das criptomoedas, os temas que surgem com menor frequência na Tabela 1, estão relacionados ao mercado tradicional, visto que esse mercado serve de base para a valoração ou comparação dos preços e da volatilidade das criptomoedas. *Volatility* foi um dos termos de destaque intermediário, indicado na Figura 7, assim como *digital storage*, que serve como forma de registro dessas características das criptomoedas.

Em suma, as pesquisas que relacionam mercado financeiro tradicional, representado pelas bolsas de valores, e as criptomoedas evoluíram de estudos do mercado financeiro com interferências dos estoques de carbono orgânico e da criptomoeda Bitcoin para os mesmos temas citados, acrescidos de temas como criptomoedas em geral, com a inclusão de outras além da Bitcoin, custos, índices, previsão e armazenamento digital. As pesquisas passaram a ter maior complexidade nas análises e na seleção das variáveis, e robustez metodológica para o desenvolvimento dos resultados. O tema é incipiente e com potencial de desenvolvimento, principalmente no que tange à tecnologia de armazenamento digital que envolve as criptomoedas, e nas relações com o mercado tradicional.

CONSIDERAÇÕES FINAIS

As criptomoedas são recentes no mercado financeiro se comparadas a outros ativos ou moedas, por isso ainda há potencial a explorar sobre comportamento e influências que podem sofrer e impor aos ativos. Apesar de ser uma moeda virtual, possui caráter de investimento especulativo, e em alguns casos pôde ser considerada porto seguro para economias consolidadas, ainda que em momento de crise.

Pela revisão sistemática de literatura sobre a relação entre as criptomoedas e as bolsas de valores nas bases de dados *Scopus* e *Web of Science*, foi possível identificar a evolução dos estudos sobre a temática. Até 2019, a temática mais tratada foi o mercado financeiro, mas, a partir de 2020, foi subdividida em mercado financeiro, criptomoedas, custos, mercado de ações e armazenamento digital.

Estudos sobre armazenamento digital, previsão e desenvolvimento sustentável têm potencial para servirem de base para o desenvolvimento dos temas centrais como algoritmos de aprendizagem, negociação eletrônica ligados às criptomoedas e às bolsas de valores, visto que esses temas são identificados pelos artigos como novos tipos de ativos e ativos tradicionais, respectivamente. Os termos tendência identificados foram “*exchange*”, Bitcoin, “*gold*”, “*financial markets*” e “*digital storage*”. O Bitcoin é a criptomoeda mais citada, contudo não é a única aplicada em estudos como os de verificação de correlação ou volatilidade; também foram citadas Ethereum, Ripple, Binance Coin, Cardano. Litecoin, Monero e Dash.

Os principais estudos foram focados na verificação do comportamento das criptomoedas diante de um conjunto de variáveis mercadológicas como ativos negociados nas bolsas de valores, taxa e índices. As criptomoedas também foram verificadas quanto à possibilidade de

serem um ativo porto seguro ou de diversificação para as carteiras de investimentos. Estudos sobre os preços das criptomoedas e o impacto dos *tweets*, como valor emocional, em grupos que tratam de assuntos relacionados a economia, também foram identificados.

A limitação deste estudo foi a aplicação do *String* somente em duas bases científicas; mais bases indicariam outros estudos. O estudo efetuado, conforme prevê a metodologia da pesquisa, necessitará de atualização devido às constantes publicações de artigos sobre o tema, visto que o intuito não é esgotar a discussão, mas compreender o conhecimento gerado e as oportunidades de estudos a desenvolver.

REFERÊNCIAS

- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959–975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Bariviera, A. F., Zunino, L., & Rosso, O. A. (2018). An analysis of high-frequency cryptocurrencies prices dynamics using permutation-information-theory quantifiers. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 28(7), 1–17. <https://doi.org/10.1063/1.5027153>
- Baumeister, R. F., & Leary, M. R. (1997). Writing Narrative Literature Reviews - Baumeister & Leary. *Review of General Psychology*, 1(3), 311–320.
- Baur, D. G., Hong, K., & Lee, A. D. (2018). Bitcoin: Medium of exchange or speculative assets? *Journal of International Financial Markets, Institutions and Money*, 54, 177–189. <https://doi.org/10.1016/j.intfin.2017.12.004>
- Begušić, S., Kostanjčar, Z., Eugene Stanley, H., & Podobnik, B. (2018). Scaling properties of extreme price fluctuations in Bitcoin markets. *Physica A: Statistical Mechanics and Its Applications*, 510, 400–406. <https://doi.org/10.1016/j.physa.2018.06.131>
- Bhandarkar, V. V., Bhandarkar, A. A., & Shiva, A. (2019). Digital Stocks using blockchain technology the possible future of stocks? *International Journal of Management*, 10(3), 44–49. <https://doi.org/10.34218/IJM.10.3.2019/005>
- Bouri, E., Lucey, B., & Roubaud, D. (2020). Cryptocurrencies and the downside risk in equity investments. *Finance Research Letters*, 33, 101211. <https://doi.org/10.1016/j.frl.2019.06.009>
- Cobo, M. J., López-Herrera, A. G., Herrera-Viedma, E., & Herrera, F. (2011). An approach for detecting, quantifying, and visualizing the evolution of a research field: A practical application to the Fuzzy Sets Theory field. *Journal of Informetrics*, 5, 146–166. <https://doi.org/10.1016/j.joi.2010.10.002>
- Gama Silva, P. V. J., Klotzle, M. C., Pinto, A. C. F., & Gomes, L. L. (2019). Herding behavior and contagion in the cryptocurrency market. *Journal of Behavioral and Experimental Finance*, 22, 41–50. <https://doi.org/10.1016/j.jbef.2019.01.006>
- da Silva Filho, A. C., Maganini, N. D., & de Almeida, E. F. (2018). Multifractal analysis of Bitcoin market. *Physica A: Statistical Mechanics and Its Applications*, 512, 954–967. <https://doi.org/10.1016/j.physa.2018.08.076>
- Drózdź, S., Gębarowski, R., Minati, L., Oświęcimka, P., & Watorek, M. (2018). Bitcoin market route to maturity? Evidence from return fluctuations, temporal correlations and multiscaling effects. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 28(7), 071101. <https://doi.org/10.1063/1.5036517>

- Eliacik, A. B., & Erdogan, N. (2018). Influential user weighted sentiment analysis on topic based microblogging community. *Expert Systems with Applications*, 92, 403–418. <https://doi.org/10.1016/j.eswa.2017.10.006>
- Engle, R. (2002). Dynamic Conditional Correlation. *Journal of Business & Economic Statistics*, 20(3), 339–350. <https://doi.org/10.1198/073500102288618487>
- Eross, A., McGroarty, F., Urquhart, A., & Wolfe, S. (2019). The intraday dynamics of bitcoin. *Research in International Business and Finance*, 49, 71–81. <https://doi.org/10.1016/j.ribaf.2019.01.008>
- Feng, W., Wang, Y., & Zhang, Z. (2018). Informed trading in the Bitcoin market. *Finance Research Letters*, 26, 63–70. <https://doi.org/10.1016/j.frl.2017.11.009>
- Gajardo, G., Kristjanpoller, W. D., & Minutolo, M. (2018). Does Bitcoin exhibit the same asymmetric multifractal cross-correlations with crude oil, gold and DJIA as the Euro, Great British Pound and Yen? *Chaos, Solitons & Fractals*, 109, 195–205. <https://doi.org/10.1016/j.chaos.2018.02.029>
- Galvão, M. C. B., & Ricarte, I. L. M. (2019). REVISÃO SISTEMÁTICA DA LITERATURA: CONCEITUAÇÃO, PRODUÇÃO E PUBLICAÇÃO. *Logeion: Filosofia Da Informação*, 6(1), 57–73. <https://doi.org/10.21728/logeion.2019v6n1.p57-73>
- Garcia, D., & Schweitzer, F. (2015). Social signals and algorithmic trading of Bitcoin. *Royal Society Open Science*, 2(9), 150288. <https://doi.org/10.1098/rsos.150288>
- Harris, L. (1991). Stock Price Clustering and Discreteness. *The Review of Financial Studies*, 4(3), 389–415.
- Higgins, J. P., & Green, S. (2008). Cochrane Handbook for Systematic Reviews of Interventions. In J. P. Higgins & S. Green (Eds.), *Cochrane Handbook for Systematic Reviews of Interventions: Cochrane Book Series*, 1-649. Wiley.
- Ikenberry, D. L., & Weston, J. P. (2007). Clustering in US Stock Prices after Decimalisation. *European Financial Management*, 14(1), 30–54. <https://doi.org/10.1111/j.1468-036X.2007.00410.x>
- Ilha, P. C. da S., Piacenti, C. A., & Leismann, E. L. (2018). Uma Análise Comparativa da Competitividade Econômico-financeira das Cooperativas Agroindustriais do Oeste do Paraná. *Revista de Economia e Sociologia Rural*, 56(1), 91–106. <https://doi.org/10.1590/1234-56781806-94790560106>
- Ji, Q., Zhang, D., & Zhao, Y. (2020). Searching for safe-haven assets during the COVID-19 pandemic. *International Review of Financial Analysis*, 71, 101526. <https://doi.org/10.1016/j.irfa.2020.101526>
- Kamran, M., Butt, P., Abdel-Razzaq, A., & Djajadikerta, H. G. (2022). Is Bitcoin a safe haven? Application of FinTech to safeguard Australian stock markets. *Studies in Economics and Finance*, 39(3), 386–402. <https://doi.org/10.1108/SEF-05-2021-0201>
- Kliber, A., Marszałek, P., Musiałkowska, I., & Świerczyńska, K. (2019). Bitcoin: Safe haven, hedge or diversifier? Perception of bitcoin in the context of a country's economic situation — A stochastic volatility approach. *Physica A: Statistical Mechanics and Its Applications*, 524, 246–257. <https://doi.org/10.1016/j.physa.2019.04.145>
- Kristjanpoller, W., & Bouri, E. (2019). Asymmetric multifractal cross-correlations between the main world currencies and the main cryptocurrencies. *Physica A: Statistical Mechanics and Its Applications*, 523, 1057–1071. <https://doi.org/10.1016/j.physa.2019.04.115>
- Kurka, J. (2019). Do cryptocurrencies and traditional asset classes influence each other? *Finance Research Letters*, 31, 38–46. <https://doi.org/10.1016/j.frl.2019.04.018>

- Liang, J., Li, L., & Zeng, D. (2018). Evolutionary dynamics of cryptocurrency transaction networks: An empirical study. *PLOS ONE*, 13(8), e0202202. <https://doi.org/10.1371/journal.pone.0202202>
- Mensi, W., Sensoy, A., Aslan, A., & Kang, S. H. (2019). High-frequency asymmetric volatility connectedness between Bitcoin and major precious metals markets. *The North American Journal of Economics and Finance*, 50, 101031. <https://doi.org/10.1016/j.najef.2019.101031>
- Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. www.bitcoin.org
- Panagiotidis, T., Stengos, T., & Vravosinos, O. (2019a). The effects of markets, uncertainty and search intensity on bitcoin returns. *International Review of Financial Analysis*, 63, 220–242. <https://doi.org/10.1016/j.irfa.2018.11.002>
- Peng, Y., Albuquerque, P. H. M., Camboim de Sá, J. M., Padula, A. J. A., & Montenegro, M. R. (2018). The best of two worlds: Forecasting high frequency volatility for cryptocurrencies and traditional currencies with Support Vector Regression. *Expert Systems with Applications*, 97, 177–192. <https://doi.org/10.1016/j.eswa.2017.12.004>
- Poyser, O. (2019). Exploring the dynamics of Bitcoin's price: a Bayesian structural time series approach. *Eurasian Economic Review*, 9(1), 29–60. <https://doi.org/10.1007/s40822-018-0108-2>
- Siddaway, A. P., Wood, A. M., & Hedges, L. V. (2019). How to Do a Systematic Review: A Best Practice Guide for Conducting and Reporting Narrative Reviews, Meta-Analyses, and Meta-Syntheses. *Annual Review of Psychology*, 70(1), 747–770. <https://doi.org/10.1146/annurev-psych-010418-102803>
- Stosic, D., Stosic, D., Ludermir, T. B., & Stosic, T. (2019). Multifractal behavior of price and volume changes in the cryptocurrency market. *Physica A: Statistical Mechanics and Its Applications*, 520, 54–61. <https://doi.org/10.1016/j.physa.2018.12.038>
- Symitsi, E., & Chalvatzis, K. J. (2019). The economic value of Bitcoin: A portfolio analysis of currencies, gold, oil and stocks. *Research in International Business and Finance*, 48(C), 97–110. <https://doi.org/10.1016/j.ribaf.2018.12.001>
- The Campbell Collaboration. (2014). Campbell Collaboration Systematic Reviews: Policies and Guidelines. <https://doi.org/10.4073/cpg.2016.1>
- Thomé, A. M. T., Scavarda, L. F., & Scavarda, A. J. (2016). Conducting systematic literature review in operations management. *Production Planning & Control*, 27(5), 408–420. <https://doi.org/10.1080/09537287.2015.1129464>
- Thorne, S., Jensen, L., Kearney, M. H., Noblit, G., & Sandelowski, M. (2004). Qualitative Metasynthesis: Reflections on Methodological Orientation and Ideological Agenda. *Qualitative Health Research*, 14(10), 1342–1365. <https://doi.org/10.1177/1049732304269888>
- Tiwari, A. K., Raheem, I. D., & Kang, S. H. (2019). Time-varying dynamic conditional correlation between stock and cryptocurrency markets using the copula-ADCC-EGARCH model. *Physica A: Statistical Mechanics and Its Applications*, 535, 122295. <https://doi.org/10.1016/j.physa.2019.122295>
- Tiwari, A. K., Selmi, R., & Hammoudeh, S. (2018). Efficiency or speculation? A dynamic analysis of the Bitcoin market. *Economics Bulletin*, 38(4), 2037–2046. <https://ideas.repec.org/a/ebl/ecbull/eb18-00395.html>
- Urquhart, A. (2017a). Price clustering in Bitcoin. *Economics Letters*, 159, 145–148. <https://doi.org/10.1016/j.econlet.2017.07.035>

CONFLITOS DE INTERESSE

O/A autor/a não têm conflitos de interesse a declarar.

CONTRIBUIÇÃO DO/A AUTOR/A

Viviane de Senna: Conceituação, curadoria de dados, análise formal; Investigação; Metodologia; Programas; Visualização; Redação – rascunho original; Redação – revisão e edição.

Adriano Mendonça Souza: Administração de projetos; Recursos; Supervisão; Validação.

5 ARTIGO 3 - IMPACTS OF SHORT AND LONG-TERM BETWEEN CRYPTOCURRENCIES AND STOCK EXCHANGE INDEXES

Quality & Quantity <https://doi.org/10.1007/s11135-022-01356-2>



Impacts of short and long-term between cryptocurrencies and stock exchange indexes

Viviane de Senna¹ · Adriano Mendonça Souza²

Accepted: 16 February 2022

© The Author(s), under exclusive licence to Springer Nature B.V. 2022

ABSTRACT

The Stock Exchanges are safe and organized markets for stock and bond trading, which aim to expand the capital of both publicly traded companies and investors. Since 2009, cryptocurrencies have been created, mostly decentralized, registered through *blockchain* and encryption, which can be a new form of investment and trading. The main purpose of this research is to determine the short and long-term relationships of the main indicators of twenty-one Stock Exchanges and three cryptocurrencies and verify their effects on the financial market. The defined methodology was the VAR/VEC Model that obtained as a result the causality between all the series, which are stationary in the first difference, the VAR indicated the short-term relationship, the cointegration indicated the order for the VEC application, which was explained with the help of IRF and the variance decomposition that indicated the long-term relationship between the series and the possibility of cryptocurrencies' influence in the Stock Exchange series. The Bitcoin cryptocurrency, after the shock's application, indicated to influence the Stock Exchanges for an average time of 16 periods, Litecoin for 15 periods, and Ripple for 16 periods. The time evaluated was 24 periods and proved to be sufficient for the study's definition.

Keywords Stock exchanges · Cryptocurrencies · VAR/VEC model · Financial market

1 INTRODUCTION

Major world economic negotiations take place through the Stock Exchanges, which are institutions focused on trading stocks and bonds as a goal to generate a safe and organized environment for business development. The companies go public and start

* Viviane de Senna viviansenna@hotmail.com Adriano Mendonça Souza amsouza.sm@gmail.com

¹ Production Engineering, Federal University of Santa Maria – UFSM, Avenida Nossa Senhora das Dores n° 43/508; Bairro: Nossa Senhora das Dores, Santa Maria, RS CEP 97050-531, Brazil

² Graduate Program in Production Engineering, Federal University of Santa Maria – UFSM, Centro De Ciências Naturais e Exatas – CCNE, Prédio 13; Av. Roraima n° 1000; Cidade Universitária; Bairro Camobi, Santa Maria, RS CEP 97105-900, Brazil

are of interest to all parties involved, as companies expand their capital and investors profit together with the companies.

Currently there is a new way of trading that does not take place in the Stock Exchanges—the Cryptocurrencies. Cryptocurrencies have begun to establish new ways of developing negotiations, since they are a means of exchange that use a system, mostly decentralized, based on *blockchain* and encryption technologies. Analyses about cryptocurrencies are made considering the forecast of prices (Urquhart 2017; Begušić and Kostanjčar 2019) or exchange rates between them and the dollar or comparing them with stocks or market indexes (Panagiotidis et al. 2019; Kurka 2019; Poyser 2019; Teh et al. 2015; Kostika and Laopodis 2019). As is the case of Uras et. al. (2020) who developed a comparative study between three cryptocurrencies, Bitcoin, Ethereum, and Litecoin and stock prices to verify how these cryptocurrencies resemble and differ from traditional market prices.

The relationship between Stock Exchanges movements and cryptocurrency prices was analyzed by Bhullar and Bhatnagar (2020), but the variables in question were Bitcoin and the India and China Stock Exchanges. The research obtained as empirical results the existence of a long-term relationship between Bitcoin and the India and China Stock Exchanges. Olaiwola et al. (2020) examined the relationship between economic and financial variables, exchange rate and stock market price, and the Bitcoin and Ethereum cryptocurrencies in Nigeria. The result shows that the share price is more influenced by the instability of Bitcoin and Ethereum prices than the exchange rate in Nigeria.

Stock Exchanges are traditional and consolidated institutions worldwide, knowing all the short and long-term relationships capable of influencing this market helps decision making. As is the case with cryptocurrencies, Kurka (2019) identified that market disturbances can be transferred from Bitcoin to traditional economic assets including commodities, foreign exchange, stocks and financials. The study by Panagiotidis et al. (2019) identified significant interaction between Bitcoin and traditional stock markets and weaker interaction between foreign exchange markets.

This research is justified for presenting a large number of Stock Exchanges series, twenty-one, which are its main indexes, and relating them to three cryptocurrencies, thus it is distinct as it expands the system and the evaluation's complexity. The representativeness of Stock Exchanges in several countries indicates the existence of a relationship between traditional international markets and the ability to be impacted by new tradable assets. Combining the high number of Stock Exchanges, the interactions between them will enable the determination of capital gains of policy formulations for the companies involved.

The problem to be answered is how do some of the world's major Stock Exchanges and the cryptocurrencies relate in the short and long term? The objective of this research is to determine the short and long-term relationships of the main indicators of twenty-one Stock Exchanges and three cryptocurrencies and verify their effects on the financial market. The study's differential is the large number of indexes analyzed simultaneously from traditional international financial institutions against the new market assets (the cryptocurrencies) to identify the system's relationships. Cryptocurrencies were selected based on their relevance in the market and the difference in performance, trading volume, market valuation and the same number of observations.

In the next item, a brief approach on Stock Exchanges and cryptocurrencies will be presented, in item 3 the scientific methodology applied, in item 4 the results and discussions, in item 5 the final considerations, and in item 6 the references.

2 STOCK EXCHANGES AND CRYPTOCURRENCIES

Stock Exchanges are institutions that organize the stock market, which is a market where individuals and companies negotiate the purchase and sale of bonds and shares that are made

available by publicly traded companies. The shares are legal capital's pieces of publicly traded companies and bonds, they can be public or Treasury or organized civil society assets, they are fixed income investments in which the investor chooses when investing. All the Stock Exchanges are represented by indexes that are comprised by the main companies that belong to it. This type of market can be considered traditional and able to influence various types of negotiations, however new forms of negotiations arise, as is the case with cryptocurrencies. Cryptocurrencies are electronic money or a type of currency that can be centralized or decentralized and produced collectively by a system that, at the time of its creation, is publicly available. A decentralized currency does not have a centralized banking or economic system, or even a board of directors or control of any government in the currency printing process, as is the case with centralized systems, for example the United States Federal Reserve (Chatterjee et al. 2018). The first cryptocurrency, called Bitcoin, was created in 2009 by a user who adopted the pseudonym Satoshi Nakamoto.

The purpose of electronic money is to allow online payments from one party to another without the intermediation of financial institutions (Nakamoto 2008). As a solution to the proposal, a network that marks the transactions' time in a long and continuous chain that serves as proof of sequence and transactions' event was created. The network used by the cryptocurrencies is the *blockchain* and encryption technology to ensure the validity of transactions or the creation of new currencies (Stosic et al. 2019; Park and Park 2020).

Blockchain is a digital logbook distributed over a *peer-to-peer* network of thousands of computers that may or may not be public (Nazifi et al. 2021; Poyser 2019). The *blockchain* system defines what is valid in terms of financial activity, in this manner the series of transactions approved by the validation and verification process are grouped in a block (Miraz and Ali 2018; Chatterjee et al. 2018). The newly prepared block is communicated to all other participating nodes to be attached to the existing blockchain. Encryption, which is an algorithm to reconcile a ledger distributed on a decentralized platform, is combined with *blockchain*. Each user has a digital cryptographic signature and the public key encryption is used in *blockchain* to generate a signature for *blockchain* (Ramachandran and Krishnamachari 2018). Users perform transactions by creating a digital signature using their private keys.

There are several cryptocurrencies available and negotiable in the market, the best known is called Bitcoin (Urquhart 2017; Park and Park 2020). Although it was created in 2009, it began to be used from 2013 onwards, it is a new entry into the foreign exchange market, although it is officially considered a commodity rather than a currency (Uras et al. 2020; White et al. 2020). Bitcoin is not correlated with traditional asset classes, but is used as a speculative investment and not as an alternative currency or medium of exchange. (Baur et al. 2018). It cannot be considered a hedge for developed stock markets either. as it declines when markets are declining in shock situations and its properties are fundamentally different as assets and connections with stock markets if compared to gold. (Klein et al. 2018). Besides Bitcoin, two other currencies, Ripple and Litecoin, will be part of the study. These cryptocurrencies were selected due to the considerable amount of transactions and their valuation. The cryptocurrency time series have the same periodicity and number of observations as the Bitcoin series.

The development of the study will rely on the methodology described in the next chapter.

3 METHODOLOGY

The variables used in the study correspond to the indexes' daily series of the twenty-one Stock Exchanges and the three cryptocurrencies. The series were collected in the *Yahoo Finance* website in the period between 05/26/2016 and 12/30/2019, totaling 905 observations of each

series and analyzed in the software *Eviews* version 10SV—*Student Version*. For the series that presented some gap it was made the moving average of the four closest values.

The selected cryptomaps were Bitcoin, Ripple, and Litecoin represented by BTC, XRP, and LTC respectively. The indexes that represent the Stock Exchanges used to develop the research are described in Table 1:

Table 1 describes the codes and the respective names of the indexes that represent the Stock Exchanges in the first and second columns, the identification of the Stock Exchanges in the third column, and the country where they are located in the fourth column.

The proposed time series study assumes several steps to be accomplished and will be described in the following topics.

Table 1 Description of Stock Exchange Indexes used in the survey

Code	Index name	Stock exchange	Country
^AXAT	Australia S&P/ASX ALL Australian 200	Australia	Australia
^BSESN	India Bombay S&P BSE Sensex	Bombay	India
^FTSE	London FTSE 100	London	England
^HSI	Hang Seng Index	Hong Kong	China
^KLSE	FTSE Bursa Malaysia KLCI	Malaysia	Malaysia
^KS11	Korea KOSPI Composite Index	South Korea	South Korea
^MERV	MERVAL	Buenos Aires	Argentina
^N100	EURONEXT 100	Paris	France
^N225	Nikkei 225 Osaka	Tokyo	Japan
^NSEI	India NIFTY 50	India	India
^SSE180	SSE 180 Index	Shanghai	China
^SSMI	Switzerland SMI	Switzerland	Switzerland
^STI	FTSE Straits Times Singapore	Singapore	Singapore
^TWII	FTSE MIB Index	Milan	Italy
159903.SZ	China SZSE Component Index Fund/ETF	Shenzhen	China
DAX	Frankfurt Global X DAX Germany ETF	Frankfurt	Germany
FNCMX	Fidelity NASDAQ Composite Index	Nasdaq	United States
IBOV	IBOVESPA	B3, Brasil Bolsa Balcão	Brazil
IMOEX.ME	MOEX Russia Index	Moscow	Russia
JSE.JO	JSE Limited	Johannesburg	South Africa
TA35.TA	TA-35	Tel Aviv	Israel

Source Authors

3.1 Series stationarity test

A series is considered stationary when it has constant variance over time and its oscillation is around the average. Augmented Dickey Fuller—ADF (1981), Phillips and Perron—PP (1988), and Kwiatkowski et al. (1992) tests verify the presence of unit root in the series.

For the ADF test the null hypothesis is that the series is non-stationary, that is, it has unit roots. In the PP test the null hypothesis is also of non-stationarity—I(1), the non presupposition of white noise in the residue's behavior ε_t of this test can lead to wrong conclusions, for this reason several tests are used. The test proposes a correction of the calculated *t*-statistics, since it considers it possible for the residues to be autocorrelated. The KPSS test has as null hypothesis the series' stationarity—I(0), by a deterministic tendency. When the series is not stationary in level, a difference of first or second order is made (Agung 2010). The stationarity tests are necessary for the application of Granger's causality test and VAR/VEC models that assume the series' stationarity in level or with difference in first order, as described in the next topics.

3.2 Granger causality test

Granger's causality aims to verify if there are relations between the system's series, these relations are presented in pairs and with the indication of the direction of this interdependence (Granger 1986). If there is no causality between the series it may indicate that the series' presence in the system is not important, because it does not cause modification in the proposed model the coefficient will be close to zero and the exclusion meets the assumption of parsimony.

The application of causality is useful because it allows the withdrawal of the series that are not useful for forecasting and, therefore, do not need to be included in VAR modeling.

3.3 Vector autoregression model—VAR

The VAR is a vector autoregression model capable of evaluating the existence of relationships between endogenous or exogenous variables, which can be used to predict values of two or more economic series and is related to simultaneous equation models (Sims 1980). The model examines the relationship between variables and their lagged values and allows the assessment of the impact of random disturbances caused in the systems. The representation of the VAR order, p order, is defined by Eq. (1) (Enders 2014).

p

$$x_t = A_0 + \sum_{i=1}^p A_i x_{t-i} + \varepsilon_t \quad (1)$$

$i=1$

where: x_t is the vector of variables; A_0 is the representation of the intercept matrix; A_i , $i = 1, 2, 3, \dots, p$ are matrices with the terms of the equations; ε_t is white noise, and a vector of innovation or shock. The VAR starts by estimating an auxiliary model that is used to determine the lag p order. The results of this auxiliary model indicate the p order of the model by AIC, SC, and HQ criteria. To estimate the model's p order, the AIC, SC, and HQ criteria represented by Eqs. (2) (Akaike 1974), (3) (Schwarz 1978), and (4) (Hannan and Quinn 1979) are used:

$$2 \quad (2)$$

$$AIC(\hat{p}) = \ln \|\Sigma(p)\| + \frac{2pn}{T} \quad (3)$$

$$SC(\hat{p}) = \ln \|\Sigma(p)\| + \frac{pn}{T}$$

$$HQ(\hat{p}) = \ln \|\Sigma(p)\| + \frac{\ln(\ln T)}{2pn} \quad (4)$$

As a decision criterion, the lower the values presented by the tests, the better the model adopted. The knowledge of the number of lags already selected by the VAR Model is the basis for discovering the number of series relations in the application of cointegration (Johansen 1988). The best model is the one with the most appropriate number of lags according to the criteria. The Lag Order Selection Criteria test that indicates the joint significance of the lags included in the VAR model (Senna and Souza 2016) can be used to define the lags.

The tests do not present a consensus regarding the ideal number of estimators, so the quantities of lags indicated by most tests can be observed. After the p -order is defined, the model is again estimated with the correct order to define the system series' order from the most exogenous to the least exogenous, necessary for the application of the VEC model, the IRF, and the variance decomposition. For the continuity of the study, Johansen's Cointegration method checks the linear combination between the series and will be described in the next topic.

3.4 Cointegration by the Johansen method

The selection of the VAR model's number of lags is assumed to analyze if there is a cointegration vector between the series and from that verify the existence of linear combination between them. When the series are cointegrated there is a long-term relationship between them, even if there are stochastic tendencies in the series they will move together, if the proportions between them are stable, over time and in common direction (Granger et al. 2000). For this, the series must be stationary with difference in first order, according to the Stationarity Test.

Johansen (1988) developed a cointegration, based on the rank (r) of the matrix Π and the number of vectors determined by the knowledge of the matrix' rank (r), according to the Eq. (5):

$$\Delta X_t = \alpha + \Gamma_1 \Delta X_{t-1} + \dots + \Gamma_{p-1} \Delta X_{t-p+1} + \Pi Y_{t-1} + \varepsilon_{x,t} \quad (5)$$

In this case, I_g , β is the cointegration parameter e ΔX_t is vector with n variables, $\varepsilon_{x,t} \sim (0, \Sigma)$ e $E(\varepsilon_{x,t}, \varepsilon'_s) = 0$ for t different from s. The transformed VAR has g variables on the left of the equation and k-1 lags of the dependent variables on the right, both associated with a coefficient matrix Γ .

There can be three possibilities (Enders 2014):

(i) the rank of Π is complete, a linear combination between variables is stationary and the model adjustment is carried out with the variables in level;

(ii) the rank of Π being null, there is no cointegration, the model is adjusted with the variables in difference;

(iii) the matrix Π has reduced rank, there are r cointegration vectors, where $0 < r < n$.

To find out the series' number of cointegration relations there are two statistical tests, the Trace test and the maximum eigenvalue test.

The Trace test focuses on testing the null hypothesis, in which the number of distinct cointegration vectors is less than or equal to r or the alternative hypothesis (Engle and Granger 1987). In the alternative hypothesis the number of vectors will be greater than r, according to Eq. (6).

n

$$\lambda_{\text{trace}}(r) = -T \sum_{i=r+1}^n \ln(1 - \lambda_i) \quad (6)$$

i=r+1

In this case, r is the number of cointegration vectors under the null hypothesis, T is the number of observations, λ_i indicates the estimated i-th ordered eigenvalue of the matrix Π .

In the maximum eigenvalue test the null hypothesis indicates that the number of vectors is r and, consequently, the alternative hypothesis is the existence of r + 1 cointegration vectors, represented by Eq. (7).

$$\lambda_{\text{max}}(r, r + 1) = -T \ln(1 - \lambda_{r+1}) \quad (7)$$

r+

where r is the number of cointegrations vectors, T the number of observations and λ the eigenvalues considering r + 1 vectors.

After checking the cointegration relationship between the variables X_{t-i} and Y_{t-i} (Engle and Granger 1987), we proceed to the next step, which is to include the error correction model described in the next topic.

3.5 Error correction model—VEC

By applying the VEC Model it is possible to analyze the interdependence of the series that are influenced by their order. When two variables are cointegrated, they converge to longterm balance and the VEC's estimation allows defining the speed to reach balance. VEC has the advantage of retaining information about the series level, that is, the relationships remain present (Engle and Granger 1987). However, the series must be integrated in the same order, which indicates the need for stationarity tests.

If the variables X_{t-i} and Y_{t-i} are integrated in one order I(1) and have cointegration of zero order I(0) the VEC is represented by Eq. (8) (Engle and Granger 1987):

$$\{\Delta Y_t = \beta_0 + \beta_1 \Delta Y_{t-1} + \beta_2 \Delta X_{t-1} + \varphi \text{ECT}_{y,t-1} + u_{y,t}$$

$$\Delta X_t = \alpha_0 + \alpha_1 \Delta Y_{t-1} + \alpha_2 \Delta X_{t-1} + \varphi \text{ECT}_{x,t-1} + u_{x,t} \quad (8)$$

where ΔY_{t-i} and ΔX_{t-i} indicate the first difference of the variables lagged i periods; β_0 , β_1 , β_2 , α_0 , α_1 , α_2 are coefficients of the model; φ is the long-term coefficient; $u_{y,t}$ and $u_{x,t}$ are terms of random error; $\text{ECT}_{t-i}^{\text{ECT}}$ are deviations from the long-term balance between ΔY_{t-i} and ΔX_{t-i} lagged i periods. If φ is significant, the errors of the long-term cointegration equation serve to adjust the short-term variations making it possible to check the imbalance proportion of Y_t which is corrected in the following period. The lagged values of the variable ΔX_t can help explain the changes of another variable ΔY_t , even if the changes in ΔY_t are irrelevant and considering that the variables are stationary. If ΔX_t and ΔY_t have a common tendency the causality must exist in at least one direction, being it inverse or bi-causality.

If the organization of the relations of variances is incorrect it is necessary to apply the Granger *Causality/Block Exogeneity Wald* test to order the series from the most exogenous to the most endogenous and to obtain the joint significance of the endogenous variables lagged in the VEC equation. λ^2 indicates the variable's representativity, the greater it is the more endogenous the p value and the degree of endogeneity.

When the VEC result presents a high number of cointegrations and lags the number of parameters is excessive for the explanation and interpretation of the parameters (Sims 1980). Thus, Sims (1980) developed the Impulse Response Function—IRF method and the decomposition of variance described in the next topics.

3.6 Impulse response function—IRF

The Impulse Response Function allows to verify which variations, positive or negative, occur in the system's variables when a shock, that is, a standard deviation, is applied to the residue of one of the variables of the system of equations. This makes it possible to verify the extent of the contagion in the model to a change in one of the variables and the time needed to return to balance (Brooks 2008). If the occurrence of the shock has no effect on the variance forecasts of the other variables, it is possible that the variable is exogenous, which makes it independent of the system.

IRF represents the behavior of a variable when this or another, of the same system, suffers a shock in the instant of time t , transfers to $t+1$, $t+2$, and consecutively and makes it possible to evaluate the results in any of the system's variables (Brooks 2008). Through Cholesky's decomposition it is possible to impose restrictions so that the analysis of the relations between the variables can be carried out (Sims 1980). The decompositions are different according to the order of the variables, even if no causality occurs between two variables there may be a shock effect as a function of the covariance between the respective residues.

3.7 Decomposition of variance

By decomposing the variance of the forecast errors it is possible to obtain the evolution of the variables' behavior over time and in a dynamic way. It is also possible to separate the variance of the forecast residues from the variables into components that can be attributed by the endogenous variables and result in percentages, and thus, identify the percentage of the variables' variation according to the individual shock of the system's variables (Le et al. 2021). In other words, understand the VAR's errors through the interrelation between the system's variables (Enders 2014).

Each variable is responsible for explaining the variance of the others after the shock. Through the decomposition of the variance, we try to identify the relative importance of each variable in the determination of itself and of others. In bivariate models the variance is decomposed into two parts for each period by $\sigma_y^2(h)$, for y and for z . If a shock is applied to one of the variables and it does not result in an effect on the error variances of the others' forecasts, this variable is independent or exogenous. From the application of the models described in the methodology, the results are obtained as described in chapter 5, below.

4 RESULTS AND DISCUSSIONS

The ADF, PP, and KPSS stationarity tests indicated that the series are stationary with difference in first order, at 1% significance level, with the exception of the XRP series which presented stationarity at the ADF and PP tests level, but in first difference in KPSS, also at 1% significance, for this reason the series was kept in the system with a difference. This result meets the assumption of series stationarity for the determination of VAR/VEC models.

The result of Granger's causality test, which was developed with a *lag*, defined by the *Lag Order Selection* test presented in sequence, and consequently with 903 observations, indicates that all series have a causality relationship according to Fig. 1:

In Fig. 1, the Sankey diagram (Kennedy and Sankey 1898), shows the causality relationships between the series, which go from "A" to "B" with significances of 5% and 10%. The use of Fig. 1 helps the interpretation of the test result in a visual way, because the higher the area of the series in the graphic on the "A" side, the greater the amount of series that this causes. The lines join "A" and "B" to identify which series "B" is caused by "A", the higher the area on the "B" side of the graphic the greater the amount of relations on it.

Highlights include the D(FNCMX), D(DAX), D(^N100), and D(IBOV) series, which represent the Nasdaq, Frankfurt, Paris, and B3 Stock Exchanges respectively, which in




Fig. 1 Sankey chart showing Granger's causality relationship

this system are related to a considerable number of other Exchanges. The series representing the cryptocurrencies, BTC, LTC, and XRP have a causality relationship with some Stock Exchanges, but BTC is not present on the "B" side of Fig. 1, so it is not caused by the Stock Exchanges in the system. All the series are related to at least one of the others, which will be detailed in Tables 2 and 3. The series with unidirectional causality are shown in Table 2.

The form represented in Table 2 allows the identification of the relations' significance levels. The relations indicated in Table 2 are exclusively unidirectional starting from "A", represented by the Null Hypothesis, in the first column, to "B" at 5% of significance, in the second column, or to 10% of significance, in the third column. The highlight of Table 2 is the presence of series caused by cryptocurrencies and 5% of significance, Bitcoin also has a causality relationship with the other two cryptomorphs.

In Table 3 are the responses to the bidirectional Granger causality test, for series that present a mutual causality relationship.

Table 3 presents the series causing "A" in the first column, and the series causing "B", at 5% significance, in the second column, and at 10% significance, in the third column. These series have bidirectional causality, but differ in significance, for example, D(^STI) causes D(LTC) with a significance lower than 5%, but D(LTC) causes D(^STI) with a significance higher than 5% and lower than 10%. Of the bidirectional series, D(DAX), which has a relation of mutual cause with eight other Stock Exchanges at 5% and one at 10% of significance, stands out.

The VAR model starts with the definition of the number of lags from the *Lag Order Selection Criteria* test, in Table 4 are the results of this test:

According to the results in Table 4, by the AIC definition criteria, there is a lag, by HQ and SC there are no lags. To help decide the number of lags to be adopted, the residues' autocorrelation test was performed for the indicated lags. To verify the existence of white noise in the residues, the residues' autocorrelation test was performed for all the indicated lags. The model's inverted roots (x^{-1}), which must be within the unitary

circle, in this case, showed better response for 1 *lag*. For this reason, 1 *lag* was adopted for the application of the VAR model and for the cointegration test.

The equations that represent the short-term relationships between the cryptocurrencies and the Stock Exchanges have many terms, because all the series in the system have a causality relationship. The estimation of the VAR allows the assignment of equations for each of the system's series, in these equations all the others belonging to the system are visualized. From the short-term relationships, through Johansen's cointegration it will be possible to verify the existence of long-term relationships.

To apply the cointegration test the number of lags defined in the VAR model is used, in this case it is not necessary to station the series, even if they are not individually stationary or do not have the same order. A long-term relationship indicates that the series trace the same direction, showing an analogous stochastic tendency. The number of cointegration vectors is determined by knowing the matrix rank (r). Table 5 shows the results of the Granger test that assists in the ordering of variables:

Cointegration by the Johansen Method, with the application of the *Granger Causality/Block Exogeneity Wald* test, shows that the most exogenous series is the series with the highest value for the statistics χ^2 and the most endogenous the one with the lowest for this statistic χ^2 . The larger the χ^2 , the more representative the series will be, and the more exogenous, therefore it is the first series of the model. According to the data presented in Table 5 the ordering of the series, considering the most exogenous for the most endogenous will be:

Table 2 Series with unidirectional causality according to the Granger's Test

Null Hypothesis	Significance at 5%	Significance at 10%
D(^AXAT)	D(^KS11), D(^N225), D(^STI), D(^TWII)	
D(^FTSE)	D(159903.SZ), D(^AXAT), D(^BSESN), D(^HSI), D(^KLSE), D(^KS11), D(^NSEI), D(^SSE180), D(^STI), D(^MOEX_ME)	D(^MERV)
D(^HSI)	D(^KS11), D(^SSE180), D(^STI)	D(^BSESN), D(^NSEI)
D(^KS11)		D(^SEJO)
D(^MERV)	D(159903_SZ), D(^AXAT), D(^BSESN), D(^KLSE), D(^KS11), D(^N225), D(^NSEI), D(^SSE180), D(^SSMI), D(^STI)	
D(^N100)	D(159903.SZ), D(^AXAT), D(^BSESN), D(^HSI), D(^KLSE), D(^KS11), D(^N225), D(^SSE180), D(^STI)	D(^FTSE), D(^MERV), D(^NSEI)
D(^N225)	D(DAX), D(LTC)	D(^SEJO)
D(^SSMI)	D(159903.SZ), D(^HSI), D(^MOEX_ME), D(^KLSE), D(^KS11), D(^SSE180), D(^STI)	
D(^STI)	D(^NSEI)	D(^BSESN), D(^KS11)
D(^TWII)	D(^SSE180), D(^STI), D(LTC)	D(^TWII)
D(159903.SZ)	D(^KLSE)	
D(BTC)	D(159903_SZ), D(^FTSE), D(^N100), D(^N225), D(^TWII), D(LTC), D(XRP)	D(^AXAT), D(FNCMX), D(TA35.TA)
D(DAX)	D(159903_SZ), D(^AXAT), D(^BSESN), D(^FTSE), D(^KLSE), D(^N225), D(^NSEI), D(^MOEX_ME), D(^SEJO)	D(^MERV)
D(FNCMX)	D(159903_SZ), D(^AXAT), D(^BSESN), D(^FTSE), D(^KLSE), D(^KS11), D(^MERV), D(^N225), D(^NSEI), D(^SSE180), D(^SSMI), D(^STI), D(^TWII), D(^MOEX_ME), D(TA35.TA)	
D(IBOV)	D(159903_SZ), D(^BSESN), D(^FTSE), D(^HSI), D(^KLSE), D(^KS11), D(^N225), D(^NSEI), D(^SSE180), D(^SSMI), D(^STI), D(^TWII), D(^MOEX_ME), D(^SEJO)	D(^MERV)
D(MOEX_ME)	D(^AXAT), D(^HSI), D(^KLSE), D(^KS11), D(^N225), D(^SSE180), D(^STI), D(^TWII)	D(159903_SZ)
D(JSE_JO)	D(^KLSE), D(^KS11), D(^STI), D(^TWII), D(^MOEX_ME)	
D(LTC)	D(^AXAT)	
D(TA35.TA)	D(159903_SZ), D(^AXAT), D(^HSI), D(^KLSE), D(^KS11), D(^N225), D(^SSE180), D(^STI), D(^TWII)	D(^MERV)
D(XRP)	D(^STI), D(^TWII), D(TA35.TA)	D(159903_SZ), D(^N225), D(^SSMI), D(DAX)

H0: series "A" not Granger causes series "B"; H1: series "A" Granger causes series "B"

Source Authors

Null hypothesis	Significance at 5%	Significance at 10%
D(^AXAT)		D(^SSMI), D(IBOV)
D(^FTSE)	D(^N225), D(^TWII)	
D(^HSI)	D(^MERV), D(^TWII), D(^DAX)	D(FNCMX)
D(^KS11)	D(^TWII), D(DAX)	
D(^MERV)	D(^HSI), D(^TWII)	D(^IMOEX_ME)
D(^N100)	D(^TWII), D(DAX)	D(FNCMX)
D(^N225)	D(^FTSE), D(^SSMI), D(^STI)	
D(^SSE180)	D(DAX)	
D(^SSMI)	D(^AXAT), D(^N225), D(^TWII), D(DAX)	
D(^STI)	D(LTC)	D(^N225), D(DAX)
D(^TWII)	D(^HSI), D(^KS11), D(^SSMI)	D(^FTSE), D(^MERV), D(^N100), D(DAX)
D(DAX)	D(^HSI), D(^KS11), D(^N100), D(^SSE180), D(FNCMX) D(^SSMI), D(^STI), D(^TWII), D(TA35.TA)	
D(FNCMX)	D(^HSI), D(^N100), D(DAX)	
D(IBOV)	D(^AXAT)	
D(IMOEX.ME)		D(^MERV)
D(LTC)	D(XRP)	D(^STI)
D(TA35.TA)	D(DAX)	
D(XRP)	D(LTC)	

H0: series "A" not Granger causes series "B"; H1: series "A" Granger causes series "B"

Source Authors

Table 4 Definition of the VAR model's number of lags

Lag	LR	AIC	SC	HQ
0	NA	205.1460	205.2745*	205.1951*
1	1522.950	204.6832*	207.8961	205.9108
2	812.3149	205.0099	211.3072	207.4160
3	733.1955	205.4047	214.7864	208.9893
4	758.9702	205.7405	218.2066	210.5037
5	656.2346	206.1795	221.7299	212.1211
6	770.6995	206.4389	225.0738	213.5591
7	711.6388	206.7458	228.4650	215.0445
8	722.8997*	207.0032	231.8068	216.4804

*Indicates the lag order selected by the criterion; LR is the statistics of the modified sequential LR test; AIC—Akaike information criterion; SC—Schwarz information criterion; HQ—Hannan-Quinn information criterion

Source Authors

JSE.JO → IBOV → ^MERV → 159903.SZ → BTC → FNCMX → XRP → DAX → ^BSE SN → LTC → ^NSEI → ^N100 → ^FTSE → TA35.TA → ^SSE180 → IMOEX.ME → ^SSM I → ^KS11 → ^STI → ^HSI → ^KLSE → ^TWII → ^AXAT → ^N225.

Table 5 Total Granger *Causality/Block Exogeneity Wald* test result

Dependent	λ^2	Probability	Dependent	λ^2	Probability
^AXAT	322.0566	p < 0.0001	^STI	214.8718	p < 0.0001
^BSESN	88.17974	0.0002	^TWII	313.5696	0.2866
^FTSE	97.09081	p < 0.0001	159903.SZ	69.60568	0.0139
^HSI	216.4616	p < 0.0001	BTC	70.16162	0.8866
^KLSE	221.9182	p < 0.0001	DAX	79.16332	0.0017
^KS11	197.4580	p < 0.0001	FNCMX	72.63032	0.0074
^MERV	60.48983	0.0744	IBOV	60.41297	0.0753
^N100	94.33154	p < 0.0001	IMOEX.ME	104.0489	p < 0.0001
^N225	421.1590	p < 0.0001	JSE.JO	55.64311	0.1560
^NSEI	94.10825	p < 0.0001	LTC	93.77641	p < 0.0001
^SSE180	103.0279	p < 0.0001	TA35.TA	97.49737	p < 0.0001
^SSMI	123.5782	p < 0.0001	XRP	73.19985	0.0065

Source Authors

The ordering allows classifying the series to generate the IRF and the decomposition of the variance on the forecast error. The Trace and Maximum Eigenvalue Tests for the series at the level did not indicate cointegration, but in the first difference, in which the series are all stationary, the tests indicated 12 cointegrations.

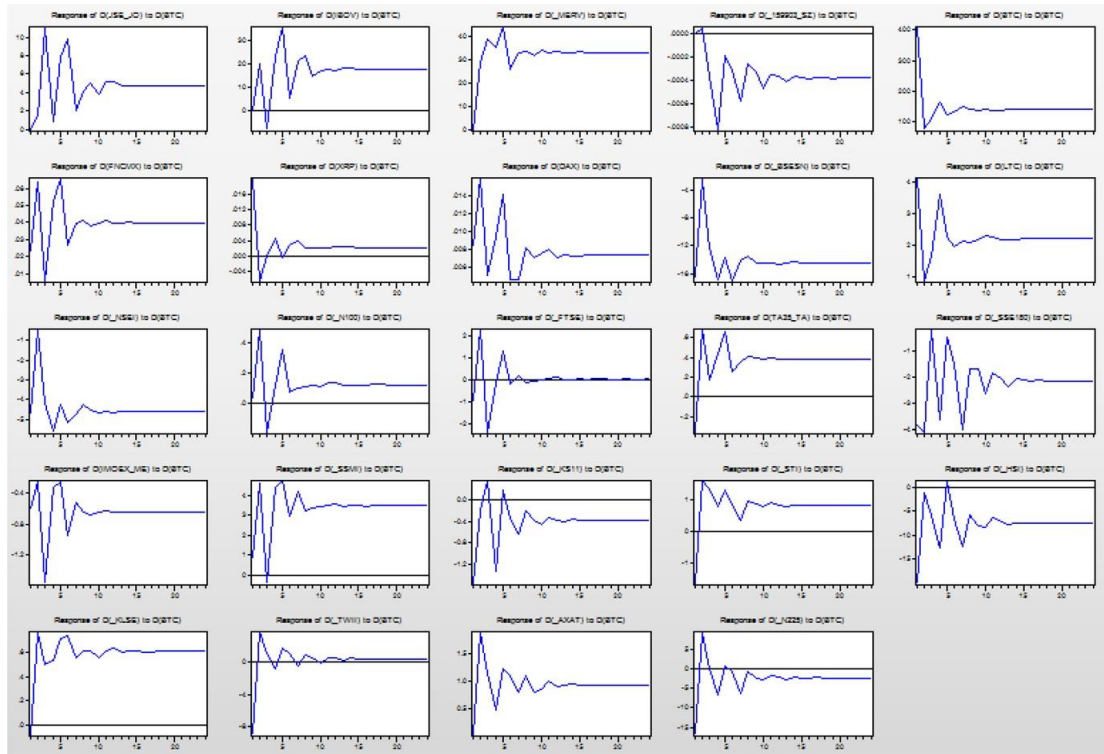
The degree of estimated adjustment of the error correction terms is identified by CointEq from one to twelve, which indicate the speed at which the short-term imbalance converges to 5% of significance. The twelve cointegration equations indicate the discrepancy between the effective and long-term balance values, corrected each period by the vectors. These cointegrating vectors are also capable of presenting the variables' speed of adjustment by the coefficient, the lower it is the lower the adjustment speed, so the shortterm correction is slow to cointegrating balance.

Observing the cryptocurrencies coefficients, these are varied, which indicates that in moments of system's unbalance the adjustment towards long-term balance will be shapeless. Other interpretations of the VEC are compromised due to the excessive number of parameters. To reduce the deficiency imposed by this restriction, IRF and the decomposition of variance for the cryptocurrencies series are used, since the purpose is to verify the relationship between the cryptocurrencies and the Stock Exchanges.

The IRF, used to explain the VEC model, graphically presents the reflex related to the application of a "shock" or an "innovation" in one of the series, which consists in the application of a standard deviation over the cryptocurrencies series to verify the reflexes in all the system series. The series must follow the order from the most exogenous to the most endogenous so that no distortion in the results occurs. Figure 2 shows the graphics referring to Bitcoin cryptocurrency:

Figure 2 should be read from right to left and from top to bottom, the graphics' sequence goes from the most exogenous to the most endogenous series. The observation period is twenty-four periods with the stationary series with one difference. It can be observed that after the Bitcoin shock is applied, the other system's series present a variation that lasts for at least ten periods.

It is possible to identify four distinct behaviors for the graphic answers of Fig. 2. The first group, formed by the series JSE.JO, IBOV, FNCMX, DAX, ^BSESN, ^NSEI, ^N100,



Order: JSE.JO, IBOV, ^MERV, 159903.SZ, BTC, FNCMX, XRP, DAX, ^BSESN, LTC, ^NSEI, ^N100, ^FTSE, TA35.TA, ^SSE180, IMOEX.ME, ^SSMI, ^KS11, ^STI, ^HSI, ^KLSE, ^TWII, ^AXAT, ^N225.

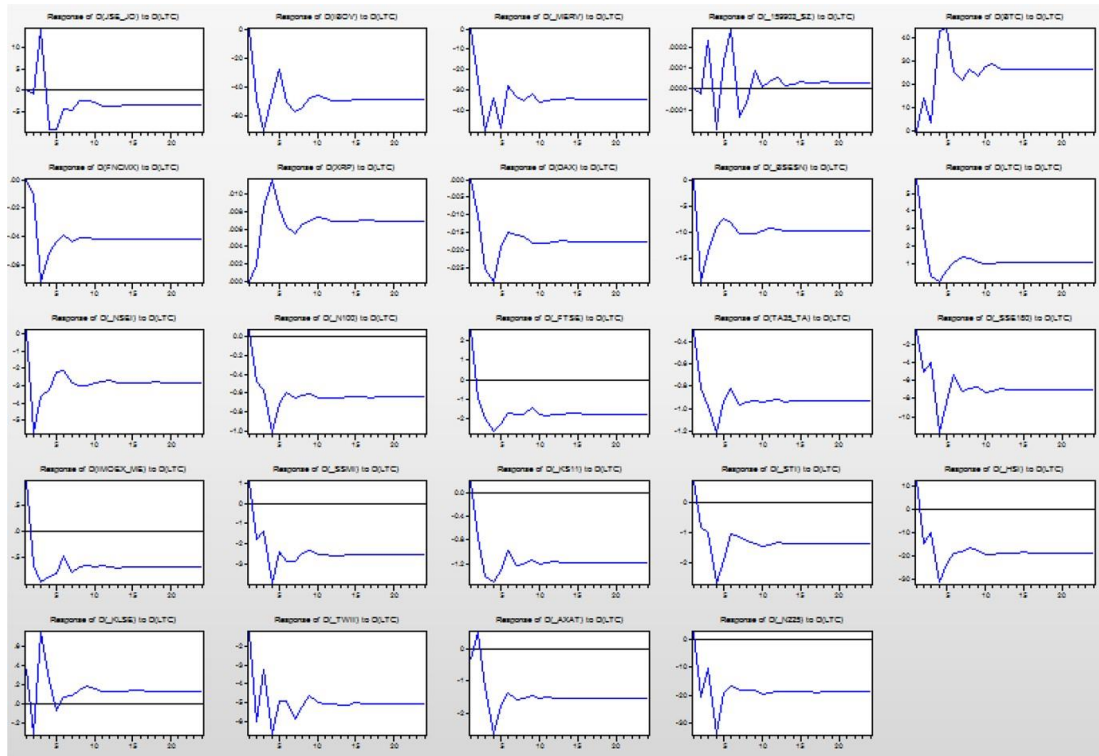
Fig. 2 IRF of the Stock Exchanges for shock in Bitcoin cryptocurrency

^FTSE, IMOEX. ME, ^SSMI, ^KS11, ^HSI, ^AXAT, ^N225, after the shock applied to the BTC, returns with a positive impulse followed by others negative, positive, and negative oscillating until, at most, the fifteenth period when it returns to balance. The second group is formed by BTC, ^KLSE, ^TWII, and ^SSE180, which responds with a negative impulse, i.e., in decline, another positive starts to oscillate for some periods until stability. In the third group, the series ^MERV, LTC, TA35.TA, and ^STI, suffer a positive impulse, oscillate, and enter in balance. The fourth group, 159903.SZ and XRP, have a negative, positive, negative impulse followed by a milder oscillation and enter into balance.

It is evident that with a shock to the BTC, the other system series oscillate for at least ten periods, as shown in Fig. 2. The same procedure was applied for the LTC series, the answers found are presented in Fig. 3.

The application of a shock to LTC was able to generate different behaviors in the series, these were divided into five groups. In the first group the JSE.JO, XRP, and ^AXAT series receive a positive impulse followed by a negative one, slight oscillations up to the fifteenth period, and enter into balance. The second group is formed by the series FNCMX, DAX, ^BSESN, LTC, ^NSEI, ^N100, ^FTSE, IMOEX.ME, ^SSMI, ^KS11, ^STI, ^HSI, and ^N225, which respond with a negative impulse followed by a positive oscillation and balance around the fifteenth period. In the third group the IBOV, TA35.TA, ^SSE180, and ^KLSE series, these receive a negative impulse followed by others positive and negative, they begin to oscillate until they return to balance.

The other two groups present more oscillations than the previous ones, the fourth group, ^MERV and ^TWII, interpose two negative and two positive impulses followed



Order: JSE.JO, IBOV, ^MERV, 159903.SZ, BTC, FNCMX, XRP, DAX, ^BSESN, LTC, ^NSEI, ^N100, ^FTSE, TA35.TA, ^SSE180, IMOEX.ME, ^SSMI, ^KS11, ^STI, ^HSI, ^KLSE, ^TWII, ^AXAT, ^N225.

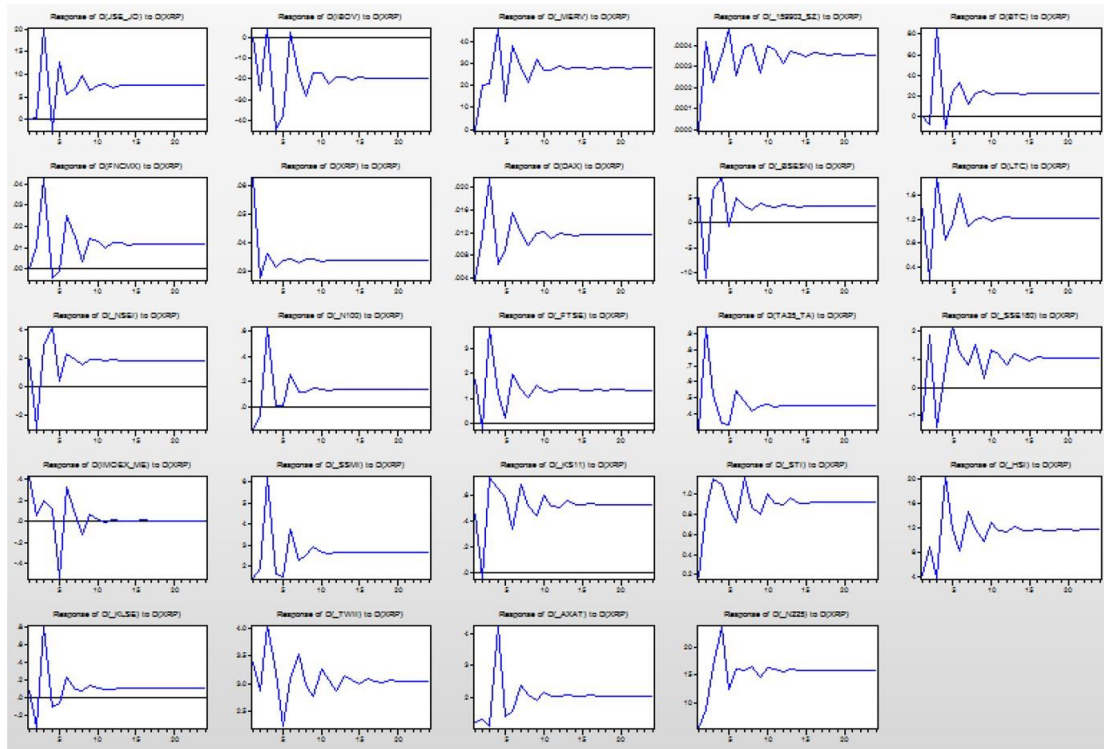
Fig. 3 IRF of the Stock Exchanges for shock in Litecoin cryptocurrency

by oscillation and balance. The fifth group, 159903.SZ and BTC, the response is opposite, two positive and two negative impulses are interposed. All the variations presented indicate that changes in the LTC cause changes in the other system series. Figure 4 presents the results of the same methodological procedure for the XRP cryptocurrency.

The IRF applied to XRP indicated four distinct behaviors in the system, according to Fig. 4, the first group formed by JSE.JO, ^MERV, 159903.SZ, BTC, FNCMX, DAX, ^N100, TA35.TA, and ^N225, responded with a positive impulse followed by a negative one, oscillations, and return to balance near the fifteenth period. The second group, composed of XRP and ^KLSE, present the opposite response to the first group with a negative impulse, a positive one, oscillations until balance.

The other two groups responded with four major impulses before oscillation and balance. In the third group, the IBOV, ^BSESN, LTC, ^NSEI, ^FTSE, IMOEX.ME, ^KS11, ^TWII, and ^AXAT series presented two negative impulses alternated with two positive impulses, oscillation, and balance. And the fifth group, ^SSE180, ^SSMI, ^STI, ^HSI, presented the opposite behavior to the third group, two positive impulses interspersed with two negative ones. In the same way as previous analyses, the shock applied to XRP modifies the behavior of the other series, thus it is evident that shocks in the cryptocurrencies generate different types of reflexes in the other series, however all are modified. It is possible to generate graphics for all the system's series, as there is the presence of cointegration the shocks applied in one of them will cause changes in the others.

Another option to assist the interpretation of the VEC model is the decomposition of variance, in which it is possible to obtain the effect of exogenous shocks applied to the



Order: JSEJO, IBOV, ^MERV, 159903.SZ, BTC, FNCMX, XRP, DAX, ^BESN, LTC, ^NSEI, ^N100, ^FTSE, TA35.TA, ^SSE180, IMOEX.ME, ^SSMI, ^KS11, ^STI, ^HSI, ^KLSE, ^TWII, ^AXAT, ^N225.

Fig. 4 IRF of the Stock Exchanges for ripple cryptocurrency shock

dependent variable at different moments of time. Table 6 contains some of the results of this test in periods one, six, twelve, and twenty-four for the Bitcoin series.

The results of the variance decomposition, in Table 6, show that Bitcoin has a self-explanatory power of 99.139% in the first period, 0.4860% of Bitcoin is explained by the 159903.SZ series representing the Shenzhen Stock Exchange of China, 0.2523% is explained by ^MERV, Buenos Aires Stock Exchange and so on. In the sixth period Bitcoin's power of self-explanation falls to 80.602%, 77.28% in twelve periods, and 74.797% in twenty-four periods. The fall in self-explanation over time increases the percentages of explanation by the other system's series. The other cryptocurrencies that initially do not have the capacity to explain Bitcoin, in twenty-four periods, began to explain 2.2299% to Ripple and 2.1375% to Litecoin. In addition to the cryptocurrencies, nineteen other series now explain Bitcoin with the increase in the number of periods. The same analysis can be verified in Table 7, but for Litecoin cryptocurrency.

According to Table 7, Litecoin's self-explanatory power is lower than Bitcoin, still in the first period, as it is 63.855%. Another distinctive characteristic between the two cryptocurrencies is the number of Stock Exchanges that have the power to explain Litecoin, which add up to nine series, still in the first period, of which Bitcoin is included, which explains 32.374% of Litecoin and another 3.6078% are explained by Ripple. Both cryptocurrencies increase the power of explanation to 46.821% and 13.117% in twentyfour periods, which reduces the series' self-explanation to 22.626%. Among the Stock Exchanges the one that has the greatest power of explanation is ^SSMI, Switzerland,

Table 6 Analysis of bitcoin variance decomposition

Period	Error	JSE.JO	IBOV	^MERV	159903.SZ	BTC	FNCMX	XRP	DAX	^BSESN	LTC	^NSEI	^N100
1	243.77	0.0197	0.1030	0.2523	0.4860	99.139	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
6	327.71	0.3002	0.2579	1.0982	1.0669	80.602	0.0858	3.0157	0.1071	0.8493	1.5300	1.2034	0.0905
12	408.05	0.3462	0.3437	1.4635	1.3091	77.287	0.1242	2.5305	0.0695	1.0266	1.8333	1.5139	0.0729
24	532.98	0.3985	0.4123	1.7273	1.4889	74.797	0.1459	2.2299	0.0414	1.1554	2.1375	1.7005	0.0532
Period	^FTSE	TA35.TA	^SSE180	IMOEX.ME	^SSMI	^KSI1	^STI	^HSI	^KLSE	^TWII	^AXAT	^N225	Total
1	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	100.00
6	0.1048	0.2768	0.1269	0.6924	3.6993	0.1270	1.4205	0.4873	1.3693	0.9164	0.3788	0.1931	100.00
12	0.1202	0.3060	0.0826	0.8929	4.6957	0.1021	1.9229	0.4943	1.7499	1.2059	0.3778	0.1260	100.00
24	0.1351	0.3529	0.0491	1.0449	5.4264	0.0776	2.2655	0.5009	2.0530	1.3418	0.3881	0.0769	100.00

Cholesky Ordering: JSE.JO, IBOV, ^MERV, 159903.SZ, BTC, FNCMX, XRP, DAX, ^BSESN, LTC, ^NSEI, ^N100, ^FTSE, TA35.TA, ^SSE180, IMOEX.ME, ^SSMI, ^KSI1, ^STI, ^HSI, ^KLSE, ^TWII, ^AXAT, ^N225

Table 7 Analysis of the decomposition of variance in litecoin

Period	Error	JSE.JO	IBOV	^MERV	159903.SZ	BTC	FNCMX	XRP	DAX	^BSESN	LTC	^NSEI	^N100
1	243.77	0.0004	0.0641	0.0248	0.0116	32.374	0.0026	3.6078	0.0530	0.0072	63.855	0.0000	0.0000
6	327.71	0.2242	0.0884	0.1627	0.0201	39.973	0.1443	9.4883	0.1154	0.1175	38.996	0.6248	0.4107
12	408.05	0.2824	0.0640	0.1124	0.0155	43.621	0.1051	11.365	0.1671	0.0930	30.053	0.9567	0.4700
24	532.98	0.3134	0.0432	0.0674	0.0098	46.821	0.0626	13.117	0.2037	0.0694	22.626	1.1587	0.4923
Period	^FTSE	TA35.TA	^SSE180	IMOEX.ME	^SSMI	^KS11	^STI	^HSI	^KLSE	^TWII	^AXAT	^N225	Total
1	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	100.00
6	0.2604	1.7681	1.7841	0.1745	2.3314	0.1904	0.8463	0.1999	1.3539	0.2635	0.1750	0.2867	100.00
12	0.2923	2.0811	2.2594	0.2009	3.6033	0.1385	1.1466	0.2342	1.9868	0.2278	0.1540	0.3695	100.00
24	0.3164	2.3936	2.6884	0.1995	4.4871	0.0846	1.3576	0.2599	2.5033	0.1517	0.1447	0.4286	100.00

Cholesky Ordering: JSE.JO, IBOV, ^MERV, 159903.SZ, BTC, FNCMX, XRP, DAX, ^BSESN, LTC, ^NSEI, ^N100, ^FTSE, TA35.TA, ^SSE180, IMOEX.ME, ^SSMI, ^KS11, ^STI, ^HSI, ^KLSE, ^TWII, ^AXAT, ^N225

which reaches 4.4871% in the last period presented. Table 8 indicates the results of variance decomposition for the Ripple.

Ripple, according to Table 8, has a self-explanatory power of 90.485% in the first period and reduces to 89.307% in the 24th period. Bitcoin explains 9.1971% in the first period and reduces the percentage of explanation over time, reaching 1.7262% in the 24th period. Litecoin has not the explanation capacity of Ripple in the first period and it passes to 3.0411% in the sixth period and to 3.5606% in the last period. In this cryptocurrency the distribution of the explanation percentages by the Stock Exchanges are more balanced.

In this study, Tables 6, 7, and 8 were presented with the decompositions of variance of cryptocurrencies. However, the repetition of this procedure is up to all the system's series, so the test was carried out for all the series and the answers indicated the modification of the tested series in the face of modifications of a shock in the Stock Exchanges.

According to the results presented in this item, all the series in the system are stationary in first differences. Granger's causality shows the relationships between all the series, whether they are one- or two-dimensional.

The existence of these relationships between the variables indicates that external shocks in cryptocurrencies will be transferred to stock exchange indexes in the short and medium term. The application of the VAR model showed the short-term relationship between the system variables and the Johansen cointegration test indicated cointegration between them. The ordering of the series indicates that among the cryptocurrencies Bitcoin is the fifth most exogenous, most representative, followed by Ripple, the seventh, and Litecoin the tenth most exogenous. The short-term relationship between the variables is evidenced, in this way variations in one of the series will cause variations in the others in the short term.

Thus, the VEC model was estimated, which had the normality of the residues proved by the unitary circle of polynomial inverse roots. IRF and the decomposition of variance in the cryptocurrencies series were applied to help explain the VEC, so it was possible to verify which system's series are affected by the application of a shock in the system and the percentages of participation in the system. The VEC results indicate the long-term relationship between the series, shocks applied to cryptocurrencies will be transmitted to the Stock Exchanges in the long term, causing a change in the traditional market.

The results of the study by Panagiotidis et al. (2019) agree with those of this study, as they indicated significant interaction between Bitcoin and the stock market, weak interaction with foreign exchange markets and macroeconomics, and a weak importance of popularity measures. Interaction has increased between Asian markets and Bitcoin compared to other markets, but has declined in the past two years after regulatory interventions by China and the CNY contraction in Bitcoin trading volume. Alternative VAR and VAR with increased factor (FAVAR), factor analysis and principal component (PC) were used to verify the magnitude of the effects that the European, US and China-Japan markets have on Bitcoin returns.

Kurka (2019) studied the asymmetric shock transmission mechanisms among the most liquid representatives of traditional asset classes, such as commodities, foreign exchange, financial stocks and cryptocurrencies (Bitcoin). By applying the volatility spillovers framework developed it was identified that the unconditional connection between cryptocurrencies and traditional assets is negligible. Conditional analysis reveals substantial shock transmission periods between Bitcoin and traditional assets. The results of the studies cited agree with those found in this study, however the difference presented is the long-term relationship evidenced by the VEC model between the indices of the twenty-one stock exchanges and the three cryptocurrencies.

Table 8 Analysis of ripple variance decomposition

Period	Error	JSE.JO	IBOV	^MERV	159903.SZ	BTC	FNCMX	XRP	DAX	^BSESN	LTC	^NSEI	^N100
1	243.77	0.0187	0.1649	0.0605	0.0579	9.1971	0.0155	90.485	0.0000	0.0000	0.0000	0.0000	0.0000
6	327.71	0.0431	0.1269	0.8568	0.2438	4.4257	0.0635	87.734	0.1191	0.0340	3.0411	0.5569	0.1829
12	408.05	0.0261	0.0853	1.1276	0.2801	2.8083	0.0377	88.718	0.1155	0.0297	3.3129	0.6150	0.2024
24	532.97	0.0144	0.0577	1.2996	0.3035	1.7262	0.0207	89.307	0.1118	0.0260	3.5606	0.6765	0.2161
Period	^FTSE	TA35.TA	^SSE180	IMOEX.ME	^SSMI	^KS11	^STI	^HSI	^KLSE	^TWII	^AXAT	^N225	Total
1	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	100.00
6	0.0117	0.1562	0.0600	0.2039	0.2872	0.1087	0.2237	0.1668	0.4580	0.0397	0.2584	0.5951	100.00
12	0.0087	0.1389	0.0474	0.1992	0.2630	0.0865	0.2060	0.1392	0.5534	0.0476	0.3405	0.6103	100.00
24	0.0058	0.1312	0.0387	0.1956	0.2462	0.0689	0.1835	0.1246	0.6251	0.0524	0.3833	0.6238	100.00

Cholesky Ordering: JSE.JO, IBOV, ^MERV, 159903.SZ, BTC, FNCMX, XRP, DAX, ^BSESN, LTC, ^NSEI, ^N100, ^FTSE, TA35.TA, ^SSE180, IMOEX.ME, ^SSMI, ^KS11, ^STI, ^HSI, ^KLSE, ^TWII, ^AXAT, ^N225

FINAL CONSIDERATIONS

The application of the tests described in the methodology indicated the short and longterm relationship between the system's component series, i.e., the cryptocurrencies have the capacity to influence the indicators of the Stock Exchanges selected for the study. The objective of the study was to contribute to the academy and to society, since understanding the effects that a variable has on the system helps to monitor and understand the possible results in advance, expanding the competence of decision making and preparation for possible reflexes.

Cryptocurrencies are recent in the market, compared to Stock Exchanges, it took about three years to consolidate, but they indicate power to modify traditional forms of trading. The existence of a short-term relationship can be evidenced by the result of Granger's causality test, in which all series have a relationship, either one or two-dimensional in up to 10% significance. Variations in cryptocurrencies are transferred to the traditional economy in the short term, this information is important given the volume of cryptocurrencies that are currently traded and after an external shock, on average, the time to return to stability is 15 months, a period that commodities and others financial markets can be wary of and anticipate market fluctuations.

The long-term relationship was demonstrated by the result of the VEC model and the interpretations of the IRF and the decomposition of variance. The application of these two tests facilitated the identification of how much the Stock Exchanges series help to explain the cryptocurrencies series, as well as the possibility that cryptocurrencies have to influence the Stock Exchanges, through the application of a shock and its reflexes on the system's series. The Bitcoin cryptocurrency, after the shock's application, indicated to influence the Stock Exchanges for an average time of 16 periods, Litecoin for 15 periods, and Ripple for 16 periods. The time evaluated was 24 periods and proved to be sufficient for the study's definition.

It is worth mentioning that the Shenzhen Stock Exchange of China, among those evaluated, is the one that takes the longest time to resume balance for shocks applied in cryptocurrencies, around 20 periods, besides this one there are others that return to balance around the same period: for Bitcoin the London Stock Exchange, for Litecoin the India Stock Exchange, and for Ripple the Buenos Aires Stock Exchange of Argentina. After the application of a shock the ones that presented a faster return to balance, around 11 periods, were: for Bitcoin the Moex Stock Exchange of Russia, Litecoin the Nasdaq of the United States, and Ripple the Swiss and Tel Aviv's Stock Exchanges. The shock applied to Bitcoin generates the first positive impact for the majority of the Exchanges in the system, for Litecoin the first impact is negative for the majority of the Exchanges, and for Ripple it has balanced positive and negative responses for the series representing the Exchanges.

For future studies it is suggested the application of other analysis and comparison methodologies for data from Stock Exchanges and Cryptocurrencies. The limitations faced in the study's development were the inexistence of indexes disclosure of some Stock Exchanges, as well as the quantity of observations of the series under study, 905 observations, due to the total limit of observations that can be analyzed concomitantly in the version of Eviews 10SV *software*.

Supplementary Information The online version contains supplementary material available at <https://doi.org/10.1007/s11135-022-01356-2>.

Author contributions All authors contributed to the study conception and design. Material preparation, data collection and analysis were performed by Viviane de Senna and Adriano Mendonça Souza.

Funding This research receive funding in the UFSM for providing language help.

Availability of data and material The time series used in article are attachment.

Code availability Not applicable.

DECLARATIONS

Conflict of interest There is no conflict of interest. The authors have no financial or proprietary interests in any material discussed in this article.

Consent to participate The authors read and approved the final manuscript.

Consent for publication The authors approved the publication.

Ethics approval Not applicable.

Research involved in humans and/or animals Not applicable.

REFERENCES

- Agung, I.G.N.: Time Series Data Analysis Using EViews. John Wiley & Sons, Ltd., Chichester (2010).
<https://doi.org/10.1002/9780470823699>
- Akaike, H.: A new look at the statistical model identification. *IEEE Trans. Autom. Control* **19**(6), 716–723 (1974). <https://doi.org/10.1109/TAC.1974.1100705>
- Baur, D.G., Hong, K., Lee, A.D.: Bitcoin: medium of exchange or speculative assets? *J. Int. Financ. Mark. Inst. Money* **54**(May), 177–189 (2018). <https://doi.org/10.1016/j.intfin.2017.12.004>
- Begušić, S., Kostanjčar, Z.: Momentum and Liquidity in Cryptocurrencies. April (2019). <http://arxiv.org/abs/1904.00890>.
- Bhullar, P.S., Bhatnagar, D.: Bitcoins as a determinant of stock market movements: a comparison of Indian and chinese stock markets. *Dir. Open Access J.* (2020). <https://doaj.org/article/a919b24ffb394c02a7c788b32448e46c>.
- Brooks, C.: *Introductory Econometrics for Finance*. Cambridge University Press, Cambridge (2008)
- Chatterjee, J.M., Son, L.H., Ghatak, S., Kumar, R., Khari, M.: BitCoin exclusively informational money: a valuable review from 2010 to 2017. *Qual. Quant.* **52**(5), 2037–2054 (2018). <https://doi.org/10.1007/s11135-017-0605-5>
- de Senna, V., Souza, A.M.: Assessment of the relationship of government spending on social assistance programs with Brazilian macroeconomic variables. *Physica A* **462**(November), 21–30 (2016). <https://doi.org/10.1016/j.physa.2016.05.022>
- Dickey, D.A., Fuller, W.A.: Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica* **49**(4), 1057 (1981). <https://doi.org/10.2307/1912517>
- Enders, W.: *Applied Econometric Time Series*. (2014). <https://doi.org/978-1-118-80856-6>.
- Engle, R.F., Granger, C.W.J.: Co-integration and error correction: representation, estimation, and testing. *Econometrica* **55**(2), 251 (1987). <https://doi.org/10.2307/1913236>
- Granger, C.W.J.: Developments in the study of cointegrated economic variables. *Oxford Bull. Econ. Stat.* **48**(3), 213–228 (1986). <https://doi.org/10.1111/j.1468-0084.1986.mp48003002.x>
- Granger, C.W.J., Huangb, B.-N., Yang, C.-W.: A bivariate causality between stock prices and exchange rates: evidence from recent Asian flu ☆. *Q. Rev. Econ. Financ.* **40**(3), 337–354 (2000). [https://doi.org/10.1016/S1062-9769\(00\)00042-9](https://doi.org/10.1016/S1062-9769(00)00042-9)
- Hannan, E.J., Quinn, B.G.: The determination of the order of an autoregression. *J. r. Stat. Soc.: Ser. B (Methodol.)* **41**(2), 190–195 (1979). <https://doi.org/10.1111/j.2517-6161.1979.tb01072.x>
- Johansen, S.: Statistical analysis of cointegration vectors. *J. Econ. Dyn. Control* **12**(2–3), 231–254 (1988).
[https://doi.org/10.1016/0165-1889\(88\)90041-3](https://doi.org/10.1016/0165-1889(88)90041-3)
- Kennedy, A.B.W., Sankey, H.R.: The thermal efficiency of steam engines. report of the committee appointed to the council upon the subject of the definition of a standard or standards of thermal efficiency for steam engines: with an introductory note.

- (including appendixes and plate at back of volume). *Min. Proc. Inst. Civ. Eng.* **134**, 278–312 (1898). [https:// doi. org/ 10. 1680/ imotp. 1898. 19100](https://doi.org/10.1680/imotp.1898.19100)
- Klein, T., Thu, H.P., Walther, T.: Bitcoin is not the new gold—a comparison of volatility, correlation, and portfolio performance. *Int. Rev. Financ. Anal.* **59**(October), 105–116 (2018). [https:// doi. org/ 10. 1016/j. irfa. 2018. 07. 010](https://doi.org/10.1016/j.irfa.2018.07.010)
- Kostika, E., Laopodis, N.T.: Dynamic linkages among cryptocurrencies, exchange rates and global equity markets. *Stud. Econ. Financ.* **37**(2), 243–265 (2019). [https:// doi. org/ 10. 1108/ SEF- 01- 2019- 0032](https://doi.org/10.1108/SEF-01-2019-0032)
- Kurka, J.: Do cryptocurrencies and traditional asset classes influence each other? *Financ. Res. Lett.* **31**(December), 38–46 (2019). [https:// doi. org/ 10. 1016/j. frl. 2019. 04. 018](https://doi.org/10.1016/j.frl.2019.04.018)
- Kwiatkowski, D., Phillips, P.C.B., Schmidt, P., Shin, Y.: Testing the null hypothesis of stationarity against the alternative of a unit root. *J. Econom.* **54**(1–3), 159–178 (1992). [https:// doi. org/ 10. 1016/ 0304- 4076\(92\) 90104- Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Le, T.-L., Abakah, E.J.A., Tiwari, A.K.: Time and frequency domain connectedness and spill-over among fintech, green bonds and cryptocurrencies in the age of the fourth industrial revolution. *Technol. Forecast. Soc. Chang.* **162**(January), 120382 (2021). [https:// doi. org/ 10. 1016/j. techf ore. 2020. 120382](https://doi.org/10.1016/j.techfore.2020.120382)
- Miraz, M.H., Ali, M.: Applications of blockchain technology beyond cryptocurrency. *Ann. Emerg. Technol. Comput.* **2**(1), 1–6 (2018). [https:// doi. org/ 10. 33166/ aetic. 2018. 01. 001](https://doi.org/10.33166/aetic.2018.01.001)
- Nakamoto, S.: Bitcoin: A Peer-to-Peer Electronic Cash System (2008). [www. bitco in. org](http://www.bitcoin.org).
- Nazifi, A., Murdy, S., Marder, B., Gäthke, J., Shabani, B.: A bit(coin) of happiness after a failure: an empirical examination of the effectiveness of cryptocurrencies as an innovative recovery tool. *J. Bus. Res.* **124**, 494–505 (2021). [https:// doi. org/ 10. 1016/j. jbusr es. 2020. 11. 012](https://doi.org/10.1016/j.jbusres.2020.11.012)
- Olaiwola, S., Jimoh, B., Olawale, O.: The effect of cryptocurrency returns volatility on stock prices and exchange rate returns volatility in Nigeria | Directory of Open Access Journals. *Acta Universitatis Danubius* **16**(3), 200–213 (2020). [https:// doaj. org/ artic le/ 3afc1 a8953 17415 ab0fe abb6d 64ae2 dc](https://doi.org/10.31632/acta.univ.danubius.16.3.200-213)
- Panagiotidis, T., Stengos, T., Vravosinos, O.: The effects of markets, uncertainty and search intensity on bitcoin returns. *Int. Rev. Financ. Anal.* **63**(May), 220–242 (2019). [https:// doi. org/ 10. 1016/j. irfa. 2018. 11. 002](https://doi.org/10.1016/j.irfa.2018.11.002)
- Park, S., Park, H.W.: Diffusion of cryptocurrencies: web traffic and social network attributes as indicators of cryptocurrency performance. *Qual. Quant.* **54**(1), 297–314 (2020). [https:// doi. org/ 10. 1007/ s11135- 019- 00840- 6](https://doi.org/10.1007/s11135-019-00840-6)
- Phillips, P.C.B., Perron, P.: Testing for a unit root in time series regression. *Biometrika* **75**(2), 335–346 (1988). [https:// doi. org/ 10. 1093/ biomet/ 75.2. 335](https://doi.org/10.1093/biomet/75.2.335)
- Poyser, O.: Exploring the dynamics of bitcoin’s price: a bayesian structural time series approach. *Eurasian Econ. Rev.* **9**(1), 29–60 (2019). [https:// doi. org/ 10. 1007/ s40822- 018- 0108- 2](https://doi.org/10.1007/s40822-018-0108-2)
- Ramachandran, G.S., Krishnamachari, B.: Blockchain for the IoT: Opportunities and challenges. May (2018). [arXiv:1805.02818v1](https://arxiv.org/abs/1805.02818v1).
- Schwarz, G.: Estimating the dimension of a model. *Ann. Stat.* (1978). [https:// doi. org/ 10. 1214/ aos/ 11763 44136](https://doi.org/10.1214/aos/1176344136)
- Sims, C.A.: Macroeconomics and reality. *Econometrica* (1980). [https:// doi. org/ 10. 2307/ 19120 17](https://doi.org/10.2307/1912017)

- Stosic, D., Stosic, D., Ludermir, T.B., Stosic, T.: Multifractal behavior of price and volume changes in the cryptocurrency market. *Physica A* **520**(April), 54–61 (2019). <https://doi.org/10.1016/j.physa.2018.12.038>
- Teh, B.K., Goo, Y.W., Lian, T.W., Ong, W.G., Choi, W.T., Damodaran, M., Cheong, S.A.: The Chinese correction of February 2007: how financial hierarchies change in a market crash. *Physica A* **424**(April), 225–241 (2015). <https://doi.org/10.1016/j.physa.2015.01.024>
- Uras, N., Marchesi, L., Marchesi, M., Tonelli, R.: Forecasting bitcoin closing price series using linear regression and neural networks models. *PeerJ Comput. Sci.* **6**(July), e279 (2020). <https://doi.org/10.7717/peerj-cs.279>
- Urquhart, A.: Price clustering in bitcoin. *Econ. Lett.* **159**(October), 145–148 (2017). <https://doi.org/10.1016/j.econl et.2017.07.035>
- White, R., Marinakis, Y., Islam, N., Walsh, S.: Is bitcoin a currency, a technology-based product, or something else? *Technol. Forecast. Soc. Chang.* **151**(February), 119877 (2020). <https://doi.org/10.1016/j.techf ore.2019.119877>

Publisher's Note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

6 ARTIGO 4 - INFLUÊNCIA DAS CRIPTOMOEDAS NAS BOLSAS DE VALORES GLOBAIS

Viviane de Senna, E-mail: vivianedsenna@hotmail.com
Adriano Mendonça Souza, E-mail: amsouza.sm@gmail.com

RESUMO

As criptomoedas são um desafio aos mercados de ativos tradicionais, por isso é importante compreender como esses ativos podem interferir no mercado. O objetivo deste estudo é analisar a influência de três criptomoedas em um conjunto de vinte e uma Bolsas de Valores, empregando a metodologia ARMAX como ferramenta analítica. As séries selecionadas são índices de 21 bolsas de valores de continentes distintos e três criptomoedas comercializadas no mercado, com periodicidade semanal da primeira semana de maio de 2013 até a última semana do mês de agosto de 2023. As séries dos índices das bolsas e das criptomoedas foram modeladas, partindo dos modelos ARIMA, ARIMAX, ARIMAX-ARCH, ARIMAX-GARCH. Além disso, as séries das criptomoedas foram inseridas nos modelos como exógenas. Em todas as séries a inserção das exógenas gerou melhoramento nos modelos comprovando que as criptomoedas podem interferir nos índices das Bolsas de valores, ou seja, mudanças que ocorram nesse tipo de ativo podem gerar interferência no mercado tradicional.

Palavras-chave: criptomoedas, bolsas de valores, ARMAX

1 INTRODUÇÃO

No mercado financeiro contemporâneo as criptomoedas estão desafiando as formas de negociações tradicionais, e é indispensável compreender como a modificação digital está impactando as Bolsas de Valores e, conseqüentemente a economia global. As diferenças mais marcantes entre ativos tradicionais e as criptomoedas são a forma de negociação, regulamentação e controle de transações. As criptomoedas são controladas pela tecnologia *blockchain* que permite o registro das transações em uma rede global de computadores, oferecendo autonomia aos usuários, mas também representando desafios de segurança e proteção.

O *blockchain* funciona como um livro de registro contábil digital, no qual todas as transações de criptomoedas são registradas, sendo públicas e imutáveis, o que pode aumentar a transparência e confiança no sistema. Esse ativo é disruptivo no mercado financeiro, pois sua característica transfronteiriça permite a realização de negociações a qualquer momento proporcionando flexibilidade aos investidores. No entanto, os preços das criptomoedas são altamente voláteis em curtos períodos, o que pode representar risco tanto para investidores quanto para o mercado em geral.

Intervenções expressivas em uma Bolsa de Valores podem desencadear problemas econômicos de larga escala. A venda maciça de ativos ou uma atividade capaz de causar alta volatilidade pode afetar não apenas investidores, mas também

sólidas instituições financeiras, fundos de investimentos e a economia em geral. A expansão do impacto tem potencial para gerar quedas nos preços das ações, o que, com o passar do tempo pode desencadear crises financeiras.

Com a finalidade de mitigar os riscos de crises e proteger o mercado econômico, rígidas regulamentações são empregadas por órgão regulamentadores, como os bancos centrais das nações. Essas regulamentações são empregadas para garantir a integridade e estabilidade das Bolsas de Valores, que são reconhecidas como balcões de negociações seguras e controladas. No entanto, as criptomoedas, que são monitoradas por índices, operam em redes descentralizadas, não estando vinculadas às Bolsas ou aos bancos centrais, e não possuem regulamentações, o que as torna novos tipos de ativos. Então, as regulamentações não são capazes de controlar ou restringir negociações que envolvam as criptomoedas, ou seja, as ações adotadas para os ativos tradicionais não podem ser utilizadas para controle desses ativos.

As Bolsas possuem índices, que funcionam como indicadores do desempenho geral em um determinado mercado de ações, monitorando e avaliando o comportamento dos preços das ações de um grupo de empresas listadas ao longo do tempo. Cada ação dentro do índice pode ter uma ponderação diferente, dependendo das regras do índice. Essas diferenças substanciais entre os ativos tradicionais e os novos geram a possibilidade de discussões e a necessidade de compreensão com relação ao problema: qual a influência das criptomoedas nos índices das Bolsas de Valores? **O objetivo deste estudo é analisar a influência de três criptomoedas em um conjunto de vinte e uma Bolsas de Valores, empregando a metodologia ARMAX como ferramenta analítica.**

Considerando a crescente utilização das criptomoedas no mercado financeiro e sua natureza descentralizada, a hipótese do estudo é que a presença e o desempenho das criptomoedas têm impacto nos índices das vinte e uma Bolsas de Valores analisadas. A adoção da metodologia ARMAX permitirá a identificação de padrões e relações causais entre as variáveis exógenas, criptomoedas, e as séries das Bolsas, contribuindo para uma compreensão mais aprofundada da dinâmica entre esses novos ativos e os tradicionais.

A modelagem ARMAX oferece algumas vantagens em comparação com outros modelos, como a capacidade de incorporar variáveis exógenas, que consideram fatores externos capazes de influenciar a série; ajustar modelos com padrões mais complexos para as previsões mais precisas; maior flexibilidade nas previsões em diferentes cenários; e auxiliar na análise da relação de causalidade entre uma série específica e as variáveis exógenas de interesse.

A diferenciação deste estudo consiste na análise detalhada da influência específica de três criptomoedas em um conjunto de Bolsas de Valores, utilizando a metodologia ARMAX como ferramenta analítica. Ao contrário de estudos anteriores que podem ter abordado a influência geral das criptomoedas nos mercados financeiros, este estudo se concentra em entender como esses ativos específicos podem afetar as bolsas de valores individuais em diferentes continentes. Além disso, o estudo se destaca pela extensão do período de análise, que abrange desde a primeira semana de maio de 2013 até a última semana do mês de agosto de 2023, permitindo uma visão abrangente das tendências ao longo do tempo.

Ao serem comparadas com o mercado representado pelas Bolsas de Valores, as criptomoedas podem ser consideradas novas, mas o expressivo volume de negociações que estão apresentando indica que sua presença no mercado tende a ser permanente. Entender como as criptomoedas podem influenciar o mercado, por meio de sua volatilidade e características distintivas, é importante, visto que essa compreensão pode auxiliar os reguladores dos mercados tradicionais na tomada de decisão, equilibrando inovação e segurança mercadológica.

A seleção das séries das Bolsas de Valores decorre da tentativa de verificar a existência de interferência das criptomoedas nos ativos tradicionais, em Bolsas distribuídas em diferentes regiões geográficas e com desempenhos distintos no mercado de ativos tradicionais. As séries das criptomoedas foram selecionadas com base no comportamento díspar com relação a aceitação e utilização pelos usuários, o que define maior ou menor valorização financeira.

Este estudo está estruturado com esta introdução, a metodologia, os resultados obtidos e as discussões realizadas, as considerações finais e, por fim, as referências utilizadas.

2 METODOLOGIA

As séries temporais selecionadas para desenvolver o estudo são os índices de vinte e uma Bolsas de Valores e três criptomoedas. As bolsas de valores foram selecionadas de acordo com a disponibilidade de séries, e para atingir a áreas geográficas e econômicas diferentes, e as criptomoedas por possuírem comportamentos distintos e aceitação mercadológica de investidores. A primeira seleção das séries foi feita considerando os valores diários para os dados, no entanto, não foram encontrados modelos adequados para as séries. Em função da alta volatilidade os modelos lineares

identificaram apenas passeios aleatórios. Para suavizar a volatilidade encontradas nas séries diárias dos índices foram selecionadas as mesmas séries, mas com a periodicidade semanal.

As séries foram coletadas novamente, em período compreendido entre a primeira semana de maio de 2013 até a última semana do mês de agosto de 2023, totalizando 539 observações semanais de cada. A seleção do período decorre da oportunidade de avaliar períodos de crises e recuperação e diferentes comportamentos dos índices relacionados as performances das Bolsas de Valores e criptomoedas.

Nas séries das criptomoedas, nos casos em que não foram encontrados registros semanais, foram efetuadas as médias entre os registros diários para complementar a paridade de observações, não excedendo dois por cento do total de observações coletadas. A coleta foi efetuada no site Yahoo Finanças (“Yahoo Finanças”, 2023) e as análises foram feitas com auxílio do *software* livre RStudio. As Criptomoedas em estudo são Bitcoin – BTC, Ripple – XRP e Litecoin – LTC e na Tabela 1 estão descritos os índices que representam as Bolsas de Valores que fazem parte do estudo.

Tabela 1 – Séries temporais das Bolsas de Valores utilizadas para a modelagem ARMAX

Código	Nome do Índice	Bolsa de Valores	País
159903.SZZ	China SZSE Component Index Fund/ETF	Shenzhen	China
AXAT	Austrália S&P/ASX ALL Australian 200	Austrália	Austrália
BSESN	Índia Bombay S&P BSE Sensex	Bombaim	Índia
DAX	Frankfurt Global X DAX Germany ETF	Frankfurt	Alemanha
IBOV	IBOVESPA	B3, Brasil Bolsa Balcão	Brasil
IMOEX.ME	MOEX Russia Index	Moscow	Rússia
JSE.JO	JSE Limited	Johannesburg	África do Sul
FNCMX	Fidelity NASDAQ Composite Index	Nasdaq	Estados Unidos
FTSE	London FTSE 100	Londres	Inglaterra
HSI	Hang Seng Index	Hong Kong	China
KLSE	FTSE Bursa Malaysia KLCI	Malásia	Malásia
KS11	Korea KOSPI Composite Index	Coreia do Sul	Coreia do Sul
MERV	MERVAL	Buenos Aires	Argentina
N100	EURONEXT 100	Paris	França
N225	Nikkei 225 Osaka	Tokyo	Japão
NSEI	Índia NIFTY 50	Índia	Índia
SSE180	SSE 180 Index	Shanghai	China
SSMI	Suíça SMI	Suíça	Suíça
STI	FTSE Straits Times Singapore	Cingapura	Singapura
TA35.TA	TA-35	Tel Aviv	Israel
TWII	FTSE MIB Index	Milão	Itália

Fonte: Autores (2023)

A Tabela 1 lista os índices, as Bolsas de Valores que eles representam e o país de origem. Em todas as 24 séries selecionadas foram aplicados os testes de estacionariedade, o teste de causalidade de Granger, foram ajustados os modelos ARIMA, e os modelos ARMAX.

2.1 Teste de estacionariedade das séries

A estacionariedade das séries é pré-requisito para o ajuste dos modelos ARIMA, pois ajudam a garantir que os modelos aplicados sejam apropriados e contribuam para previsões mais precisas. A série é considerada estacionária se sua variância é constante ao longo do tempo e a oscilação é em torno da média constante (MORETTIN, 2017). Os testes de raízes unitárias serão aplicados para verificar a estacionariedade da série, tais como o teste Augmented Dickey Fuller – ADF (DICKEY; FULLER, 1981), o teste não paramétrico de Phillips e Perron – PP (PHILLIPS; PERRON, 1988) e o teste Kwiatkowski, Phillips, Schmidt and Shin – KPSS (KWIATKOWSKI et al., 1992).

Quando uma série atende ao pressuposto de estacionariedade indica que há equilíbrio estatístico, ou seja, suas propriedades são constantes ao longo do tempo. A estacionariedade é uma condição para o ajuste dos modelos de vetores autorregressivos, para que sejam capazes de explicar as relações existentes entre as variáveis do conjunto (MORETTIN, 2017). Quando a estacionariedade não é atendida, podem ser aplicadas as técnicas de diferenciação e transformação logarítmica para tornar as séries mais apropriadas para a modelagem. A diferenciação ajuda a estabilizar a média da série, eliminando, ou reduzindo, tendências e sazonalidade e a transformação logarítmica ajuda a estabilizar a variância (HYNDMAN; ATHANASOPOULOS, 2018). Na transformação logarítmica, os valores originais da série são substituídos pelos logaritmos desses valores, o que estabiliza a variabilidade ao longo do tempo.

Para efetuar o teste de causalidade de Granger, o Modelo de Autorregressão Vetorial – VAR e os modelos lineares também é necessária a estacionariedade das séries, por isso as séries passaram por uma transformação logarítmica e por uma diferenciação, o teste será descrito no próximo tópico.

2.2 Causalidade de Granger

O teste de causalidade de Granger foi aplicado nas séries para verificar a existência de relação de causa uni ou bidirecional, pois nos casos em que as séries não possuam pelo menos uma das relações, não há motivo para a permanência no conjunto. A manutenção de uma série sem relação com o conjunto pode não afetar significativamente os resultados, mas é capaz de adicionar ruído e dificultar a identificação dos padrões do conjunto, bem como aumentar a complexidade do modelo sem contribuição para a precisão e levar a conclusões errôneas (MORETTIN, 2017).

O método se baseia em inferir se valores passados de uma variável auxiliam na previsão da outra (FERREIRA et al., 2018). O teste não informa a causalidade de forma literal, mas oferece evidências estatísticas de que oscilações acontecidas em uma variável estão correlacionadas com as de outra. A relação de causalidade entre duas ou mais séries indica a existência de relação entre as séries do sistema. O teste foi desenvolvido por Clive William John Granger (GRANGER, 1986) com o objetivo de verificar a existência de relações de causa e efeito entre duas variáveis ou mais defasadas, ou seja, um teste de procedência temporal. O teste é representado pelas equações (1) e (2):

$$\Delta X_t = a_x + \sum_{i=1}^k \beta_{x,i} \Delta X_{t-i} + \sum_{i=1}^k \gamma_{x,i} \Delta Y_{t-i} + \varepsilon_{x,t} \quad (1)$$

$$\Delta Y_t = a_y + \sum_{i=1}^k \beta_{y,i} \Delta Y_{t-i} + \sum_{i=1}^k \gamma_{y,i} \Delta X_{t-i} + \varepsilon_{y,t} \quad (2)$$

Em que: ΔX_t e ΔY_t indicam a primeira diferença das variáveis que serão testadas; a, β, γ são os coeficientes das regressões a serem estimados; ε_t erro aleatório.

Se a variável ΔX_t causa a variável ΔY_t , modificações que ocorrerem em ΔX_t gerarão temporalmente modificações em ΔY_t . Se não existir relação de causalidade com uma das séries sistema, essa série não é importante, ou seja, não causa modificação no modelo proposto. Quando uma série que não apresenta causalidade é mantida no sistema o coeficiente que a representa será próximo de zero, portanto a exclusão atende o pressuposto de parcimônia.

As relações de causalidade podem ser unidirecionais ou bidirecionais, em modelos com duas variáveis existe causalidade em pelo menos um direção (GRANGER, 1986). Uma causalidade unidirecional ocorre quando uma variável independente influencia outra, chamada de variável dependente ou efeito, em uma direção, da variável independente para a variável dependente. Na causalidade bidirecional a influência é mútua entre duas variáveis, pois ambas podem atuar como causa e efeito uma da outra, criando uma relação de interdependência. As relações são definidas aos pares de variáveis, desde que sejam estacionárias. Pela aplicação do teste é possível examinar a interdependência das séries e essa característica auxilia a selecionar as variáveis do modelo. Na sequência do teste foram selecionados os modelos ARIMA mais adequados a cada uma das séries seguindo os critérios de ajuste descritos no próximo tópico.

2.3. Estatísticas de ajustes de modelos de séries temporais

A escolha do modelo mais adequado foi realizada pelos critérios AIC – *Akaike Information Criteria* (AKAIKE, 1974), AICc – *Akaike Information Criteria Corrigido* (SUGIURA, 1978), o BIC – *Critério de Informação Bayesiano* (SCHWARZ, 1978) e Hannan-Quin – HQ (HANNAN; QUINN, 1979), conforme as expressões (3), (4), (5) e (6) respectivamente, que são equivalentes e medem a verossimilhança do modelo.

$$AIC = -2 \log L(\hat{\theta}) + 2k \quad (3)$$

$$AICc = -2 \log L(\hat{\theta}) + 2k + \left(\frac{2k^2 + 2k}{n - k - 1} \right) \quad (4)$$

$$BIC = -2 \log L(\hat{\theta}) + k \log n \quad (5)$$

$$HQ(p) = \ln \left| \sum (p) \right| + \frac{\ln(\ln T)}{T} 2pn^2 \quad (6)$$

Em que: $L(\hat{\theta})$ é a função de verossimilhança, k o número de parâmetros do modelo, n é o número de observações da amostra. Além das estatísticas de ajustes, foi realizada a análise dos resíduos do modelo para verificar a existência da característica de ruído branco. Isto é, identificar se a média dos resíduos é zero, a variância é constante e se os resíduos são não autocorrelacionados. Os valores obtidos pelos critérios em cada um dos modelos são comparados e deve ser considerado mais adequado o modelo que apresentar menor resultado para a maioria deles. Os modelos estão descritos nos próximos tópicos.

2.4 MODELOS LINEARES

Os modelos lineares serão utilizados para prever o comportamento médio de curto prazo das variáveis em estudo, baseando-se em um estudo univariado, com o intuito de utilizar os resíduos para se investigar a heteroscedasticidade da variável. Os modelos ARIMA serão utilizados principalmente para indicar o melhor modelo concorrente e determinar a volatilidade.

2.4.1 Modelos *AutoRegressive Integrated Moving Average* - ARIMA

Os modelos ARIMA(p,d,q) são provenientes do ajuste dos modelos autorregressivos AR(p), de médias móveis MA(q) e, se necessário tornar as séries estacionárias, aplica-se a diferenciação, a parte I(d). O modelo é descrito, de maneira genérica, pela equação (7) (MORETTIN; TOLOI, 2004):

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (7)$$

Em que: ε_t é o ruído branco; ϕ_p é o parâmetro do AR(p); θ_q é o parâmetro do MA(q).

Identificada a estacionariedade, é necessário verificar os movimentos da série, em que no modelo AR(p) $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ são a combinação linear dos p valores passados somados a ε_t , que é incorporado até o tempo t que não pode ser explicado pelos valores passados. Os valores de y_t são independentes de ε_t .

Nos casos em que as séries são integradas o modelo pode ser descrito pela equação (8):

$$\Delta^d y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (8)$$

Para identificar a ordem p do AR efetua-se a análise do gráfico da Função de Autocorrelação Parcial – FACP, a quantidade de parâmetros que estiver acima do intervalo de confiança apresentado no gráfico será o valor máximo do parâmetro. A ordem do q é definida pela Função de Autocorrelação – FAC. A estimação do modelo ARIMA segue as fases do ciclo iterativo (BOX; JENKINS; REINSEL, 1994), que consiste na escolha da classe do modelo, identificação do modelo, estimação do parâmetro, diagnóstico e adequação do modelo, uso do modelo para a previsão e controle. O ciclo parte do princípio da parcimônia e da iteração entre as fases, a parcimônia é a utilização do menor número de parâmetros para estabelecer o modelo matemático, e a iteração é a repetição da estimação do modelo várias vezes (MORETTIN; TOLOI, 2004).

Após a estimação dos modelos, o mais adequado é selecionado considerando os menores valores para os critérios AIC, AICc e BIC, e a presença de ruído branco nos resíduos. A identificação do ruído branco nos resíduos pode ser garantida pelos testes Ljung Box, utilizado para verificar a presença de autocorrelação, e ARCH-LM, para verificar a presença de heterocedasticidade condicional.

O teste Ljung Box (LJUNG; BOX, 1978) propõe a estatística (9) com o intuito de corrigir o problema.

$$Q_{LB}(m) = n(n+2) \sum_{k=1}^m (n-k)^{-1} \hat{\rho}_{\hat{\varepsilon}}^2(k) \quad (9)$$

A melhora proposta pelo teste, de acordo com os autores, é a incorporação do fator de correção $(n+2)/(n-k)$. O teste rejeita a hipótese nula se $Q > \chi^2$, o χ^2 é o valor obtido na tabela de distribuição chi-quadrado com h graus de liberdade ($h = m - p - q$) p e q são os parâmetros do modelo ARMA(p, q), e α nível de significância. O teste é aplicado aos resíduos do modelo da série e examina as m autocorrelações dos resíduos, em que, se as autocorrelações forem muito pequenas é possível concluir que não há falha significativa de ajuste do modelo.

Pelo teste ARCH-LM de Engle (ENGLE, 1982a), pode-se identificar se a covariância condicional é constante na série ou não. Este teste é um multiplicador de Lagrange que avalia a significância dos efeitos ARCH(1), considerando a regressão (10).

$$\varepsilon_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-s}^2 + u_t \quad (10)$$

O teste ARCH-LM pode ser definido por (11):

$$TR^2 \xrightarrow{d} \chi_p^2 \quad (11)$$

Em que: R^2 é o coeficiente de determinação da equação.

A hipótese nula do teste indica que os resíduos do modelo são homocedásticos, então não existe a presença do modelo ARCH, ou seja, se o p-valor do teste for menor que o nível de significância de 5%, rejeita-se a hipótese nula e confirma a existência de homocedasticidade condicional em ε_t^2 .

Nos modelos com presença de heterocedasticidade nos resíduos pode-se verificar o ajuste dos modelos *Autoregressive Conditional Heteroskedasticity* – ARCH ou ARIMA-ARCH combinando modelo ARIMA com um modelo ARCH com o intuito de capturar a volatilidade condicional.

2.4.2 Modelo *AutoRegressive Moving Average with Exogenous inputs* – ARMAX

Escolhido o melhor modelo ARIMA, o modelo ARMAX será utilizado para inserir as criptomoedas e suas defasagens para se determinar se existe influência nas bolsas de valores. O modelo ARMAX deriva do Autorregressivos de Médias Móveis – ARMA com dependência de uma série exógena. As variáveis exógenas são escolhidas após a aplicação do teste de causalidade de Granger, pois a inexistência de relação indica que a série não será exógena ao modelo.

As variações do modelo dependem da combinação das partes AR e MA derivando em Autorregressivos e Entradas Exógenas – ARX ou Autorregressivos de

Médias Móveis e Entradas Exógenas – ARMAX. Esse tipo de modelo garante que as variáveis sejam consideradas de forma simultânea (FRANSES, 1991), em que uma variável endógena dependente e mais as variáveis explicativas exógenas e possibilita a análise de mais de uma variável correlacionada à previsão Y_t . C.

$$Y_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t + \sum_{k=1}^{Nx} \beta_k X_{t-k} \quad (13)$$

Em que: Y_t é o modelador; c é a constante; ϕ_1, \dots, ϕ_p são os coeficientes dos termos autorregressivos; $Y_{t-1}, Y_{t-2}, \dots, Y_{t-i}$, são os termos autorregressivos; ε_t é a componente aleatória, com $\varepsilon_t \sim N(0, \sigma^2)$; $\theta_1, \theta_2, \dots, \theta_q$, são os coeficientes da média móvel, $\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ são as componentes aleatórias defasadas; X é uma matriz de variáveis exógenas em que cada coluna é uma série temporal; $Y_{(t,k)}$ é o elemento colocado na t -ésima linha e na k -ésima coluna; β_1, \dots, β_p são os coeficientes dos termos das variáveis exógenas.

Ao utilizar variáveis externas analisa-se a Função de Correlação Cruzada – FCC que mede quantos instantes da variável externa influenciam no valor presente da variável predita. Os erros do modelo são estimados de acordo com as defasagens relativas à amplitude da série temporal somado ao erro aleatório do próprio modelo (SENNA; MENDONÇA; SOUZA, 2017).

O modelo ARMAX é capaz de receber a incorporação do termo integrativo passando a ser chamado de ARIMA(X), neste caso é utilizado para descrever sistemas com perturbações lentas. Os mesmos critérios utilizados para a estimação dos modelos ARIMA são usados nesse modelo, ou seja, AIC (AKAIKE, 1974) (3), AICc (SUGIURA, 1978) (4) e BIC (SCHWARZ, 1978) (5). Os menores valores estabelecidos pelos critérios determinam o modelo mais adequado. A aplicação do modelo está apresentada no tópico de resultados e discussões.

Podem ser combinados aos modelos ARMAX os modelos ARCH, gerando os modelos ARMAX-ARCH que para modelar séries com volatilidade condicional em presença de variáveis exógenas. Ou ainda, combinar os modelos ARMAX e GARCH formando ARMAX-GARCH para capturar a volatilidade condicional da série, com maior flexibilidade, em presença de variáveis exógenas. Os modelos são relevantes

quando é possível identificar que fatores externos são capazes de alterar o comportamento de determinada série para além dos padrões intrínsecos.

2.4.3 Modelo de Autorregressão Vetorial – VAR

O Modelo VAR foi desenvolvido por Sims (SIMS, 1980) com o objetivo de verificar a existência de relações entre variáveis endógenas e exógenas. Essa característica é usada para a previsão de valores de séries econômicas relacionadas a modelos de equações simultâneas. O VAR analisa a relação ente as variáveis e seus valores defasados e admite a medir o impacto que perturbações aleatórias causam no sistema. A ordem p do modelo VAR é definida pela equação (14) (ENDERS, 2014):

$$x_t = A_0 + A_1 \sum_{i=1}^p x_{t-i} + \varepsilon_t \quad (14)$$

Em que: x_t é o vetor das variáveis; A_0 é a representação da matriz de interceptos; A_i , $i=1, 2, 3, \dots, p$ são matrizes com os termos das equações; ε_t é o ruído branco, e um vetor de inovação ou choque.

Para a estimação do VAR é efetuada a estimação de modelos VAR auxiliares com o objetivo de determinar a ordem p de defasagens.

Quando os testes não apresentam consenso com relação ao número ideal de estimadores é utilizada a quantidade de defasagens apresentada pela maioria dos testes (SENNA; SOUZA, 2016). A decisão pelo modelo mais adequado é feita pelo menor valor obtido pelos critérios em cada um dos modelos testados. O resultado do VAR é utilizado nos demais testes aplicados nas séries, como no teste de causalidade de Granger indicado no tópico 2.3.

2.5 MODELOS NÃO LINEARES

Os modelos não lineares serão utilizados em conjunto com os modelos lineares. O propósito dos modelos lineares é tratar a autocorrelação presente entre as observações e, por meio da modelagem da classe geral ARIMA passa-se a utilizar os resíduos que por apresentarem a característica de ruído branco, apresentam média zero, variância constante e não autocorrelacionados. Mas estes resíduos quando elevados na sua forma quadrática poderão apresentar características de autocorrelação, revelando assim a presença de volatilidade e conseqüentemente o uso da modelagem ARCH.

2.5.1 Modelo *Autoregressive Conditional Heteroskedasticity* - ARCH

Os modelos *Autoregressive Conditional Heteroskedasticity* – ARCH são utilizados para modelar a volatilidade condicional das séries, principalmente nas séries econômicas e financeiras.

O modelo ARCH possui a capacidade de capturar a volatilidade da série em um determinado período e modelada como uma função não linear dos erros dos períodos passados, em que a variância do erro depende de q defasagens dos erros quadráticos, e a ordem da autorregressão pode variar (ENGLE, 1982b). O modelo geral ARCH(q) é (15) (BROOKS, 2008):

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 u_{t-2}^2 + \dots + \alpha_q u_{t-q}^2 \quad (15)$$

Na literatura é comum a variância condicional ser chamada h_t e o modelo descrito por (16) e (17) (BROOKS, 2008):

$$y_t = \beta_1 + \beta_2 x_{2t} + \beta_3 x_{3t} + \beta_4 x_{4t} + u_t \quad u_t \sim N(0, h_t) \quad (16)$$

$$h_t = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 u_{t-2}^2 + \dots + \alpha_q u_{t-q}^2 \quad (17)$$

Os parâmetros do modelo são obtidos pela utilização do método da máxima verossimilhança condicional e são identificados por ARCH(q), ‘ α_1 ’, ‘ α_2 ’, ..., ‘ α_n ’.

O primeiro passo na construção de um modelo ARCH é obter uma série não autocorrelacionada, mas em geral séries econômicas são autocorrelacionadas e, como alternativa pode-se um modelo ARIMA, para remover a correlação serial na série, e modelar os seus resíduos, utilizando um dos modelos da família ARCH. O modelo ARIMA-ARCH é a combinação do modelo ARIMA com um modelo ARCH para capturar a volatilidade condicional.

2.5.2 Modelo *Generalized Autoregressive Conditional Heteroskedasticity* - GARCH

O modelo *Generalized Autoregressive Conditional Heteroskedasticity* – GARCH (‘sGARCH’ – *standard* GARCH – modelo GARCH padrão) consegue incorporar a autorregressão a volatilidade condicional mais complexa com menos parâmetros do que um ARCH. O processo GARCH(p, q) permite a entrada de variâncias condicionais defasadas também, como um mecanismo de aprendizagem adaptativo (BOLLERSLEV, 1986). Ele permite que a variância condicional seja dependente sobre as próprias defasagens anteriores, de modo que a equação de variância condicional seja simples (18) (BROOKS, 2008):

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \beta \alpha_{t-1}^2 \quad (18)$$

Os parâmetros para o modelo GARCH(p) são ' β_1 ', ' β_2 ', ..., ' β_n '. O parâmetro de interceptação de variância é ' α_0 '.

Existem muitas extensões do modelo GARCH, como o *Exponential GARCH* – eGARCH (NELSON, 1991), no qual há a inserção de choques assimétricos, que podem afetar a volatilidade de forma diferente. A volatilidade pode ser assimétrica aos retornos, sendo maior para os retornos negativos do que para os positivos (BROOKS, 2008), a esse efeito foi denominado alavanca, representado pelo parâmetro ' γ '. Outra extensão do modelo GARCH é a *Integrated GARCH* – iGARCH (ENGLE; BOLLERSLEV, 1986), usado quando a série temporal não é estacionária e precisa ser diferenciada antes de aplicar o modelo GARCH.

O *Glosten-Jagannathan-Runkle GARCH* – gjrGARCH (GLOSTEN; JAGANNATHAN; RUNKLE, 1993), é uma extensão simples do GARCH com um termo adicional acrescentado para compensar possíveis assimetrias (BROOKS, 2008). Essa extensão inclui um componente de choque assimétrico na modelagem para permitir a assimetria na resposta da volatilidade a choques positivos e negativos. A extensão *Asymmetric Power GARCH* – apGARCH (DING; GRANGER; ENGLE, 1993) também trabalha a assimetria na volatilidade condicional usando função de potência assimétrica na modelagem. Essa extensão permite a alavancagem e o efeito Taylor em que a autocorrelação amostral dos retornos absolutos é, em geral, maior do que a dos retornos quadrados.

O modelo GARCH é mais utilizado do que o modelo ARCH porque é mais parcimonioso e evita sobreajuste, ou seja, o modelo tem menos probabilidade de romper as restrições de não negatividade (BROOKS, 2008). A combinação de um modelo ARIMA com um GARCH gera um modelo ARIMA-GARCH que serve para modelar a volatilidade condicional com maior flexibilidade.

3 RESULTADOS E DISCUSSÃO

Para verificar se as criptomoedas Bitcoin, Litecoin e Ripple influenciam as bolsas de valores, foram selecionados índices de 21 bolsas distribuídas em continentes diferentes. Esses índices têm a finalidade de medir o desempenho agregado de um grupo específico de ações que representa o mercado financeiro ou uma parte dele. A composição e o cálculo dos índices podem variar dependendo da bolsa, pois cada um deles representa um conjunto de ações e setores que oferecem aos investidores uma visão do desempenho geral do mercado ou de segmentos específicos.

A partir da coleta das séries dos índices e das criptomoedas foi feita a definição de modelos iniciando pelos testes de estacionariedade, seguido pela verificação da quantidade de *lags* a serem defasados, conforme modelo VAR, em função da dependência temporal dos valores passados que afetam os futuros.

Os testes de estacionariedade ADF, PP e KPSS, indicaram que as séries são estacionárias após a aplicação de uma diferença, ou seja, em primeira ordem, ao nível de significância de 1%, os resultados dos testes estão na Tabela 2.

Tabela 2 – Resultado dos testes de estacionariedade ADF, PP e KPSS para as séries dos índices das bolsas de valores e para as criptomoedas.

SÉRIE	Em nível		Tranfor. log		Uma diferença		Em nível		Tranf. log		Uma diferença		Em nível		Tranfor. log		Uma diferença	
	KPSS	P-valor	KPSS	P-valor	KPSS	P-valor	ADF	P-valor	KPSS	P-valor	ADF	P-valor	PP	P-valor	KPSS	P-valor	PP	P-valor
159903	3,44	0,01	3,52	0,01	0,05	0,1	-2,84	0,22	-2,79	0,25	-7,53	0,01	-14,66	0,29	-14,23	0,32	-555,07	0,01
SZZ																		
AXAT	6,34	0,01	6,34	0,01	0,02	0,1	-3,50	0,04	-3,68	0,03	-8,60	0,01	-32,18	0,01	-34,91	0,01	-472,94	0,01
BSESN	6,96	0,01	7,20	0,01	0,11	0,1	-2,41	0,41	-2,90	0,2	-7,83	0,01	-11,35	0,48	-17,20	0,15	-515,70	0,01
DAX	6,03	0,01	6,03	0,01	0,02	0,1	-3,46	0,05	-3,50	0,04	-8,09	0,01	-27,12	0,02	-28,36	0,01	-490,78	0,01
FNCMX	7,05	0,01	7,51	0,01	0,08	0,1	-1,73	0,69	-2,20	0,49	-7,87	0,01	-8,88	0,61	-13,48	0,36	-533,29	0,01
FTSE	7,39	0,01	7,51	0,01	0,04	0,1	-2,34	0,43	-2,09	0,54	-9,47	0,01	15,44	0,25	-11,22	0,48	-422,10	0,01
HSI	1,08	0,01	1,08	0,01	0,13	0,1	-2,47	0,38	-2,58	0,33	-7,98	0,01	-11,39	0,47	-12,25	0,43	-568,71	0,01
IBOV	7,14	0,01	7,12	0,01	0,04	0,1	-3,50	0,04	-3,14	0,09	-7,49	0,01	-23,00	0,04	-20,12	0,07	-512,51	0,01
IMOEX																		
ME	5,43	0,01	6,02	0,01	0,06	0,1	-2,32	0,44	-2,09	0,54	-7,39	0,01	-9,13	0,6	-9,68	0,57	-479,98	0,01
JSE.JO	1,66	0,01	1,96	0,01	0,21	0,1	-1,52	0,78	-0,95	0,95	-7,85	0,01	-5,90	0,78	-3,85	0,89	-596,58	0,01
KLSE	5,47	0,01	5,46	0,01	0,03	0,1	-3,52	0,04	-3,65	0,03	-8,95	0,01	-26,52	0,02	-27,72	0,01	-493,39	0,01
KS11	3,93	0,01	4,12	0,01	0,05	0,1	-2,19	0,49	-2,33	0,44	-7,57	0,01	-10,46	0,53	-12,77	0,4	-568,56	0,01
MERV	3,68	0,01	7,08	0,01	1,53	0,1	-10,12	0,01	-3,83	0,01	-6,03	0,01	-29,14	0,01	-20,61	0,06	-361,32	0,01
N100	6,24	0,01	6,26	0,01	0,02	0,1	-3,36	0,06	-3,52	0,04	-8,27	0,01	-27,86	0,01	-30,93	0,01	-474,67	0,01
N225	6,74	0,01	6,77	0,01	0,54	0,1	-3,49	0,04	-3,35	0,06	-8,27	0,01	-26,07	0,02	-27,35	0,02	-532,97	0,01
NSEI	6,88	0,01	7,07	0,01	0,10	0,1	-2,51	0,36	-2,96	0,17	-7,88	0,01	-12,38	0,42	-18,04	0,1	-541,30	0,01
SSE180	1,70	0,01	2,12	0,01	0,06	0,1	-2,83	0,23	-2,49	0,37	-7,05	0,01	-14,53	0,3	-11,84	0,45	-527,87	0,01
SSMI	6,29	0,01	6,37	0,01	0,03	0,1	-2,52	0,36	-2,61	0,32	-9,61	0,01	-21,57	0,05	-23,99	0,03	-455,55	0,01
STI	0,31	0,1	0,31	0,1	0,06	0,1	-2,44	0,39	-2,50	0,37	-8,31	0,01	-15,65	0,24	-15,81	0,23	-414,44	0,01
TA35																		
TA	4,32	0,01	4,27	0,01	0,04	0,1	-2,34	0,44	-2,35	0,43	-9,51	0,01	-16,59	0,18	-17,03	0,16	-491,28	0,01
TWII	6,36	0,01	6,68	0,01	0,09	0,1	-1,91	0,62	-2,17	0,51	-7,49	0,01	-8,10	0,66	-10,72	0,51	-533,44	0,01
BTC	4,93	0,01	7,11	0,01	0,05	0,1	-3,01	0,15	-2,60	0,33	-7,03	0,01	-11,72	0,46	-10,91	0,5	-459,36	0,01
LTC	3,35	0,01	4,88	0,01	0,03	0,1	-2,91	0,19	-1,47	0,801	-8,40	0,01	-27,70	0,01	-8,91	0,61	-450,49	0,01
XRP	0,38	0,08	4,87	0,01	0,01	0,1	-5,54	0,01	-3,60	0,03	-9,95	0,01	-95,70	0,01	-44,79	0,01	-473,78	0,01

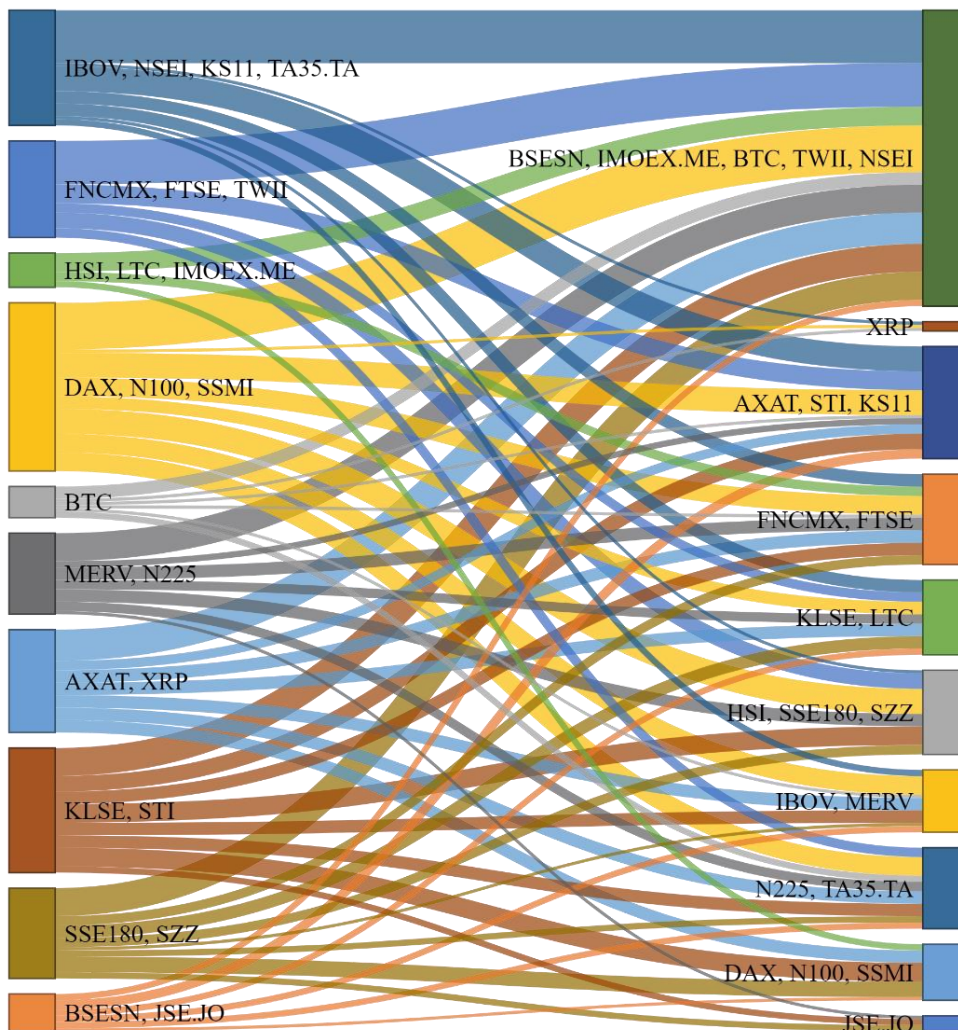
Fonte: Autores

As séries dos indicadores das Bolsas de Valores estão na parte superior da Tabela 2, e as séries das criptomoedas na parte inferior. Pela análise dos resultados dos testes KPSS, ADF e PP indicados na Tabela 2 todas as séries foram consideradas estacionárias em primeiras diferenças, pois essa padronização auxilia a tornar as previsões mais confiáveis porque pode-se admitir que o comportamento passado das séries caracteriza o comportamento futuro.

A quantidade de defasagens indicadas pelo modelo VAR de acordo com os critérios AIC - Critério de informação de Akaike, HQ - Critério de informação de Hannan-Quinn; SC - Critério de informação foi de 2 *lags*. Esses 2 *lags* foram utilizados para especificar a ordem de defasagens incluídas no teste de causalidade de Granger.

Na sequência, foi efetuado o teste de causalidade de Granger, com a finalidade de identificar a relação de causa uni ou bilateral entre o conjunto de séries. A Figura 1 indica o resultado do teste de causalidade de Granger, em que todas as séries apresentam relação de causalidade unidirecionais ou bidirecionais.

Figura 1 – Resultado do teste de causalidade de Granger entre as séries dos índices das Bolsas de Valores e das criptomoedas



Fonte: Autores (2023).

O resultado da Figura 1 indica a causalidade unilateral ou bilateral para as séries com significância de até 10%, ou seja, todas as séries possuem algum tipo de relação de causalidade que justifique a manutenção delas no conjunto em análise. O percentual de significância dessas relações de causalidade está indicado na Tabela 3.

Tabela 3 – Resultado do teste de causalidade de causalidade de Granger com até 5% e com até 10% de significância para os índices das Bolsas de Valores e as criptomoedas

Hipótese Nula	Significância a 5%	Significância a 10%
159903.SSZ	BSESN, HSI, IMOEX.ME, N100, TWII, LTC	BTC, DAX, JSE.JO, KLSE, NSEI, FNCMX, N225
AXAT	BSESN, BTC, FNCMX, FTSE, IBOV, HSI, IMOEX.ME, KLSE, MERV, NSEI, TA35.TA, TWII, N225, STI	N100, LTC
BSESN	BTC, DAX, FTSE, IBOV, N100, NSEI, SSMI, TA35.TA, AXAT, KLSE, KS11, SSMI	
DAX	AXAT, BSESN, BTC, FTSE, HSI, IBOV, IMOEX.ME, KLSE, KS11, MERV, NSEI, SSE180, SZZ, TA35.TA, TWII, FNCMX, N225	LTC, XRP
FNCMX	AXAT, BSESN, BTC, HSI, IMOEX.ME, KS11, NSEI, TA35.TA, TWII, N225	KLSE, SZZ, STI
FTSE	AXAT, BSESN, IMOEX.ME, KS11, NSEI, TWII	BTC, KLSE, SZZ
HSI	BSESN, FTSE, IMOEX.ME	N100
IBOV	BSESN, BTC, IMOEX.ME, KLSE, KS11, MERV, NSEI, FNCMX, STI	FTSE, TWII
IMOEX_ME	BSESN, BTC, FTSE, FNCMX	SSMI, TWII
JSE_JO	AXAT, BSESN, IBOV, IMOEX.ME, MERV, TA35.TA	
KLSE	AXAT, BSESN, BTC, DAX, FTSE, HSI, IBOV, JSE.JO, KS11, MERV, N100, NSEI, SSE180, SSMI, SZZ, TA35.TA, TWII, FNCMX, N225, STI	KLSE, N225
KS11	BSESN, BTC, IMOEX.ME, STI, XRP	NSEI, TWII, FNCMX, LTC
MERV	BSESN, BTC, FTSE, IMOEX.ME, KS11, NSEI, SSE180, SZZ, TA35.TA, FNCMX, N225	HSI, JSE.JO, KLSE, TWII
N100	AXAT, BSESN, BTC, FTSE, HSI, IMOEX.ME, KLSE, KS11, MERV, NSEI, SSE180, SZZ, TA35.TA, TWII, FNCMX, N225, STI	IBOV
N225	BSESN, BTC, FTSE, IMOEX.ME, KLSE, KS11, NSEI, LTC	SZZ, TA35.TA, FNCMX
NSEI	BSESN, BTC, FTSE, IMOEX.ME, KLSE, KS11, MERV, STI	AXAT
SSE180	BSESN, DAX, HSI, IBOV, IMOEX.ME, N100, SZZ, TWII, LTC	FTSE, JSE.JO, KLSE, NSEI, SSMI, FNCMX, N225
SSMI	AXAT, BSESN, BTC, FTSE, IMOEX.ME, KLSE, KS11, MERV, NSEI, SZZ, TA35.TA, FNCMX, N225, STI	HSI, IBOV, TWII
STI	AXAT, BTC, DAX, FTSE, HSI, IBOV, IMOEX.ME, JSE.JO, KS11, MERV, N100, NSEI, SSE180, SSMI, SZZ, TA35.TA, TWII, FNCMX, N225	BSESN
TA35.TA	BSESN, BTC, HSI, IMOEX.ME, KLSE, KS11, STI	NSEI
TWII	BSESN, IMOEX.ME, SZZ	BTC, KLSE, KS11, NSEI, SSE180, TA35.TA
BTC	BSESN, NSEI, TA35.TA, TWII	IMOEX.ME, KS11, MERV, FNCMX, N225, XRP
LTC	BSESN	
XRP	AXAT, BSESN, BTC, DAX, FTSE, IBOV, IMOEX.ME, KS11, MERV, N100, NSEI, SSMI, TA35.TA, TWII, FNCMX, LTC, N225	KLSE

Fonte: Autores (2023).

A Tabela 3 indica a significância da relação de causalidade das séries de A para B, sendo A a hipótese nula, indicada na primeira coluna, e B as séries com significância de 5% na segunda coluna e de 10% na terceira.

A aplicação do modelo ARMAX inicia pela seleção do modelo ARIMA mais adequado para as séries. A transformação logarítmica foi aplicada às séries para estabilizar a variância e reduzir a tendência de crescimento exponencial e, portanto, tornar a tendência mais linear, pois a variação dos valores, ao longo do tempo, é muito ampla. Essa transformação é utilizada quando os dados são números positivos, ou porcentagens com uma grande amplitude de variação, como é o caso das séries selecionadas para o estudo. Essa transformação é adequada para modelar com métodos como ARIMA, ARMAX, ARMAX-GARCH, ARIMA ou ARIMA-GARCH, entre outros. Para auxiliar na interpretação dos resultados gerados pelos modelos na Tabela 4 foram indicadas as estatísticas descritivas das séries.

Tabela 4 – Estatística descritiva das séries transformadas

Série	SZZ	AXAT	BSESN	DAX	FNCMX	FTSE	HSI	IBOV
Min.	-0.3011	8.410	9.827	8.948	3.646	6.939	9.595	10.54
1st Qu.	0.0198	8.595	10.209	9.248	4.073	7.746	10.000	10.90
Median	0.1398	8.678	10.443	9.407	4.484	8.294	10.093	11.28
Mean	0.1518	8.700	10.471	9.386	4.490	8.271	10.094	11.25
3rd Qu.	0.3148	8.815	10.795	9.495	4.945	8.898	10.209	11.57
Max.	0.5988	8.928	11.108	9.708	5.293	9.161	10.403	11.78
Sd	0.2243	0.1271	0.3420	0.1773	0.4634	0.6273	0.1400	0.3409
Série	IMOEX.ME	JSE.JO	KLSE	KS11	MERV	N100	N225	NSEI
Min.	7.121	8.590	7.173	7.301	8.013	6.519	9.475	8.597
1st Qu.	7.468	9.157	7.355	7.601	9.402	6.779	9.780	9.018
Median	7.703	9.231	7.417	7.676	10.277	6.918	9.966	9.258
Mean	7.701	9.230	7.409	7.720	10.262	6.921	9.959	9.271
3rd Qu.	7.913	9.359	7.480	7.809	10.827	7.045	10.182	9.570
Max.	8.357	9.723	7.543	8.102	13.408	7.245	10.427	9.891
Sd	0.2956	0.2168	0.0828	0.1486	1.1070	0.1687	0.2290	0.3362
Série	SSE180	SSMI	STI	TA35.TA	TWII	BTC	LTC	XRP
Min.	7.580	8.889	7.779	7.066	8.911	4.244	0.2776	-5.2983
1st Qu.	7.957	9.053	8.020	7.261	9.121	6.341	1.6243	-4.6052
Median	8.048	9.123	8.069	7.329	9.265	8.762	3.8722	-1.4271
Mean	8.009	9.160	8.047	7.345	9.320	8.155	3.3587	-2.0437
3rd Qu.	8.112	9.278	8.097	7.428	9.561	9.848	4.4819	-0.7765
Max.	8.543	9.468	8.182	7.629	9.827	11.089	5.9570	5.5797
Sd	0.1730	0.1338	0.0802	0.1215	0.2513	1.8943	1.4824	2.3854

Fonte: Autores (2023).

A Tabela 4 indica os valores mínimos e máximos de cada série, bem como primeiro e terceiro quartis, média, mediana e o desvio-padrão. Os valores auxiliam na compreensão da estrutura e das propriedades das séries, o que permite a comparação e avaliação dos coeficientes dos modelos ajustados.

Pelos valores de mínimos e máximos é possível verificar a ampla variação contida nas séries, bem como a comparação entre média e mediana indica se há simetria nas séries, ou ainda se houver grande diferença entre as medidas é provável a existência de *outliers*. Pelo desvio padrão pode-se verificar se há muita variabilidade, por exemplo, a série BTC tem um desvio padrão de 1.8943, indicando alta volatilidade em comparação com outras séries. A comparação entre as séries auxilia na identificação de quais delas, do conjunto, possuem maior variabilidade, a série TWII tem um desvio padrão de 0.2513, indicando menor volatilidade em comparação com outras séries. Pela análise da Tabela 4 pode-se obter informações sobre a variabilidade, centralidade e distribuição dos dados em cada série.

Na Tabela 5 estão apresentados os modelos mais adequados para cada série, de acordo com os critérios de avaliação, os respectivos coeficientes e os resultados dos testes Ljung-Box e ARCH-LM, aplicados nos resíduos.

Foram efetuados os modelos ARIMA, com as variações necessárias ARIMA-ARCH, ARIMA-GARCH, de acordo com o comportamento de cada série. Por fim, foram definidos os modelos com a inclusão das variáveis exógenas BTC, LTC E XRP.

Tabela 5 – Modelos ARIMA mais adequados para as séries das Bolsas de Valores e criptomoedas

Série	Modelo	Coeficientes							Critérios de avaliação			Ljung-Box test		ARCH LM Test					
									AIC	AICc	BIC	χ^2	p-value	χ^2	p-value				
159903. SZZ	ARIMA(3,1,3)	0.4565	0.3058	-0.8655	-0.5195	-0.2223	0.8759	-2053.06	-2052.85	-2023.05	86.643	0.7872	11.725	0.002845					
	ARIMA(3,1,3) with drift	0.4544	0.3084	-0.8668	-0.5175	-0.2250	0.8778	-0.0006	-2051.19	-2050.92	-2016.89	86.581	0.7886	11.751	0.002808				
	ARIMA(1,1,1)	-0.9108	0.8706							-2048.76	-2048.72	-2035.9	96.96	0.6225	10.754	0.004621			
AXAT	ARIMA(4,1,5) with drift	0.0693	-0.2873	0.3577	0.5832	-0.0426	0.3585	-0.5285	-0.6247	-0.1628	-7e-04	-2629.58	-2629.08	-2582.41	56.442	0.9994	180.6	< 2.2e-16	
	ARIMA(4,1,1) with drift	1.0185	0.0176	-0.2316	0.1354	-1.0000	-7e-04		-2629.56	-2629.35	-2599.54	62.244	0.9986	173.71	< 2.2e-16				
	ARIMA(1,1,4) with drift	0.9343	-0.9160	0.0100	-0.2066	0.1127	-7e-04		-2628.15	-2627.94	-2598.14	61.444	0.9989	175.08	< 2.2e-16				
BSESN	ARIMA(5,1,5) with drift	-0.6195	0.8107	0.6615	-0.7608	-0.8290	0.6576	-0.8073	-0.7618	0.7364	0.9298	-0.0022	-2567.19	-2566.6	-2515.74	112.11	0.09816	56.523	5,32E-10
	ARIMA(3,1,5) with drift	-0.4664	0.4684	0.8982	0.5046	-0.4605	-1.0145	-0.0471	0.0176	-0.0021		-2563.68	-2563.26	-2520.8	116.47	0.07622	42.371	6.3e-10	
	ARIMA(2,1,5) with drift	-1.4432	-0.9171	1.5041	1.0088	0.0472	0.042	0.0604	-0.0022	-2561.24	-2560.9	-2522.65	117.09	0.08069	54.467	1,49E-09			
DAX	ARIMA(3,1,3) with drift	-0.5812	0.5107	0.8889	0.5909	-0.5911	-0.9998	-1e-03	-2329.72	-2329.45	-2295.42	97.559	0.4936	77.095	< 2.2e-16				
	ARIMA(3,1,4) with drift	-0.5870	0.5071	0.8889	0.6169	-0.5758	-1.0152	-0.0258	-1e-03			-2327.99	-2327.65	-2289.4	97.9	0.4553	71.834	2.52e-16	
	ARIMA(4,1,3) with drift	-0.5622	0.5216	0.8764	-0.0219	0.5911	-0.5911	-1.0000	-1e-03	-2327.98	-2327.64	-2289.39	97.876	0.4560	71.981	2,34E-13			
FNCMX	ARIMA(4,1,4) with drift	0.1306	1.4819	0.1916	-0.9023	-0.1629	-1.5357	-0.1995	0.9795			-2309.73	-2309.31	-2266.85	93.348	0.5576	46.25	9,06E-08	
	ARIMA(2,1,2) with drift	1.9101	-0.9297	-1.9650	0.9825	-0.0031			-2308.31	-2308.15	-2282.58	96.174	0.5897	52.364	4.26e-12				
	ARIMA(3,1,4) with drift	-1.0154	0.3685	0.7232	0.9954	-0.4529	-0.8336	-0.0193	-0.0028	-2305.59	-2305.25	-2267	97.819	0.4576	46.14	9.57e-11			
FTSE	ARIMA(4,1,4) with drift	-0.0616	1.8468	0.0098	-0.9167	0.0213	-1.9340	0.0213	0.9999	-0.0037		-2077.59	-2077.18	-2034.72	90.401	0.6420	39.817	0.1366	
	ARIMA(5,1,5) with drift	0.3387	0.5074	0.5591	0.3055	-0.8659	-0.3801	-0.5315	-0.6358	-0.2617	0.9491	-0.0037	-2076.64	-2076.05	-2025.19	85.502	0.7226	20.096	0.3661
	ARIMA(3,1,3) with drift	0.9459	0.8996	-0.9062	-1.0163	-0.8866	0.9561	-0.0037				-2075.19	-2074.92	-2040.89	95.716	0.5464	33.929	0.1833	
HSI	ARIMA(1,1,1)	-0.8960	0.8273						-2287.29	-2287.25	-2274.43	100.4	0.5262	15.777	.0003751				
	ARIMA(3,1,1)	-0.7348	-0.0193	-0.0925	0.6899				-2286.98	-2286.87	-2265.54	91.282	0.7217	12.577	0.001857				
	ARIMA(1,1,3)	-0.8206	0.7761	-0.0201	-0.0819				-2286.87	-2286.76	-2265.43	91.686	0.7114	12.516	0.001915				
IBOV	ARIMA(5,1,5) with drift	0.1447	-0.0399	0.0346	-0.1550	0.8839	-0.1541	0.0876	-0.0788	0.1324	-0.9871	-0.0018	-2117.65	-2117.05	-2066.19	93.245	0.5026	117.58	< 2.2e-16

	ARIMA(5,1,5)	0.1112 -0.0699 0.0047 -0.1820 0.8514 -0.1135 0.1230 -0.0407 0.1676 -0.9462	-2115.14	-2114.64	-2067.97	94.825	0.4568	119.57	< 2.2e-16
	ARIMA(3,1,2)	0.7155 -0.9640 0.0169 -0.6866 0.9998	-2114.02	-2113.86	-2088.29	103.26	0.3648	127.01	< 2.2e-16
IMOEX _ME	ARIMA(2,1,4)	-1.4537 -0.9500 1.5416 0.9889 -0.1087 -0.1306	-2216.85	-2216.64	-2186.83	87.415	0.7695	97.195	0.007752
	ARIMA(2,1,4) with drift	-1.4538 -0.9499 1.5401 0.9842 -0.1139 -0.1331 -0.0015	-2216.29	-2216.02	-2181.99	87.597	0.7652	97.511	0.007631
	ARIMA(4,1,2)	-1.3745 -0.9600 -0.1026 -0.1167 1.4600 1.0000	-2216.08	-2215.87	-2186.07	87.896	0.7580	86.788	0.01304
JSE.JO	ARIMA(1,1,0)	-0.1265	-2121.4	-2121.37	-2112.82	83.894	0.9157	0.4004	0.8186
	ARIMA(2,1,2)	-1.3486 -0.7041 1.2315 0.6024	-2121.37	-2121.25	-2099.93	76.848	0.9587	1.638	0.4409
	ARIMA(0,1,1)	-0.1160	-2120.67	-2120.65	-2112.09	84.991	0.9013	0.3974	0.8198
KLSE	ARIMA(1,1,2) with drift	0.9496 -0.9213 -0.0787 4e-04	-3034.49	-3034.38	-3013.06	121.97	0.07630	14.661	.0006551
	ARIMA(1,1,3) with drift	0.9498 -0.9219 -0.0808 0.0027 4e-04	-3032.5	-3032.34	-3006.77	122	0.06672	14.779	0.0006176
	ARIMA(1,1,2)	0.8983 -0.8577 -0.0877	-3031.83	-3031.75	-3014.68	122.16	0.07467	15.208	0.0004985
	ARIMA(0,1,0)	-5.00E-04	-2511.15	-2511.14	-2506.86	00.24	0.5862	207.18	< 2.2e-16
KS11	ARIMA(5,1,4)	0.2948 -0.6784 0.2385 -0.8791 -0.0787 -0.3274 0.6698 -0.2294 0.8797	-2510.8	-2510.39	-2467.92	77.388	0.9061	187.99	< 2.2e-16
	ARIMA(4,1,5)	0.3641 -0.7221 0.3242 -0.9345 -0.3957 0.7213 -0.3186 0.9334 -0.0702	-2510.49	-2510.07	-2467.61	77.611	0.9030	185.82	< 2.2e-16
MERV	ARIMA(0,1,0)(0,0,1)[52] with drift	0.0655 -0.0098	-1526.42	-1526.37	-1513.55	66.266	0.9981	13.908	0.0009549
	ARIMA(0,1,0) with drift	-0.0097	-1526.08	-1526.06	-1517.51	69.282	0.9965	13.99	0.0009163
	ARIMA(1,1,0) with drift	-0.0309 -0.0097	-1524.6	-1524.55	-1511.73	70.317	0.9943	14.109	0.0008635
NI100	ARIMA(3,1,3) with drift	-0.5984 0.5097 0.8867 0.5959 -0.5959 -1.0000 -1e-03	-2422.08	-2421.81	-2387.78	96.038	0.5372	73.828	< 2.2e-16
	ARIMA(5,1,5) with drift	0.0196 -0.0965 -0.0126 -0.0524 0.8626 -0.0274 0.0326 -0.0326 0.0274 -1.0000 -1e-03]	-2418.7	-2418.11	-2367.25	93.422	0.4974	68.89	1,10E-12
	ARIMA(3,1,5) with drift	-0.6040 0.5119 0.8889 0.6217 -0.6037 -1.0284 -0.0119 0.0224 -1e-03	-2418.56	-2418.14	-2375.68	95.787	0.4869	72.511	< 2.2e-16
N225	ARIMA(3,1,4) with drift	0.7789 -0.7904 0.9101 -0.8388 0.8316 -1.0290 0.0361 -0.0014	-2354.62	-2354.28	-2316.03	92.399	0.6132	76.323	< 2.2e-16
	ARIMA(4,1,3) with drift	0.7434 -0.7630 0.8820 0.0324 -0.8027 0.8027 -1.000 -0.0014	-2354.61	-2354.27	-2316.02	92.378	0.6138	76.35	< 2.2e-16
	ARIMA(1,1,1) with drift	0.9506 -1.0000 -0.0014	-2354.3	-2354.22	-2337.14	96.03	0.6479	76.407	< 2.2e-16
NSEI	ARIMA(1,1,3) with drift	0.9644 -0.9977 0.1083 -0.1106 -0.0021	-2463.09	-2462.93	-2437.36	74.235	0.9749	93.939	< 2.2e-16
	ARIMA(0,1,2) with drift	-0.0139 0.0933 -0.0022	-2459.65	-2459.58	-2442.5	75.323	0.9780	102.04	< 2.2e-16
	ARIMA(2,1,0) with drift	-0.0201 0.0853 -0.0022	-2459.37	-2459.3	-2442.22	75.412	0.9776	105.59	< 2.2e-16
SSEI 80	ARIMA(4,1,0)	-0.0191 0.0236 -0.0693 0.1208	-2227.65	-2227.54	-2206.21	79.177	0.9384	16.397	0.0002751
	ARIMA(1,1,1)	-0.8815 0.8287	-2226.54	-2226.5	-2213.68	78.783	0.9573	18.337	0.0001043

	ARIMA(0,1,4)	-0.0202	0.0202	-0.0582	0.1118			-2226.23	-2226.12	-2204.79	80.224	0.9271	15.723	0.0003852		
SSMI	ARIMA(4,1,3)	1.0774	-1.2685	0.7914	-0.1032	-1.1136	1.2321	-0.8359	-2611.49	-2611.22	-2577.19	74.72	0.9548	32.509	8,72E-05	
	ARIMA(3,1,4)	0.9431	-1.1226	0.6336	-0.9794	1.0742	-0.6680	-0.1207	-2611.41	-2611.13	-2577.1	74.897	0.9533	32.897	7,19E-05	
	ARIMA(4,1,3) with drift	1.0861	-1.2707	0.7996	-0.103	-1.1251	1.2353	-0.8474		-2611	-2610.66	-2572.41	75.563	0.9475	31.935	1,16E-04
			-6e-04													
STI	ARIMA(5,1,3)	0.2976	-0.6852	0.5548	-0.0937	-0.0738	-0.2160	0.7282	-2741.42	-2741.08	-2702.83	83.904	0.8062	62.504	2,68E-11	
	ARIMA(3,1,5)	0.1736	-0.6701	0.5528	-0.0935	0.7266	-0.6155	-0.0909	-2741.38	-2741.04	-2702.79	83.449	0.8159	61.931	3,56E-11	
	ARIMA(3,1,2)	-0.3132	-0.8589	0.0808	0.402	0.9741			-2741.29	-2741.13	-2715.57	89.895	0.7325	59.521	1,19E-10	
TA35. TA	ARIMA(1,1,3)	0.6601	-0.6133	0.0213	-0.1414				-2656.41	-2656.3	-2634.97	81.213	0.9153	58.467	2,01E-10	
	ARIMA(3,1,1)	0.7704	0.0234	-0.1350	-0.7284				-2656.32	-2656.21	-2634.88	81.826	0.9073	56.016	6,86E-10	
	ARIMA(1,1,3) with drift	0.6749	-0.6303	0.0197	-0.1426	-8e-04			-2655.78	-2655.62	-2630.05	81.161	0.9160	57.879	2,70E-10	
TWII	ARIMA(0,1,0)								-2557.46	-2557.46	-2553.18	87.066	0.8845	59.764	1,05E-10	
	ARIMA(3,1,3)	-0.0094	-0.0890	-0.8923	-0.0367	0.1363	0.9111		-2557.34	-2557.13	-2527.33	78.598	0.9252	49.491	1,79E-08	
	ARIMA(0,1,0) with drift	-0.0013							-2557.29	-2557.27	-2548.71	87.126	0.8836	59.763	1,05E-10	
BTC	ARIMA(3,1,2)	-0.8268	-0.8648	0.0761	0.9008	0.9801			-736.16	-736	-710.43	59.344	0.9995	122.18	< 2.2e-16	
	ARIMA(2,1,3)	-0.8860	-0.9485	0.9622	1.0595	0.0674			-736.03	-735.87	-710.3	60.881	0.9991	124.23	< 2.2e-16	
	ARIMA(0,1,0) with drift	-0.0099							-734.28	-734.26	-725.71	68.383	0.9973	131.66	< 2.2e-16	
LTC	ARIMA(2,1,5)	1.0684	-0.7104	-1.0935	0.8141	-0.2518	0.3664	-0.2286	-255.3	-255.03	-221	57.775	0.9995	11.593	0.003038	
	ARIMA(5,1,2)	1.0967	-0.6728	-0.2471	0.3626	-0.2304	-1.1209	0.7714	-254.64	-254.37	-220.33	61.323	0.9982	14.061	0.000884	
	ARIMA(2,1,5) with drift	1.0686	-0.7105	-1.0939	0.8141	-0.2518	0.3664	-0.2288	-253.34	-253	-214.75	57.774	0.9995	11.599	0.003029	
		-0.0016														
XRP	ARIMA(5,1,5) with drift	-0.4302	0.2002	-0.2596	0.3958	0.7159	0.3183	-0.4038	1045.09	1045.68	1096.54	62.951	0.9942	34.166	3,81E-05	
		0.3946	-0.4882	-0.8209	-0.0106											
	ARIMA(5,1,5)	-0.4684	0.1483	-0.3062	0.3418	0.6822	0.3563	-0.3582	1045.47	1045.97	1092.63	63.506	0.9933	33.852	4,46E-05	
		0.4299	-0.4399													
	ARIMA(5,1,4) with drift	0.4423	-0.1815	-0.1577	0.6056	0.0917	-0.5580	0.0394	1060.44	1060.94	1107.60	82.298	0.8205	26.766	1,54E-03	
		0.4248	-0.9062	-0.0105												

Fonte: Autores (2023).

A Tabela 5 apresenta os resultados dos critérios de seleção AIC, AICc e BIC dos três melhores modelos ARIMA para cada uma das séries e os resultados dos respectivos testes Ljung-Box e ARCH LM. Os critérios utilizam a máxima função de verossimilhança como medida de ajustamento, o que os difere é que o AIC admite que nenhum dos modelos avaliados realmente descreve a relação entre as variáveis, mas o seleciona o modelo que minimiza as divergências. E o para BIC está implícita a existência de um modelo que descreva a relação, o que ele visa é maximizar a probabilidade de seleção do modelo verdadeiro. São considerados como melhores os modelos que apresentam os menores valores para os critérios citados, que na Tabela 5 estão na primeira linha.

Os resultados dos testes Ljung-Box são dados pelo valor de χ^2 , que é a estatística chi-quadrado e pelo p-valor, que indica a significância do teste. Nesses testes atendem a suposição de independência os resíduos que obtiverem o p-valor maior do que o nível de significância. Adotando $\alpha = 5\%$ todos os modelos na Tabela 5 apresentam independência dos resíduos.

Pelo teste ARCH-LM é possível verificar a existência de heterocedasticidade nos resíduos quadráticos, ou seja, quando o valor calculado do teste for estatisticamente significativo, ao nível de 5%, a hipótese nula de que não há heterocedasticidade, é rejeitada. Para o cálculo do teste foram utilizados 2 lags na hipótese alternativa, conforme resultado do modelo VAR.

Para os modelos indicados na Tabela 4 não há a presença de efeito ARCH para a série FTSE e JSE.JO, mas para as demais há heterocedasticidade. O resultado do teste evidencia a importância da utilização dos modelos *Autoregressive Conditional Heteroskedasticity* - ARCH ou *Generalized ARCH* – GARCH.

Os modelos com inclusão das variáveis exógenas foram desenvolvidos considerando os modelos ARIMA com menores critérios de avaliação, com a utilização de modelos ARCH ou GARCH nos resíduos. A sequência de modelos testados para cada uma das séries foi ARIMA-ARCH, ARIMA-GARCH, ARMAX, ARMAX-ARCH, ARMAX-GARCH.

Nos modelos ARMAX-GARCH foram testados o *Standard GARCH* – sGARCH, que consiste no modelo GARCH padrão; o *Exponential GARCH* – eGARCH, em que a volatilidade condicional pode ser assimétrica; *Integrated GARCH* – iGARCH, que permite a presença de raízes unitárias na série; *Glosten-Jagannathan-Runkle GARCH* – gjrGARCH, que inclui um componente de choque assimétrico na

modelagem; e *Asymmetric Power GARCH* – apGARCH com acréscimo de uma função de potência assimétrica na modelagem da volatilidade condicional. As variáveis que foram utilizadas como exógenas foram as três criptomoedas BTC, LTC e XRP, os melhores modelos, de acordo com os critérios e análise dos resíduos, estão indicados na Tabela 6.

Tabela 6 – Modelos ARIMA com Entradas Exógena mais adequados para as séries das Bolsas de Valores e criptomoedas

Série	Modelo ARIMA	Modelo com entrada Exógena	COEFICIENTES	Critérios de avaliação		Ljung-Box Test				ARCH-LM Test	
						Standardized Residuals		Standardized Squared Residuals			
				AIC	BIC	χ^2	pvalue	χ^2	p.value	χ^2	pvalue
SZZ	ARIMA (3,1,3)	ARIMAX(3,1,1) (BTC, LTC, XRP)-SGARCH(1,1)	AR1:0.6503 AR2:-0.0116 AR3:0.0257 MA1:-0.6681 BTC:-0.0004 XRP:-0.0001 LTC:0.0011 Ω :0.00001 α_1 :0.1088 β_1 :0.8875	-2177.61	-2169.03	1.6919	1.0000	0.3523	0.9779	0.1160	0.7335
AXAT	ARIMA (4,1,5) with drift	ARIMAX(4,1,1) (BTC, LTC, XRP)-SGARCH(3,0) with drift	μ :-0.0016 AR1:0.9135 AR2:0.939 AR3:0.0135 AR4:-0.0589 MA1:-1.0000 BTC:0.0010 XRP:0.0003 LTC:-0.0022 ω :0.0002 α_1 :0.2204 α_2 :0.2593 α_3 :0.0498	-2781.04	-2772.46	0.009	0.9223	0.0052	0.9420	0.4082	0.5229
BSESN	ARIMA (5,1,5) with drift	ARIMAX(5,1,1) (BTC, LTC, XRP)-SGARCH(1,1) with drift	μ :-0.0007 AR1:-0.8103 AR2:-0.0064 AR3:-0.0164 AR4:0.0512 AR5:0.0104 MA1:0.8553 BTC:-0.0004 XRP:-0.0001 LTC:0.0002 ω :0.00004 α_1 :0.1678 β_1 :0.7313	-2696,63	-2688,05	0.6716	0.4125	0.0252	0.8738	5.955	0.0147
DAX	ARIMA (3,1,3) with drift	ARIMAX(3,1,1) (BTC, LTC, XRP) -SGARCH(2,1) with drift	μ :-0.0022 AR1:-0.1041 AR2:-0.1668 AR3:-0.0513 MA1:0.9770 BTC:0.0002 XRP:-0.0008 LTC:-0.0010 ω :0.0001 α_1 :0.2397 α_2 :0.0000 β_1 :0.5002	-2256.99	-2448.42	3.3383	1.0000	1.4726	0.9304	0.0043	0.9479
FNCMX	ARIMA (4,1,4) with drift	ARIMAX(4,1,1) (BTC, LTC, XRP)-SGARCH(2,2) with drift	μ :-0.0011 AR1:0.9194 AR2:0.0398 AR3:-0.0223 AR4:0.0309 MA1:-1.0000 BTC:0.0004 XRP:0.0005 LTC:-0.0012 ω :0.0001 α_1 :0.1459 α_2 :0.2467 β_1 :0.0000 β_2 :0.5256	-2452.49	-2443.92	3.495	1.0000	2.9517	0.8743	0.0144	0.9045
FTSE	ARIMA (5,1,5) with drift	ARIMAX(5,1,5) (BTC, LTC, XRP) with drift	μ :-0.0036 AR1:0.3356 AR2:0.5192 AR3:0.5538 AR4:0.3094 AR5:-0.8732 MA1:-0.3731 MA2:-0.5403 MA3:-0.6319 MA4:-0.2693 MA5:0.9553 BTC:0.0100 XRP:-0.0008 LTC:0.0026	-2071.85	-2007.53	87.091	0.6801			1.6704	0.4338
HSI	ARIMA (1,1,1)	ARIMAX(1,1,1) (BTC, LTC, XRP)-SGARCH(1,1)	AR1:0.9762 MA1:-1.0000 BTC:0.0004 XRP:0.0005 LTC:-0.0006 ω :0.00004 α_1 :0.0916 β_1 :0.8602	-2346.13	-2337,55	0.8396	1.0000	1.3222	0.7835	0.7492	0.3867
IBOV	ARIMA (5,1,5) with drift	ARIMAX(5,1,1) (BTC, LTC, XRP)-SGARCH(2,0) with drift	μ :-0.0049 AR1:0.2150 AR2:0.0252 AR3:0.0616 AR4:0.0098 AR5:0.0505 MA1:-0.2625 BTC:0.0008 XRP:0.00001 LTC:-0.0011 ω :0.0006 α_1 :0.1579 α_2 :0.2609	-2248.72	-2240.15	5.3894	1.0000	1.1032	0.8359	0.4623	0.4965

IMOEX	MF	ARIMA (2,1,4)	ARIMAX(2,1,1) (BTC, LTC, XRP)-IGARCH(1,1)	AR1:-1.0821 AR2:-0.1018 MA1:0.9897 BTC:-0.0007 XRP:-0.0002 LTC:0.0004 ω :0.00004 α_1 :0.2881 β_1 :0.7119	-2405.24	-2394.23	5.0547	0.1798	1.3023	0.7883	0.3476	0.5555
JSE	JO	ARIMA (1,1,0)	ARIMAX(1,1,0) (BTC, LTC, XRP)	AR1:-0.1273 BTC:0.0143 XRP:0.0033 LTC:0.0089	-2122.37	-2100.93	82.488	0.9318			0.6755	0.7134
KLSE		ARIMA (1,1,2) with drift	ARIMAX(1,1,1)- (BTC, LTC, XRP) EGARCH(3,3) with drift	μ :-0.0029 AR1:0.0608 MA1:-0.1252 BTC:0.00001 XRP:-0.0005 LTC:0.0009 Ω :-2.8489 α_1 :-0.0142 α_2 :-0.0066 α_3 :0.0010 β_1 :-0.9181 β_2 :0.7051 β_3 :0.8842 γ_1 :0.3750 γ_2 :0.4316 γ_3 :0.1138	-3160.19	-3149.18	2.252	0.8899	6.2872	0.7681	0.1952	0.6586
KSII		ARIMA (5,1,4)	ARIMAX(5,1,1) (BTC, LTC, XRP)-EGARCH(2,4)	AR1:0.8143 AR2:0.0154 AR3:-0.0648 AR4:0.0456 AR5:-0.0363 MA1:-0.7907 BTC:0.0001 XRP:0.0005 LTC:-0.0003 ω :-0.5422 α_1 :-0.1431 α_2 :-0.1054 β_1 :0.1741 β_2 :0.5176 β_3 :0.5745 β_4 :-0.3356 γ_1 :0.3433 γ_2 :-0.1190	-2710.65	-2702.07	1.168	0.2798	3.464	0.0627	0.0398	0.8419
MERV		ARIMA (1,1,0) with drift	ARIMAX(1,1,1) (BTC, LTC, XRP) -EGARCH(5,3) with drift	μ :-0.0412 AR1:0.4719 MA1:-0.4213 BTC:0.0022 XRP:-0.0029 LTC:0.0013 ω :-0.6385 α_1 :-0.0691 α_2 :-0.0495 α_3 :-0.1143 α_4 :-0.0102 α_5 :-0.0538 β_1 :0.1351 β_2 :-0.1667 β_3 :0.9214 γ_1 :0.3259 γ_2 :0.4353 γ_3 :0.0106 γ_4 :-0.1044 γ_5 :-0.2007	-1643.96	-1635.38	2.890	0.5420	6.1820	0.9511	0.2717	0.6022
N100		ARIMA (3,1,3) with drift	ARIMAX(3,1,1) (BTC, LTC, XRP)-SGARCH(4,1) with drift	μ :-0.0043 AR1:-1.0569 AR2:-0.0883 AR3:-0.0172 MA1:0.9801 BTC:0.0006 XRP:0.0001 LTC:-0.0006 ω :0.0003 α_1 :0.2273 α_2 :0.2338 α_3 :0.0000 α_4 :0.0587 β_1 :0.0000	-2553.59	-2545.01	0.0003	0.9846	0.0006	0.9800	0.1189	0.7302
N225		ARIMA (3,1,4) with drift	ARIMAX(3,1,1) (BTC, LTC, XRP)-SGARCH(2,2) with drift	μ :0.0099 AR1:-0.8211 AR2:0.0008 AR3:-0.0091 MA1:0.8028 BTC:-0.0018 XRP:0.0009 LTC:0.0015 ω :0.0002 α_1 :0.0719 α_2 :0.1416 β_1 :0.0904 β_2 :0.4619	-2438.61	-2430.03	0.8889	0.3458	0.0417	0.8382	0.2862	0.5927
NSEI		ARIMA (1,1,3) with drift	ARIMAX(1,1,1) (BTC, LTC, XRP)-EGARCH(2,2) (with drift)	μ :-0.0022 AR1:0.9639 MA1:-1.0000 BTC:-0.0001 XRP:0.0004 LTC:-0.0009 ω :-0.5050 α_1 :-0.2395 α_2 :-0.0035 β_1 :0.3239 β_2 :0.6100 γ_1 :0.0901 γ_2 :0.2290	-2625.63	-2617.05	0.594	0.4409	0.0188	0.8910	0.0159	0.8995
SSE180		ARIMA (4,1,0)	ARIMAX(4,1,1) (BTC, LTC, XRP)-SGARCH(2,3)	AR1:-0.1197 AR2:-0.0161 AR3:0.0029 AR4:-0.0692 MA1:0.0575 BTC:-0.0006 XRP:0.00002 LTC:0.0013 ω :0.00003 α_1 :0.0798 α_2 :0.2280 β_1 :0.000001 β_2 :0.3877 β_3 :0.3013	-2371.63	-2360.62	4.7883	1.0000	2.0551	0.9901	0.0035	0.9525
SSMI		ARIMA (4,1,3)	ARIMAX(4,1,1) (BTC, LTC, XRP)-	AR1:0.2511 AR2:0.0255 AR3:0.0627 AR4:0.0737 MA1:-0.1632 BTC:-0.0002 XRP:0.0016 LTC:-0.0016	-2791.96	-2783.38	7.0874	0.7507	3.2606	0.3615	0.4977	0.4805

		EGARCH(1,1)	ω :-1.1008 α_1 :-0.4540 β_1 :0.8591 γ_1 :0.3738											
STI	ARIMA (5,1,3)	ARIMAX(5,1,1) (BTC, LTC, XRP)- EGARCH(5,5)	AR1:-0.7445 AR2:-0.0084 AR3:-0.0284 AR4:0.0102 AR5:-0.0494 MA1:0.7952 BTC:-0.0007 XRP:-0.0002 LTC:0.0012 ω :-0.0108 α_1 :-0.1854 α_2 :-0.0830 α_3 :0.2222 α_4 :-0.0655 α_5 :-0.0616 β_1 :0.0234 β_2 :0.8872 β_3 :0.3458 β_4 :0.0427 β_5 :-0.3009 γ_1 :0.1617 γ_2 :0.2123 γ_3 :0.2194 γ_4 :- 0.3041 γ_5 :-0.3430	-2934.08	-2923.06	3.8967	1.0000	10.777	0.8262	0.8672	0.3517			
TA35. TA	ARIMA (1,1,3)	ARIMAX(1,1,1) (BTC, LTC, XRP) - EGARCH(3,5) with drift	AR1:0.1087 MA1:-0.1648 BTC:-0.00002 XRP:0.0001 LTC:-0.0009 ω :-0.8473 α_1 :-0.1625 α_2 :0.0515 α_3 :-0.2157 β_1 :0.9946 β_2 :-0.7232 β_3 :0.6274 β_4 :0.3113 β_5 :-0.3186 γ_1 :-0.2025 γ_2 :0.0973 γ_3 :0.0799	-2842.54	-2831.53	3.1155	0.4011	10.811	0.5757	0.2291	0.6322			
TWII	ARIMA (3,1,3)	ARIMAX(3,1,1) (BTC, LTC, XRP)- EGARCH(5,5)	AR1:0.4974 AR2:-0.0463 AR3:0.0846 MA1:-0.5177 BTC:-0.00001 XRP:0.00007 LTC:-0.0009 ω :-1.0172 α_1 :-0.1246 α_2 :0.0571 α_3 :-0.000006 α_4 :0.0074 α_5 :-0.1547 β_1 :0.4669 β_2 :0.0448 β_3 :0.8881 β_4 :-0.5140 β_5 :-0.0287 γ_1 :0.3180 γ_2 :0.3192 γ_3 :-0.1388 γ_4 :-0.1096 γ_5 :-0.2330	-2290.77	-2279.76	4.8548	0.9773	8.2108	0.5913	1.102	0.2938			
BTC	ARIMA (3,1,2)	ARIMAX(3,1,1) (LTC, XRP)- EGARCH(4,4)	AR1:0.6866 AR2:-0.0713 AR3:0.1018 MA1:-0.6701 LTC:0.0009 XRP:-0.0018 ω :-0.5228 α_1 :0.0092 α_2 :- 0.0185 α_3 :0.0594 α_4 :-0.0361 β_1 :0.8388 β_2 :0.0095 β_3 :- 0.8741 β_4 :0.9158 γ_1 :0.3035 γ_2 :0.0441 γ_3 :0.2379 γ_4 :0.1551	-1150.38	-1139.36	2.5786	1.0000	8.2431	0.8246	0.4293	0.5123			
LTC	ARIMA (2,1,5)	ARIMAX(2,1,1) (BTC, XRP)- EGARCH(4,4)	AR1:-0.6062 AR2:-0.0906 MA1:0.5889 BTC:0.0009 XRP:-0.0010 ω :-0.4031 α_1 :-0.0214 α_2 :0.2618 α_3 :-0.3599 α_4 :0.3356 β_1 :0.9996 β_2 :-0.2419 β_3 :-0.6081 β_4 :0.7473 γ_1 :0.1989 γ_2 :0.2486 γ_3 :0.1435 γ_4 :0.1418	-848.85	-837.83	5.5430	0.0514	10.133	0.6458	1.593	0.2068			
XRP	ARIMA (5,1,5) with drift	ARIMAX(5,1,1) (BTC, LTC)- EGARCH(3,5)	AR1:1.1106 AR2:-0.0551 AR3:-0.4389 AR4:0.5277 AR5:-0.1641 MA1:-0.9142 BTC:0.0148 LTC:-0.0294 ω :-0.6965 α_1 :-0.3213 α_2 :-0.0539 α_3 :0.0500 β_1 :-0.8101 β_2 :-0.1873 β_3 :0.7500 β_4 :0.7616 β_5 :0.1973 γ_1 :0.4626 γ_2 :1.1149 γ_3 :0.8408	-34.18	-23.16	15.55	8.018e -05	0.8242	0.3639	9.092	0.0578			

Fonte: Autores (2023).

Na Tabela 6 constam os modelos para ARIMAX-GARCH e ARIMAX para as séries temporais dos índices das Bolsas de Valores e para as criptomoedas, os valores dos critérios de seleção e os resultados dos testes *Ljung-Box Test* e *ARCH-LM Test*. Para a seleção desses modelos foram testados os parâmetros de zero a cinco para cada um dos parâmetros, bem como as respectivas combinações, com dois *lags* de defasagem. As criptomoedas foram utilizadas, em todos os modelos, como exógenas, à exceção da própria série.

A quarta coluna da Tabela 6 estão os coeficientes dos modelos, que representa os parâmetros: " μ " que é o componente de média condicional do modelo, um valor constante; "AR1" até "AR5" termos autorregressivos; "MA1" até "MA5" termo de média móvel; " ω " termo de variância; " α_1 " até " α_5 " termo para o modelo por ARCH(q); " β_1 " até " β_5 " termo para o modelo GARCH(p); " γ_1 " até " γ_5 " termo de alavancagem; "BTC, XRP e LTC" termo das variáveis exógenas.

A inserção dos componentes ARCH e GARCH decorre da necessidade de modelar a volatilidade condicional, comum nas séries financeiras, decorrente da variação ao longo do tempo. A inclusão das variáveis exógenas foi efetuada para a verificação da afetação que as criptomoedas podem causar nos índices das Bolsas que servem de proxy para o mercado tradicional.

O resultado geral obtido pelos modelos gerados indica que as criptomoedas são capazes de afetar os índices das Bolsas de Valores, pois os modelos com a inserção delas como exógenas indicaram melhores valores para os critérios de avaliação. Entretanto, ao analisar os coeficientes dos termos das equações, que representam as exógenas, identifica-se que essa interferência pode ser considerada de moderada a fraca, já que, é necessário considerar a variabilidade da série. Pela Tabela 4 as séries com maior variabilidade são SZZ (China), MERV (Argentina), FNCMX (Estados Unidos) e FTSE (Inglaterra), assim como as criptomoedas, principalmente as séries BTC e XRP, respectivamente.

Outro aspecto importante com relação aos coeficientes das variáveis exógenas nos modelos é o sentido, quando o coeficiente é positivo existe uma relação positiva, e quando é negativo a relação negativa. Nas séries AXAT (Austrália), FTSE (Inglaterra), JSE.JO (África do Sul) os coeficientes das três criptomoedas possuem o mesmo sinal, positivo, que indica que um aumento nas exógenas está associado a um aumento no índice. Nas demais séries uma das séries exógenas possui coeficiente em sentido contrário das outras duas. De modo geral, os novos ativos não regulamentados são capazes de interferir no mercado de ativos tradicionais, mas de forma distinta.

As séries dos índices com menor influência das criptomoedas são TWII (Itália), TA35.TA (Israel), N100 (França) e BSESN (Índia) e as com maior influência são JSE.JO (África do Sul), FTSE (Inglaterra), MERV (Argentina), e XRP tomando como critério de comparação os coeficientes dos termos das variáveis exógenas nas equações geradas pelos modelos indicados na Tabela 6. Quanto menor for o coeficiente de um termo, menor será a influência desse termo na série endógena. No entanto, ainda que fraca a influência, é importante ser observada pois, se tratando de índices de Bolsas de valores, pode resultar em expressivas quantias monetárias.

Nos modelos selecionados para a definição do ajuste do modelo que melhor represente as séries dos índices foram encontrados, na maioria, heterocedasticidade nos resíduos. Por essa razão foram incluídos os modelos ARCH e GARCH e como a finalidade era verificar a influência das criptomoedas, elas foram acrescentadas como exógenas, que resultaram em modelos ARIMAX-GARCH.

Esse tipo de modelo foi definido como o mais adequado para os índices CAC40 e DAX30, analisados no período 1995-1999, e forneceu previsões de volatilidade de negociação estatisticamente superiores a outros modelos (DEGIANNAKIS, 2008). Também foi utilizado para modelar a inflação mensal em dez países pós-Segunda Guerra Mundial, foram encontradas fortes evidências de memória longa com comportamento de reversão à média para todos os países, exceto o Japão (CORSI; PIRINO; RENÒ, 2010).

A maioria dos estudos utilizam os modelos ARIMAX-GARCH em séries econômicas ou financeiras, mas outras séries também podem ser modeladas como é o caso o efeito das temperaturas e da velocidade do vento na variabilidade da demanda diária de energia elétrica na Silésia. Pelo modelo os autores descobriram que a relação entre carga elétrica e temperatura é afetada por uma especificação de heterocedasticidade condicional autorregressiva e por um componente dinâmico de temperatura na carga (WŁODARCZYK;; ZAWADA, 2010).

A combinação dos modelos que geram o ARIMAX-GARCH tem como diferencial, com relação aos demais modelos, a possibilidade de modelar tendências e comportamentos de longo prazo e capturar padrões de autocorrelação de longo alcance. A inserção do GARCH auxilia a modelar a volatilidade condicional, dessa forma a variabilidade pode ser alterada ao longo tempo em resposta a choques, bem como capturar comportamentos de cauda longa.

O diferencial do estudo é a possibilidade de verificar a influência de três criptomoedas, com comportamentos mercadológicos distintos, em muitos índices de Bolsas de Valores localizadas em diferentes áreas globais. É possível em um mesmo estudo atingir uma

amplitude maior de resposta para o resultado. Pelos modelos obtidos verificou-se que há a interferência das criptomoedas nos índices em comportamentos que diferem de localização, índice e criptomoeda analisados.

4 CONSIDERAÇÕES FINAIS

Pela metodologia ARMAX, combinada aos modelos de séries temporais ARCH e GARCH, foi possível identificar a influência das criptomoedas nas Bolsas de Valores, bem como pelo teste de causalidade de Granger identificou-se que o conjunto de séries, sendo vinte e uma Bolsas de Valores e três criptomoedas, possuem relação de causalidade uni ou bilateral. Esses resultados destacam que alterações das características de, pelo menos uma das séries do conjunto, pode gerar modificações nas demais, ainda que de maneira distinta.

Os modelos, com dependência de variáveis exógenas, identificaram como as séries das criptomoedas são capazes de interferir nos índices das Bolsas de Valores, ou seja, os novos ativos, que são independentes, possuem capacidade de interferir no mercado. Os coeficientes dos modelos das séries temporais mostram que as variáveis exógenas influenciam a séries dos índices de forma distinta, pois coeficiente positivo indica uma relação positiva, enquanto um coeficiente negativo indica uma relação negativa. As séries em que todos os coeficientes das exógenas são positivas são AXAT, FTSE e JSE.JO. Pela análise dos coeficientes dos modelos para as criptomoedas verificou-se que a influência pode ser considerada moderada ou fraca, pois as variações, ainda que pequenas, podem gerar ganhos ou perdas importantes.

A maioria dos modelos mais adequados para os índices das Bolsas de Valores combinou ARIMA (*AutoRegressive Integrated Moving Average*), com a inclusão de componentes de média móvel integrada fracionária, com variáveis exógenas e modelo GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*), para modelar a volatilidade condicional em séries temporais, considerando a heterocedasticidade condicional. Esse modelo fornece previsões superiores, mais flexíveis em diferentes cenários, e auxilia a analisar a relação de causalidade entre a série de interesse e a exógena, o que foi a principal contribuição com o estudo.

É importante ressaltar que a combinação de vários modelos de séries temporais pode ser um fator inviabilizador para a reprodução de estudos, pois exige do pesquisador extenso conhecimento das características dos modelos. Contudo, pela união dos métodos é possível identificar as características comportamentais de cada série e, principalmente no caso dos modelos ARMAX, há a possibilidade de caracterizar o desempenho de variáveis externas ao comportamento interno das séries. Uma das principais limitações deste estudo consistiu na

disponibilidade limitada de séries temporais com periodicidades similares, para variáveis qualitativas e quantitativas. Recomenda-se, para futuras pesquisas, a substituição de séries no conjunto de dados, especialmente as relacionadas às criptomoedas para avaliar se isso afeta os resultados obtidos.

INFLUENCE OF CRYPTOCURRENCIES ON GLOBAL STOCK EXCHANGES

ABSTRACT

Cryptocurrencies are a challenge to traditional asset markets, so it is important to understand how these assets can interfere with the market. The objective of this study is to analyze the influence of three cryptocurrencies on a set of twenty-one Stock Exchanges, using the ARMAX methodology as an analytical tool. The selected series are indices from 21 stock exchanges on different continents and three cryptocurrencies traded on the market, with a weekly frequency from the first week of May 2013 to the last week of August 2023. The exchange and cryptocurrency index series were modeled, starting from the ARIMA, ARIMAX, ARIMAX-ARCH, ARIMAX-GARCH models. Moreover, the cryptocurrency series were inserted into the models as exogenous. In all series, the inclusion of exogenous variables generated improvements in the models, proving that cryptocurrencies can interfere with stock exchange indices, that is, changes that occur in this type of asset can generate interference in the traditional market. Key-words: Cryptocurrencies, Stock Exchanges, ARMAX

REFERÊNCIAS BIBLIOGRÁFICAS

AIKEN, L. H. et al. Nurse staffing and education and hospital mortality in nine European countries: a retrospective observational study. **The Lancet**, v. 383, n. 9931, p. 1824–1830, 24 maio 2014.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716–723, dez. 1974.

ARIA, M.; CUCCURULLO, C. bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v. 11, n. 4, p. 959–975, 1 nov. 2017.

BDQueimadas - Programa Queimadas - INPE. Disponível em: <<http://terrabrasilis.dpi.inpe.br/queimadas/bdqueimadas/#graficos>>. Acesso em: 1 dez. 2023.

BLANCHARD, O. J. et al. **Monetary Policy Matter? A New Spirit of Friedman and Schwartz**. [s.l.] MIT Press, 1989. v. Title

BOLLERSLEV, T. GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSKEDASTICITY. **Journal of Econometrics**, v. 31, n. 3, p. 307–327, 1986.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 3. ed. New Jersey: Printice Hall, 1994.

- BROOKS, C. **Introductory Econometrics for Finance**. Disponível em: <<https://www.amazon.com.br/Introductory-Econometrics-Finance-Chris-Brooks/dp/052169468X>>. Acesso em: 10 out. 2020.
- BURGOYNE, J.; JAMES, K. T. Towards best or better practice in corporate leadership development: Operational issues in mode 2 and design science research. **British Journal of Management**, v. 17, n. 4, p. 303–316, dez. 2006.
- ÇAĞDAŞ, V.; STUBKJÆR, E. Design research for cadastral systems. **Computers, Environment and Urban Systems**, v. 35, n. 1, p. 77–87, jan. 2011.
- CAUCHICK-MIGUEL, P. A. et al. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 3. ed. Rio de Janeiro: Elsevier, 2018.
- CORRAR, L. J.; PAULO, E.; DIAS FILHO, J. M. **Análise Multivariada: Para Os Cursos De Administração, Ciências Contábeis E Economia**. 1. ed. São Paulo: Atlas, 2014.
- CORSI, F.; PIRINO, D.; RENÒ, R. Threshold bipower variation and the impact of jumps on volatility forecasting. **Journal of Econometrics**, v. 159, n. 2, p. 276–288, 1 dez. 2010.
- DEGIANNAKIS, S. ARFIMAX and ARFIMAX-TARCH realized volatility modeling. **Journal of Applied Statistics**, v. 35, n. 10, p. 1169–1180, out. 2008.
- DICKEY, D. A.; FULLER, W. A. Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. **Econometrica**, v. 49, n. 4, p. 1057, jul. 1981.
- DING, Z.; GRANGER, C. W. J.; ENGLE, R. F. A long memory property of stock market returns and a new model. **Journal of Empirical Finance**, v. 1, n. 1, p. 83–106, 1 jun. 1993.
- DUEKER, M. Dynamic Forecasts of Qualitative Variables. **Journal of Business & Economic Statistics**, v. 23, n. 1, p. 96–104, jan. 2005.
- EKONG, N. et al. A Comparative Study of the Impact of Dummy Variables on Regression Coefficients and Canonical Correlation Indices: An Empirical Perspective. **International Journal of Analysis and Applications**, v. 19, n. 4, p. 576–586, 17 jun. 2021.
- ENDERS, W. **Applied Econometric Time Series**. Disponível em: <<https://www.wiley.com/en-us/Applied+Econometric+Time+Series%2C+4th+Edition-p-9781118808566>>. Acesso em: 10 out. 2020.
- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987, jul. 1982a.
- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987, jul. 1982b.
- ENGLE, R. F.; BOLLERSLEV, T. Modelling the persistence of conditional variances. **Econometric Reviews**, v. 5, n. 1, p. 1–50, 1986.
- ENGLE, R. F.; GRANGER, C. W. J. Co-Integration and Error Correction: Representation, Estimation, and Testing. **Econometrica**, v. 55, n. 2, p. 251, mar. 1987.

- FERNANDES RC, C. F. W. Espacialização temporal dos focos de queimadas e de poluentes atmosféricos (Co , Ch4 , No2 , N2o) em Alagoas. **Ciência e Natura**, p. 287–294, 2013.
- FERREIRA, P. C. et al. **Análise de Séries Temporais em R: Curso Introductório**. 1. ed. Rio de Janeiro: Elsevier, 2018.
- FRANSES, P. H. Primary Demand for Beer in the Netherlands: An Application of ARMAX Model Specification. **Journal of Marketing Research**, v. 28, n. 2, p. 240–245, 6 maio 1991.
- FREITAS, S. R. et al. Emissões de queimadas em ecossistemas da América do Sul. **Estudos Avançados**, v. 19, n. 53, p. 167–185, 2005.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.
- GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. **The Journal of Finance**, v. 48, n. 5, p. 1779, dez. 1993.
- GRANGER, C. W. J. DEVELOPMENTS IN THE STUDY OF COINTEGRATED ECONOMIC VARIABLES. **Oxford Bulletin of Economics and Statistics**, v. 48, n. 3, p. 213–228, 1 maio 1986.
- HANNAN, E. J.; QUINN, B. G. The Determination of the Order of an Autoregression. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 41, n. 2, p. 190–195, jan. 1979.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice (2nd ed)**. Australia: [s.n.].
- JOHANSEN, S. Statistical analysis of cointegration vectors. **Journal of Economic Dynamics and Control**, v. 12, n. 2–3, p. 231–254, jun. 1988.
- KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, n. 1–3, p. 159–178, out. 1992.
- LACERDA, D. P. et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741–761, 26 nov. 2013.
- LARA, L. L. et al. Properties of aerosols from sugar-cane burning emissions in Southeastern Brazil. **Atmospheric Environment**, v. 39, n. 26, p. 4627–4637, 2005.
- LI, C.; LI, M.; LI, Y. Improving estimation of forest aboveground biomass using landsat 8 imagery by incorporating forest crown density as a dummy variable. **Canadian Journal of Forest Research**, v. 50, n. 4, p. 390–398, 2020.
- LIANG, J.; LI, L.; ZENG, D. Evolutionary dynamics of cryptocurrency transaction networks: An empirical study. **PLOS ONE**, v. 13, n. 8, p. e0202202, 17 ago. 2018.
- LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, n. 2, p. 297–303, 1 ago. 1978.
- LOUZADA, F. et al. **Controle Estatístico de Processos-Uma Abordagem Prática para**

Cursos de Eng. e Administração. LTC ed. Rio de Janeiro: [s.n.].

MALHOTRA, N. K. **Pesquisa de Marketing** -. 4^a ed. Porto Alegre: Bookman, 2006.

MARCH, S. T.; SMITH, G. F. **Design and natural science research on information technology Decision Support Systems.** [s.l: s.n.].

MARCONI, M. DE A.; LAKATOS, E. M. **Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisas, elaboração, análise e interpretação de dados.** 8. ed. São Paulo: Atlas, 2018.

MIAO, J. et al. A Dummy-Variable Model for Humidity-Influenced DC Film Capacitors Lifetime Estimation. **IEEE JOURNAL OF EMERGING AND SELECTED TOPICS IN POWER ELECTRONICS**, v. 11, p. 1056–1070, 2023.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros.** Rio de Janeiro: [s.n.].

MORETTIN, P. A. . **Econometria Financeira: um Curso em Séries Temporais Financeiras.** 3. ed. São Paulo: Blucher, 2017.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais.** São Paulo: Blucher, 2004.

NAKAMOTO, S. **Bitcoin: A Peer-to-Peer Electronic Cash System.** [s.l: s.n.]. Disponível em: <www.bitcoin.org>. Acesso em: 11 out. 2020.

NELSON, D. B. Conditional Heteroskedasticity in Asset Returns: A New Approach. **Econometrica**, v. 59, n. 2, p. 347, mar. 1991.

PEARL, J. Fusion, Propagation, and Structuring in Belief Networks. In: **Probabilistic and Causal Inference.** New York, NY, USA: ACM, 1986. v. 29p. 241–288.

PECICAN, E. S. Forecasting Based on Open VAR Model. **Romanian Journal of Economic Forecasting-1**, v. 1, p. 59–69, 2010.

PEFFERS, K. et al. A Design Science Research Methodology for Information Systems Research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45–77, 8 dez. 2007.

PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, v. 75, n. 2, p. 335–346, 1988.

ROMME, A. G. L. Making a Difference: Organization as Design. **Organization Science**, v. 14, n. 5, p. 558–573, out. 2003.

SCHWARZ, G. Estimating the Dimension of a Model. **The Annals of Statistics**, 1978.

SENNA, V. DE; MENDONÇA, A.; SOUZA. **Expense Relation Analysis in Social Program Welfare in Brazil.** Verlag: Éditions universitaires européennes, 2017.

SENNA, V. DE; SOUZA, A. M. Assessment of the relationship of government spending on social assistance programs with Brazilian macroeconomic variables. **Physica A: Statistical**

Mechanics and its Applications, v. 462, p. 21–30, nov. 2016.

SENNÁ, V. DE; SOUZA, A. M. Criptomoadas e sistema financeiro: revisão sistemática de literatura. **Revista de Administração de Empresas**, v. 63, n. 4, p. e2022- 0019, 8 set. 2023.

SIMON, H. A. **The Sciences of the Artificial**. [s.l: s.n.]. v. 11

SIMS, C. A. Macroeconomics and Reality. **Econometrica**, 1980.

SUGIURA, N. Further analysis of the data by Akaike's information criterion and the finite corrections. **Communications in Statistics - Theory and Methods**, v. 7, n. 1, p. 13–26, 1 jan. 1978.

THOMÉ, A. M. T.; SCAVARDA, L. F.; SCAVARDA, A. J. Conducting systematic literature review in operations management. **Production Planning & Control**, v. 27, n. 5, p. 408–420, 3 abr. 2016.

VAN AKEN, J. E. Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules. **Journal of Management Studies**, v. 41, n. 2, p. 219–246, 10 fev. 2004.

WANG, X. Z. et al. Gas Leakage Prediction Model of Large-Scale Explosions in Hard Rock Based on Quantification Theory. **Transport in Porous Media**, v. 95, n. 1, p. 171–183, 28 out. 2012.

WANG, Z.-X.; HE, L.-Y.; ZHAO, Y.-F. Forecasting the seasonal natural gas consumption in the US using a gray model with dummy variables. **Applied Soft Computing**, v. 113, p. 108002, dez. 2021.

WŁODARCZYK, A.; ZAWADA, M. **Modeling the impact of the weather factors on the electrical energy consumption in one of the regions in the southern Poland**. Disponível em: <<https://ieeexplore-ieee-org.ez47.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=5558738>>. Acesso em: 7 nov. 2023.

Yahoo Finanças. Disponível em: <<https://br.financas.yahoo.com/>>.

7 ARTIGO 5 - OTIMIZAÇÃO DAS PREVISÕES COM A INTEGRAÇÃO DE VARIÁVEIS QUALITATIVAS EM MODELOS DE SÉRIES TEMPORAIS

Viviane de Senna, E-mail: vivianedsenna@hotmail.com

Adriano Mendonça Souza, E-mail: amsouza.sm@gmail.com

RESUMO

Os ativos tradicionais são normalmente transacionados nas bolsas de valores, que são reconhecidas como ambientes seguros para a realização de negociações. No entanto, a introdução de novos ativos e variáveis qualitativas, como eventos climáticos inesperados, pode influenciar o comportamento desses mercados. Diante desse cenário, o objetivo do estudo é o desenvolvimento de um modelo preditivo de séries temporais aprimorado pela inserção de variáveis qualitativas no modelo para otimizar as previsões. Para isso, foram incorporadas variáveis exógenas quantitativas de três criptomoedas e uma variável qualitativa relacionada aos focos de queimadas nos modelos de séries temporais ARIMAX, ARIMAX-ARCH e ARIMAX-GARCH. Essa abordagem resultou em melhorias no desempenho dos modelos. Os modelos que com a presença de volatilidade foram aprimorados pela inclusão de uma variável qualitativa do tipo *dummy*, indicando a ocorrência de focos de queimadas acima do terceiro quartil de observações. Essas melhorias demonstram a relevância e eficácia da consideração de variáveis qualitativas em modelos preditivos, especialmente em um contexto em que eventos imprevistos podem exercer impactos substanciais nos mercados financeiros. Essa abordagem aprimorada contribui para a robustez e precisão das previsões, possibilitando uma análise mais abrangente e informada do comportamento do mercado.

Palavras-chave: modelos de séries temporais, variáveis qualitativas, variáveis *dummy*, focos de queimadas.

1 INTRODUÇÃO

Distintas razões podem influenciar nos resultados de processos produtivos, econômicos ou sociais. As mudanças ocorridas em uma série temporal financeira ou econômica são atribuídas a eventos de grande escala, como guerras, pandemias, mudanças na política governamental, que podem não apenas torná-la mais volátil do que anteriormente, como modificar seu comportamento (BROOKS, 2008). Por eventos que podem mudar repentinamente o comportamento de uma série temporal, se torna importante investigar quando e onde as mudanças poderão ocorrer e quais as variáveis têm maior capacidade de interferência. Mensurar como determinadas situações podem intervir no comportamento é um vasto campo a ser explorado, especialmente na área financeira.

Na economia os ativos tradicionais são negociados nas Bolsas de Valores, que são considerados balcões de negociação seguros e fazem parte de uma atividade regulamentada por Banco Centrais vinculados aos países. Contudo, essa não é mais a única maneira de efetuar negociações, desde 2008 foram criadas as criptomoedas, iniciadas pelo Bitcoin

(NAKAMOTO, 2008), em que os usuários são capazes de efetuar negociações diretas, sem a necessidade de um intermediário como as Bolsas de Valores ou unidades bancárias. O controle das transações é feito pelo *Blockchain* que é uma tecnologia de registro, semelhante aos livros de registros contábeis, que garante a visibilidade das transações por todos os usuários e garante a transparência das negociações.

Entretanto, as transações financeiras tradicionais ou os novos ativos, como as criptomoedas estão sujeitas a diversas interferências. Algumas delas podem ser geradas por uma regulamentação ou uma negociação expressiva, outras podem ser advindas de variáveis qualitativas geradas de formas aleatórias, como discursos de representantes de nações, fenômenos da natureza, ou acontecimentos inesperados. O problema desse estudo é: como a inclusão de variáveis qualitativas, como eventos climáticos inesperados, em modelos de previsão de séries temporais pode melhorar a precisão das previsões e proporcionar uma análise mais abrangente do comportamento do mercado financeiro?

A diferenciação do artigo consiste na abordagem inovadora de desenvolver um modelo de previsão de séries temporais aprimorado pela inclusão de variáveis qualitativas. **O objetivo do estudo é o desenvolvimento de um modelo de previsão de séries temporais aprimorado pela inserção de variáveis qualitativas no modelo para otimizar as previsões.**

Os modelos de séries temporais possuem alta precisão para a geração de previsões, mas *outliers* podem afetar a qualidade das previsões, mas eles são comuns de serem identificados. Esses *outliers*, que são observações com características únicas notadamente diferentes das demais, podem ser causados por variáveis qualitativas e podem ser definidas como categóricas ou classificações (CORRAR; PAULO; DIAS FILHO, 2014).

A pesquisa torna-se importante por fazer uma ligação entre as cotações das principais bolsas de valores e as queimadas ocorridas no seu país de origem da Bolsa de Valores. Sabe-se que as queimadas são um dos principais fatores de emissão de gás carbônico na atmosfera, e conseqüentemente afeta o desempenho das bolsas de valores. Captar estes episódios de queimadas e quantificá-los, embora sejam tratados muitas vezes como *outliers* qualifica as previsões e contribui como uma nova abordagem para qualificar as previsões realizadas pela análise de séries temporais. O número de queimadas é uma medida de frequência e muitas vezes não é possível avaliar o seu grau de intensidade ou destruição, para este caso utiliza-se uma padronização por meio da utilização de quartis, que auxiliarão na parametrização da variável qualitativa que será expressa em *dummies*.

A viabilidade do objetivo proposto se dará pelo ajuste de um modelo da classe geral ARIMA, em que as variáveis a serem modeladas serão os índices de valores incluindo-se criptomoedas tendo como variáveis exógenas o foco de queimadas, após a padronização realizada pelos quartis. Após estabelecer o modelo adequado, o mesmo será avaliado por meio do gráfico de Controle de Somas Acumuladas – CuSum modificado, para avaliar a estabilidade do modelo e monitorar o desempenho da variável, este será um procedimento utilizado para garantir a assertividade do modelo proposto.

O estudo está estruturado em quatro seções, sendo a primeira composta por esta breve introdução. A segunda seção traz a descrição do método proposto utilizando como base as séries semanais de índices das Bolsas de Valores, as criptomoedas e a variável qualitativa. A terceira seção contempla os resultados e discussões e a quarta seção apresenta as considerações finais e recomendações para trabalhos futuros.

2 METODOLOGIA

Para a criação do modelo de séries temporais com a inserção de variáveis qualitativas foram inicialmente selecionadas séries de índices Bolsas de Valores de Países e continentes diferentes e três criptomoedas. Os índices das Bolsas são indicadores capazes de medir o desempenho de um grupo de ações listadas nessa Bolsa, pois geralmente são gerados a partir de ponderações do valor de mercado das ações, sendo influenciado pelas empresas com maior capitalização de mercado.

As observações foram coletadas no período compreendido entre a primeira semana de maio de 2013 e a última semana de agosto de 2023, compondo 539 observações semanais de cada série. Inicialmente a periodicidade das séries foi diária, no entanto, como não foi possível definir modelos devido à alta volatilidade, as séries foram novamente coletadas em periodicidade semanal. O período selecionado, de 2013 a 2023, oportuniza a avaliação de distintos comportamentos dos índices, como crises e recuperações.

As séries das criptomoedas receberam valores das médias entre os registros diários para complementar a paridade de quantidade de observações, nos casos em que elas não foram encontradas, sem exceder dois por cento do total de observações coletadas. As séries foram coletadas no site Yahoo Finanças (“Yahoo Finanças”, 2023) e para as análises foi utilizado o *software* livre RStudio. Na Tabela 1, constam as séries dos índices das Bolsas de Valores e das criptomoedas, selecionados para o estudo.

Tabela 1 – Índices das Bolsas de Valores e criptomoedas selecionadas para o estudo

Código	Nome do Índice	Bolsa de Valores	País
159903.SZZ	China SZSE Component Index Fund/ETF	Shenzhen	China
AXAT	Austrália S&P/ASX ALL Australian 200	Austrália	Austrália
BSESN	Índia Bombay S&P BSE Sensex	Bombaim	Índia
DAX	Frankfurt Global X DAX Germany ETF	Frankfurt	Alemanha
IBOV	IBOVESPA	B3, Brasil Bolsa Balcão	Brasil
IMOEX.ME	MOEX Russia Index	Moscow	Rússia
JSE.JO	JSE Limited	Johannesburg	África do Sul
FNCMX	Fidelity NASDAQ Composite Index	Nasdaq	Estados Unidos
FTSE	London FTSE 100	Londres	Inglaterra
HSI	Hang Seng Index	Hong Kong	China
KLSE	FTSE Bursa Malaysia KLCI	Malásia	Malásia
KS11	Korea KOSPI Composite Index	Coreia do Sul	Coreia do Sul
MERV	MERVAL	Buenos Aires	Argentina
N100	EURONEXT 100	Paris	França
N225	Nikkei 225 Osaka	Tokyo	Japão
NSEI	Índia NIFTY 50	Índia	Índia
SSE180	SSE 180 Index	Shanghai	China
SSMI	Suíça SMI	Suíça	Suíça
TWII	FTSE MIB Index	Milão	Itália
BTC	Bitcoin	Criptomoeda	
LTC	Litecoin	Criptomoeda	
XRP	Ripple	Criptomoeda	

Fonte: Autores (2023)

Para as séries indicadas na Tabela 1, os modelos seguem metodologicamente os modelos ajustados por Senna e Souza (2024). Esses modelos iniciaram pelos *AutoRegressive Integrated Moving Average* - ARIMA e testados na sequência os modelos *AutoRegressive Integrated Moving Average with eXogenous inputs* - ARIMAX, *AutoRegressive Integrated Moving Average with eXogenous inputs and Autoregressive Conditional Heteroskedasticity* - ARIMAX-ARCH e *AutoRegressive Integrated Moving Average with eXogenous inputs and Generalized Autoregressive Conditional Heteroskedasticity* ARIMAX-GARCH. Os foram utilizados como base para a inserção da variável qualitativa para a tentativa de melhoramento.

As variáveis qualitativas selecionadas foram referentes à existência de focos queimadas. Essas variáveis compõem os principais agentes causadores de emissões de gás carbônico na atmosfera, que tem como consequência o aquecimento global capaz de provocar predação na agricultura, mudanças climáticas e desastres naturais (FERNANDES RC, 2013; FREITAS et al., 2005; LARA et al., 2005). A definição dessa variável decorre das temáticas estoques de carbono orgânico que se relacionam com estudos sobre as criptomoedas e as bolsas de valores (SENNA; SOUZA, 2023).

Os focos de queimadas foram coletados no site do Instituto Nacional de Pesquisas Espaciais – INPE (“BDQueimadas - Programa Queimadas - INPE”, [s.d.]). A definição dos focos é feita por imagem de satélite por resolução de imagem, pixel, que varia de 375m x

375m até 5km x 4km, dependendo do satélite. Dentro de um pixel pode ocorrer mais de um foco, mas será registrado como um único ponto, bem como se o fogo na vegetação for extenso a detecção será feita em alguns píxeis, contando vários focos de um grande evento. As detecções efetuadas por mais de um satélite são unificadas pelo sistema para que não ocorra a duplicação da informação.

Foram coletadas as observações para todo o país de origem da respectiva Bolsa de Valores, sem separação por região, e de todos os satélites disponíveis, durante o período semanal definido para as séries das Bolsas. Os focos foram transformados em variáveis *dummy* para serem incluídos ao modelo previamente definido para as séries das Bolsas de Valores (Senna, Souza, 2024). As definições da variável e dos critérios utilizados para geração dessas variáveis estão definidas na seção seguinte.

2.1 VARIÁVEIS *DUMMY*

Uma variável independente *dummy* é usada para indicar a presença ou ausência de determinado atributo qualitativo, ela pode ser chamada de variável binária ou categórica (CORRAR; PAULO; DIAS FILHO, 2014), ou ainda dicotômicas, instrumentais ou qualitativas (MALHOTRA, 2006). Essa variável pode tomar dois valores, “0” ou “1”, em que se usa “0” para ausência da variável e “1” para a presença.

Essas variáveis podem ser usadas para avaliar qualitativamente algumas situações com mais de uma alternativa sem atribuição de precedência entre elas categórica (CORRAR; PAULO; DIAS FILHO, 2014). A análise do coeficiente da *dummy* indica se há diferença estatística com a sua inserção, se estatisticamente significativa. Estudos realizados por PEARL, (1986); AIKEN et al., (2014).; LI; LI; LI, (2020); EKONG et al., (2021); WANG; HE; ZHAO, (2021) e MIAO et al., (2023) mostram a sua aplicabilidade e eficiência.

Para esse estudo, foi possível observar na série de frequência de ocorrência de focos de queimadas que em todos os períodos são registrados focos. Para padronizar esta variável foi dividida em quartis e, para a inserção no modelo, admitiu-se *dummy* igual a 1 para as variáveis com frequências posicionadas acima do terceiro quartil. Como existem registros de focos de queimadas durante todos os períodos coletados, o estudo buscou destacar as observações em que existem muitos focos ocorrendo simultaneamente, considerando um problema de queimadas crítico. Os demais quartis, abaixo do terceiro, receberam o valor “0” para a *dummy*, dada a menor gravidade da situação geral. A variável foi inserida no modelo como uma variável exógena, juntamente com as criptomoedas.

Após o ajuste dos modelos, os resíduos foram monitorados para detectar a presença de mudanças sistemáticas na variável e a estabilidade do processo por meio dos gráficos de controle de somas acumuladas.

2.2 GRÁFICO DE SOMAS ACUMULADAS CUSUM MODIFICADO

Uma forma de monitoramento da variabilidade do processo é a aplicação de gráficos de controle estatístico. Os gráficos de controle são utilizados como ferramenta no Controle Estatístico de Processos – CEP, indicam quando um processo sofre modificações que afetam seu desempenho devido a causas comuns ou assinaláveis (MONTGOMERY; RUNGER, 2014). As causas comuns são a soma dos efeitos de variações provenientes de muitas fontes inevitáveis e inerentes ao processo e não alteram substancialmente o desempenho do processo. As causas especiais são frutos de fontes que geram variabilidade que não podem ser explicadas adequadamente por uma distribuição e causam anomalias no processo analisado, logo o gráfico de controle CuSum tem a função de distinguir causas comuns de causas assinaláveis.

O Gráfico de Controle da Soma Cumulativa – CuSum modificado, que é uma ferramenta capaz de acumular informações das amostras de um processo, ponderando todas as amostras com um mesmo peso (LOUZADA et al., 2013). Quando o gráfico CuSum é modificado os desvios são comparados com os desvios da série ajustada incorporando ao desenvolvimento dos gráficos antigas estruturas de séries temporais.

O gráfico foi aplicado aos resíduos para que seja possível monitorar se ocorrem mudanças estruturais no modelo ao longo do tempo após a inserção da variável qualitativa como exógena. Um aumento no número de pontos fora de controle pode indicar mudança na estrutura dos resíduos, como uma tendência, sazonalidade ou padrão. Já uma redução de pontos fora de controle pode indicar uma melhoria na precisão do modelo, mas se essa redução for excessiva pode indicar a necessidade de avaliar a eficácia do modelo, em função de uma simplificação excessiva. A utilização do gráfico CUSUM contribui para a avaliação do modelo proposto, sinalizando se houve uma sub ou super especificação do modelo, trazendo qualidade ao modelo final proposto.

3 RESULTADOS E DISCUSSÕES

As quantidades de focos de queimadas são referentes às ocorrências em todo o território do país de origem da respectiva Bolsa de Valores, sem distinção de regiões, com coletas efetuadas por todos os satélites disponíveis no site em periodicidade semanal. Após

efetuada a coleta das variáveis qualitativas no site do INPE (“BDQueimadas - Programa Queimadas - INPE”, [s.d.]), elas foram transformadas em variáveis *dummy* do tipo “0” ou “1”. Sendo “0” para os focos de queimadas até o terceiro quartil e “1” para os valores posicionados acima do terceiro quartil, visto que, em praticamente todos os períodos das séries, existem registros de focos de queimadas ocorrendo.

Os modelos ARIMAX-GARCH e ARIMAX utilizados como base para a inserção da variável qualitativa são oriundos do artigo Senna e Souza (2024). Os resultados obtidos para cada uma das séries são mostrados nas Tabelas 2 a 20 e nas Figuras 1 a 38. O melhor modelo selecionado para a série da Bolsa de Shenzhen, código 159903.SZZ, da China, foi o ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(1,1). A Tabela 2 indica os coeficientes, os critérios de avaliação e os resíduos dos modelos antes e depois da inserção da variável qualitativa

Tabela 2 – Comparação do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(1,1) para a série 159903.SZZ antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.


Coeficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa		Modelo com qualitativa	
	AR1	0,65025930	0,65019247	Critérios		
AR2	-0,01164542	-0,01210310	AIC_value	-2177,612	-2177,688	
AR3	0,02571354	0,02659434	BIC_value	-2169,033	-2169,109	
MA1	-0,66809420	-0,66771196	Resíduos			
BTC	-0,00041311	-0,00038535	Mínimo	-0,14841140	-0,14853440	
XRP	-0,00012119	-0,00012256	Primeiro Quartil	-0,01897290	-0,01897360	
LTC	0,00105146	0,00103848	Mediana	-0,00113080	-0,00110850	
Queimadas		-0,00076074	Média	-0,00088870	-0,00088150	
ω	0,00001490	0,00001484	Terceiro Quartil	0,01828630	0,01830750	
α_1	0,10882080	0,10854768	Máximo	0,20841910	0,20827350	
β_1	0,88747370	0,88778523				

Fonte: Autores (2024).

A série da variável qualitativa Focos de queimada na China, utilizada para o ajuste do modelo na Tabela 2, é composta por 539 observações semanais, com no mínimo 237 e no máximo 87.686 focos por semana, resultando em uma média de 13.647,42 focos e desvio padrão de 10.858,16. A quantidade de focos acima do terceiro quartil, que recebeu o valor 1 da *dummy*, possui valores acima de 16.111,50.

Os coeficientes dos modelos são semelhantes com melhora nos valores do modelo que recebeu a variável qualitativa, pois a inclusão dela no modelo permitiu melhoria nos coeficientes estimados. Isso foi decisivo para entender como a qualidade influencia os resultados. A Figura 1 indica, na parte superior, os resíduos do modelo antes da inserção da qualitativa, e na parte inferior os resíduos após a inserção dela.

Figura 1 – Resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(1,1) para a série 159903.SZZ antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.




Fonte: Autores (2024).

Os gráficos dos resíduos da Figura 1 são semelhantes, tendo como diferenciação a amplitude total, que é reduzida após a inserção da variável qualitativa. Essa redução indica que as previsões do modelo tendem a ser mais precisas, ou seja, o modelo está explicando uma maior proporção da variação total nos dados. A presença de *outliers* pode ser observada pelos valores mínimo e máximo nos resíduos, de ambos os gráficos. Apesar da existência de valores extremos, eles não parecem ser excessivamente influentes. A inclusão da variável de qualidade pode fornecer uma melhor avaliação dos efeitos residuais, ajudando a identificar e capturar melhor a variabilidade que não foi explicada pelos outros termos.

A Figura 2 é composta por dois gráficos de controle, sendo o primeiro resultante do modelo sem variável qualitativa e o segundo com a inserção da variável *dummy*. Os gráficos de controle CuSum modificados tem a finalidade de monitorar as mudanças na estrutura dos resíduos ao longo do tempo. Se houver uma alteração na estrutura, isso pode indicar que o modelo precisa ser ajustado para capturar as novas características dos dados.

Figura 2 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(1,1) para a série 159903.SZZ antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.



Fonte: Autores (2024).

No estudo a aplicação do gráfico CuSum modificado visa identificar se ocorre uma modificação nos resíduos do modelo proposto. Pela comparação dos pontos fora de controle existentes nos dois gráficos da Figura 2 identifica-se a redução na quantidade de pontos fora de controle. Ou seja, a variável qualitativa, focos de queimadas, está interferindo na captura de comportamentos não modelados anteriormente. O modelo que recebeu a variável qualitativa pode resultar em um modelo que se adapta melhor aos dados, capturando padrões que não são refletidos sem ela. Isso pode levar a previsões mais precisas, especialmente se a qualitativa for uma variável relevante para o comportamento dos dados.

A série AXAT representa o índice “Austrália S&P/ASX ALL Australian 200” da bolsa de valores da Austrália através do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(1,1) *with drift*. A Tabela 3 apresenta o comparativo entre o modelo citado e o modelo com a inserção da variável qualitativa focos de queimadas semanais ocorridas na Austrália no período do estudo.


Tabela 3 – Comparação do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(3,0) *with drift* para a série AXAT antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Austrália.

Coefficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
μ	-0,00166977	-0,00136175		
AR1	0,91351762	0,97715680		
AR2	0,09392452	0,00536705		
AR3	0,01355171	-0,01497574		
AR4	-0,05892941	-0,01011201		
MA1	-0,99999993	-1,00000000		
BTC	0,00100428	0,00044535		
XRP	0,00034107	0,00003411		
LTC	-0,00218444	-0,00116901		
Queimadas		0,00120322		
ω	0,00019095	0,00041356		
α_1	0,22043401	0,00000004		
α_2	0,25935380	0,00000106		
α_3	0,04977620	0,00000000		
			Critérios	
			AIC_value	-2781,042
			BIC_value	-2772,463
			Resíduos	
			Mínimo	-0,14750000
			Primeiro Quartil	-0,01138000
			Mediana	0,00000542
			Média	-0,00027870
			Terceiro Quartil	0,00998200
			Máximo	0,12250000
				0,11278330

Fonte: Autores (2024).

A série de focos de queimadas registrou uma média de 29.936,85 focos semanais, sendo no mínimo de 395, no máximo 321.557 focos e desvio padrão de 27.858,28. Para a formação da *dummy* foram consideradas “1” as observações no terceiro quartil, com valor acima de 38.735,5 focos semanais. Na Tabela 3, o novo modelo gerado com essa *dummy* sofreu alteração nos coeficientes, em comparação com o anterior, com melhoria no valor estimado para os parâmetros. A amplitude dos resíduos diminuiu que pode indicar melhoria na precisão, como indicado na Figura 3.


Figura 3 – Resíduos do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(3,0) *with drift* para a série AXAT antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Austrália.



Fonte: Autores (2024).

Pela comparação da Figura 3, na qual constam os gráficos dos resíduos sem e com a inserção da variável qualitativa é possível identificar a redução da amplitude dos resíduos. Ou seja, a qualitativa pode captar a variabilidade que não foi explicada pelos demais termos. Os gráficos de controle desses resíduos constam na Figura 4.

Figura 4 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(3,0) *with drift* para a série AXAT antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Austrália.



Fonte: Autores (2024).

A modificação no número de pontos que estão fora do controle no gráfico CuSum Modificado da Figura 4, pode indicar que a variável qualitativa, focos de queimadas, está identificando comportamentos não modelados anteriormente. Essa característica pode indicar melhoria na capacidade do modelo de refletir a dinâmica dos dados.

O modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(1,1) *with drift* foi definido para o índice “Índia Bombay S&P BSE Sensex” da bolsa de valores de Bombaim localizada na Índia. A Tabela 4 apresenta os coeficientes, critérios e resíduos desse modelo e do modelo com a variável qualitativa focos de queimadas que ocorreram na Índia durante o período do estudo.


Tabela 4 – Comparação do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(1,1) *with drift* para a série BSESN antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Índia.

Coefficientes	Modelo sem qualitativa	Modelo com qualitativa		Modelo sem qualitativa	Modelo com qualitativa
μ	-0,00069706	-0,00070282			
AR1	-0,81029150	-0,81037880			
AR2	0,00640783	0,00632617			
AR3	-0,01643170	-0,01649231			
AR4	0,05120644	0,05117200			
AR5	0,01038785	0,01040483			
MA1	0,85535430	0,85538030			
BTC	-0,00036189	-0,00036001			
XRP	-0,00002667	-0,00002696			
LTC	0,00022732	0,00022676			
Queimadas		-0,00003307			
ω	0,00004588	0,00004585			
α_1	0,16782720	0,16782100			
β_1	0,73136480	0,73143150			
			Critérios		
			AIC_value	-2696,632	-2696,624
			BIC_value	-2688,053	-2688,045
			Resíduos		
			Mínimo	-0,10937420	-0,10930000
			Primeiro Quartil	-0,01211600	-0,01209000
			Mediana	0,00018840	0,00001035
			Média	0,00063080	0,00062730
			Terceiro Quartil	0,01242210	0,01236000
			Máximo	0,13076070	0,13080000

Fonte: Autores (2024).

Na série de focos de queimada na Índia foram identificados 20.163,32 focos semanais em média, o mínimo foi de 175 e o máximo de 2.495.947 focos. A variável *dummy* recebeu o valor “1” a partir do quantitativo 19.824, que é o terceiro quartil. É possível identificar na Tabela 4 que a inserção da qualitativa gerou modificações nos coeficientes dos parâmetros melhorando-os, bem como uma discreta redução no valor dos critérios de avaliação do modelo. Os resíduos dos modelos podem ser comparados na Figura 5.


Figura 5 – Resíduos do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(1,1) *with drift* para a série BSESN antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Índia.



Fonte: Autores (2024).

Ao comparar os resultados da Figura 5 é possível identificar uma leve modificação nos resíduos, que tiveram discreta redução da amplitude total. Pelos gráficos da Figura 6 obtiveram-se mais informações sobre esses resíduos.

Figura 6 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(1,1) *with drift* para a série BSEN antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Índia.



Fonte: Autores (2024).

Pela análise dos gráficos CuSum modificado indicados na Figura 6 a quantidade de pontos fora do limite de controle antes e depois da inserção da variável qualitativa é a mesma. Quando isso ocorre sugere que a inserção da variável não introduziu mudanças significativas no padrão de comportamento dos resíduos em relação ao tempo. No geral, as características do novo modelo sugerem que a inserção da variável é benéfica. Os coeficientes estáveis indicam que a variável é incorporada de forma consistente ao modelo. A diminuição na amplitude dos resíduos, e a redução na média e mediana, sugere uma melhoria na capacidade do modelo de explicar a variabilidade nos dados.

A variável DAX refere-se ao índice “Frankfurt Global X DAX Germany ETF” da bolsa de Frankfurt, na Alemanha, o modelo inicial foi ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,1) *with drift*. Ao modelo foi inserida a variável qualitativa de focos de queimadas na Alemanha e os resultados estão indicados na Tabela 5.

Tabela 5 – Comparação do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,1) *with drift* para a série DAX antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Alemanha.

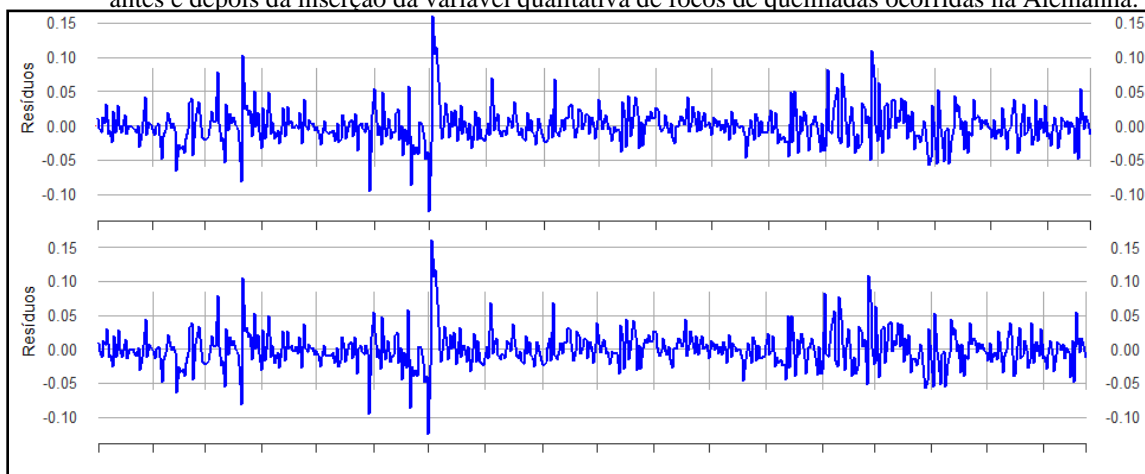
Coefficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
μ	0,00219332	0,00254604		
AR1	-1,10406900	-1,10594400		
AR2	-0,16678670	-0,17408710		
AR3	-0,05132492	-0,05661219		
MA1	0,97703110	0,97708010		
BTC	0,00014818	0,00003002		
XRP	0,00087850	0,00085997		
LTC	-0,00101025	-0,00102193		
Queimadas		0,00218753		
ω	0,00018187	0,00017316		
α_1	0,23971890	0,23537420		
α_2	0,00000000	0,00000000		
β_1	0,50028380	0,51662910		
			Resíduos	
			Mínimo	-0,12518850
			Primeiro Quartil	-0,01493170
			Mediana	-0,00202070
			Média	-0,00015950
			Terceiro Quartil	0,01210060
			Máximo	0,15991860
				0,16000000

Fonte: Autores (2024).

A série qualitativa apresentou um quantitativo mínimo de focos semanais de 1, máximo de 1.911, e em média 491,82 focos. O terceiro quartil, que delimita a geração da

dummy “1” no modelo iniciou em 684 focos semanais. A inserção dessa variável no modelo gerou um coeficiente positivo, conforme Tabela 5, indicando que ela tem uma influência positiva na série temporal. A redução na média e mediana dos resíduos sugere que a inserção da variável está contribuindo para a captura de padrões ou estruturas não modeladas anteriormente. Os gráficos dos resíduos estão na Figura 7.


Figura 7 – Resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,1) *with drift* para a série DAX antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Alemanha.



Fonte: Autores (2024).

A diminuição na amplitude dos resíduos, conforme Figura 7, pode indicar uma melhor adequação do modelo aos dados. Na Figura 8 os gráficos CuSum modificados confirmam a informação.

Figura 8 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,1) *with drift* para a série DAX antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Alemanha.




Fonte: Autores (2024).

Na Figura 8 pode-se identificar o aumento na quantidade de pontos de quebra fora do controle no gráfico CuSum após a inserção da variável qualitativa, em comparação com o gráfico do modelo anterior. Os critérios AIC e BIC são próximos entre os modelos, as estatísticas resumidas dos resíduos mostram que ambos os modelos ajustam bem a série temporal, mas a inclusão da variável qualitativa pode ter contribuído para uma redução na mediana dos resíduos.

Pela comparação dos gráficos da Figura 9 identifica-se as alterações supracitadas. A identificação das modificações na estrutura dos resultados é evidenciada na Figura 10.

Figura 10 – Gráfico CuSum modificado aplicado nos resíduos modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(2,2) *with drift* para a série FNCMX antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Estados Unidos.



Fonte: Autores (2024).

Comparando os gráficos de controle aplicados aos resíduos do modelo identifica-se a redução dos pontos de quebra no segundo gráfico, que representa a estrutura dos resíduos após a inserção da variável qualitativa. Menos pontos de quebra indicam que o modelo é mais estável e apresenta menos desvios em relação ao comportamento esperado, o que sugere uma melhoria na estabilidade do modelo ao longo do tempo.

Para a série FTSE, índice “London FTSE 100”, da Bolsa de valores de Londres, na Inglaterra, o modelo inicial foi ARIMAX(5,1,5)(BTC, LTC, XRP) *with drift*. A Tabela 7 indica os resultados do modelo e a comparação com outro modelo inserindo a variável qualitativa focos de queimadas semanais ocorridas na Inglaterra.

Tabela 7 – Comparação do modelo ARIMAX(5,1,5)(BTC, LTC, XRP) *with drift* para a série FTSE antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Inglaterra.


Coefficientes	Modelo sem qualitativa	Modelo com qualitativa		Modelo sem qualitativa	Modelo com qualitativa
μ	-0,00360000	-0,00360000			
AR1	0,33560000	0,69510000		Critérios	
AR2	0,51920000	-0,24000000	AIC_value	-2071,85	-2062,67
AR3	0,55380000	-0,14650000	BIC_value	-2007,53	-1994,07
AR4	0,30940000	0,89260000		Resíduos	
AR5	-0,87320000	-0,58970000	Mínimo	-0,14730000	-0,15420000
MA1	-0,37310000	-0,72750000	Primeiro Quartil	-0,01916000	-0,02002000
MA2	-0,54030000	0,24100000	Mediana	-0,00064720	-0,00036170
MA3	-0,63190000	0,10370000	Média	-0,00002567	0,00004449
MA4	-0,26930000	-0,92550000	Terceiro Quartil	0,01920000	0,01872000
MA5	0,95530000	0,56300000	Máximo	0,25640000	0,24470000
BTC	0,01000000	0,01700000			
XRP	-0,00080000	-0,00030000			
LTC	0,00260000	0,00550000			
Queimadas		0,00490000			

Fonte: Autores (2024).

Foram identificados os valores de 100 para média de focos semanais, 0 para o mínimo, 968 para o máximo e 132,5 para o terceiro quartil em quantidade de focos semanais no

período do estudo. A Tabela 7 indica que a variável gerou mudança nos termos dos coeficientes sugerindo que ela é relevante para explicar a série temporal. As estatísticas resumidas dos resíduos mostram diferenças nas tendências centrais e dispersão, indicando alterações na qualidade do ajuste dos modelos à série temporal. Os resíduos estão apresentados na Figura 11.

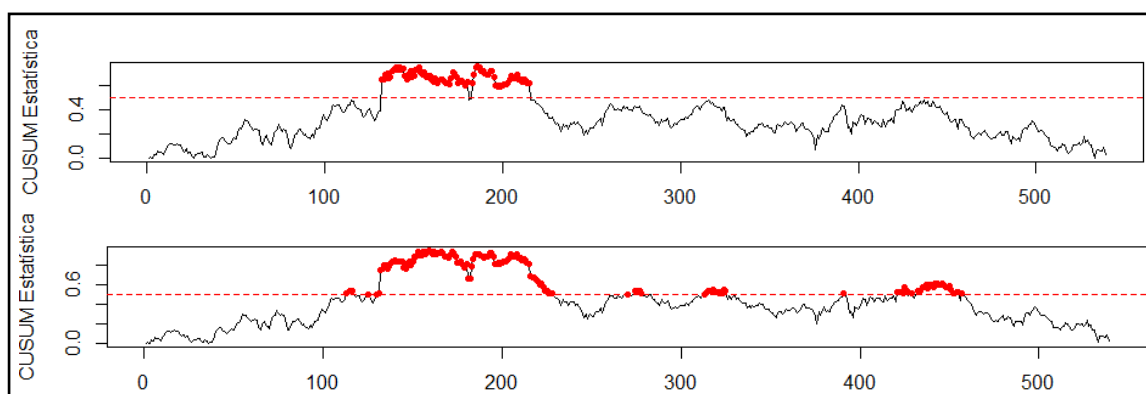
Figura 11 – Resíduos do modelo ARIMAX(5,1,5)(BTC, LTC, XRP) *with drift* para a série FTSE antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Inglaterra.



Fonte: Autores (2024).

A comparação dos gráficos dos resíduos constantes na Figura 11 indica o aumento na amplitude dos resíduos, que pode ser indicativo de que a variabilidade dos erros do modelo está aumentando. Os gráficos CuSum modificados da Figura 12 visam auxiliar na interpretação dos resultados.

Figura 12 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(5,1,5)(BTC, LTC, XRP) *with drift* para a série FTSE antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Inglaterra.



Fonte: Autores (2024).

O aumento na quantidade de pontos de quebra indicados no segundo gráfico CuSum, após a inserção da variável, sugere que houve uma mudança na estrutura dos resíduos ao longo do tempo. As mudanças na média, mediana e a presença de mais pontos de quebra indicam que o modelo com a variável qualitativa está respondendo de maneira diferente aos dados. Essa resposta pode ser positiva se a variável qualitativa for considerada relevante e a nova dinâmica do modelo for mais representativa dos dados.

A série descrita por HSI corresponde ao índice Hang Seng Index da Bolsa de Valores de Hong Kong na China. O modelo encontrado para a série foi ARIMAX(1,1,1)(BTC, LTC, XRP)-SGARCH(1,1) está descrito na Tabela 8. A variável qualitativa aplicada foi referente aos focos de queimadas semanais acontecidas na China semanalmente no período do estudo.


Tabela 8 – Comparação do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-SGARCH(1,1) para a série HSI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.

Coeficientes	Modelo sem qualitativa	Modelo com qualitativa		
			Modelo sem qualitativa	Modelo com qualitativa
AR1	0,97624020	0,96755080	Critérios	
MA1	-1,00000000	-1,00000000	AIC_value	-2346,126 -2346,918
BTC	0,00044611	0,00046233	BIC_value	-2337,547 -2338,339
XRP	0,00055225	0,00063929	Resíduos	
LTC	-0,00063210	-0,00081057	Mínimo	-0,12527080 -0,12930800
Queimadas		0,00263040	Primeiro Quartil	-0,01514200 -0,01480100
ω	0,00003975	0,00003878	Mediana	0,00034740 0,00024900
α_1	0,09162540	0,09409624	Média	0,00151440 0,00143100
β_1	0,86024620	0,85934920	Terceiro Quartil	0,01847620 0,01808900
			Máximo	0,10281040 0,10285400

Fonte: Autores (2024).

Verifica-se na Tabela 8 que os coeficientes do modelo foram pouco melhorados pela inserção da variável qualitativa. Os valores da média e da mediana dos resíduos diminuíram, ou seja, o ponto central dos resíduos se deslocou para valores mais baixos. Isso pode ser influenciado por mudanças nos valores extremos dos resíduos ou por novas características trazidas pela qualitativa e que afetam a tendência central. Na Figura 13 constam os gráficos dos resíduos dos modelos antes e depois da inserção da variável qualitativa.


Figura 13 – Resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-SGARCH(1,1) para a série HSI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.



Fonte: Autores (2024).

O aumento da amplitude dos resíduos do modelo, conforme Figura 13, pode indicar que existem características nos dados que ainda não foram modelados adequadamente, ou seja, a variável qualitativa, nesse pode estar causando mudança estrutural e complexidade adicional em relação ao modelo anterior. O gráfico CuSum modificado dos resíduos consta na Figura 14.

Figura 14 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-SGARCH(1,1) para a série HSI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.



Fonte: Autores (2024).

A quantidade de pontos de quebra no gráfico CuSum modificado aumentou no segundo gráfico da Figura 14, que indica a ocorrência de mudanças ao longo do tempo. A presença de mais pontos de quebra pode indicar maior variabilidade ou mudanças nos parâmetros do modelo. Em geral, a melhoria nos coeficientes pode ser positiva, mas o aumento na amplitude dos resíduos e na quantidade de pontos de quebra indica que a complexidade dos dados ainda precisa ser modelada.

O modelo referente a série IBOV foi ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(2,0) *with drift*, que obteve melhores valores para os critérios de avaliação, conforme Tabela 9. A variável qualitativa selecionada foi de focos de queimadas semanais no Brasil.


Tabela 9 – Comparação do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(2,0) *with drift* para a série IBOV antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas no Brasil.

Coefficientes	Modelo sem qualitativa	Modelo com qualitativa		Modelo sem qualitativa	Modelo com qualitativa
μ	-0,00497895	-0,00846007			
AR1	0,21502042	0,93353937			
AR2	0,02518104	0,07806698			
AR3	0,06162385	0,03333076			
AR4	0,00981128	-0,02840843			
AR5	0,05046139	-0,03740846			
MA1	-0,26250242	-0,99999999			
BTC	0,00077611	0,00032239			
XRP	0,00001489	-0,00047137			
LTC	-0,00108876	0,00039186			
Queimadas		0,00434321			
ω	0,00058089	0,00058685			
α_1	0,15797847	0,14714175			
α_2	0,26087956	0,25855667			
				Critérios	
			AIC_value	-2.248,724	-2.251,810
			BIC_value	-2.240,145	-2.243,231
				Resíduos	
			Mínimo	-0,14720250	-0,15070000
			Primeiro Quartil	-0,01968790	-0,02064000
			Mediana	-0,00072150	-0,00003443
			Média	0,00032820	0,00013300
			Terceiro Quartil	0,01844620	0,01769000
			Máximo	0,20971080	0,20080000

Fonte: Autores (2024).

Os valores dos coeficientes do modelo após a inserção da variável qualitativa aumentaram, o que pode indicar a contribuição dela para a explicação da variabilidade dos dados. A amplitude dos resíduos teve uma leve redução, conforme identifica-se na Figura 15.


Figura 15 – Resíduos do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(2,0) *with drift* para a série IBOV antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas no Brasil.



Fonte: Autores (2024).

A redução da amplitude dos resíduos, do segundo gráfico da Figura 15, pode ser interpretada como uma melhoria na capacidade do modelo em explicar a variabilidade dos dados. Os gráficos CuSum modificados aplicados a esses resíduos constam na Figura 16.

Figura 16 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-SGARCH(2,0) *with drift* para a série IBOV antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas no Brasil.



Fonte: Autores (2024).

A modificação no número de pontos que estão fora do controle no gráfico CuSum Modificado da Figura 16, pode indicar que a variável qualitativa, focos de queimadas, está auxiliando na captura de comportamentos não modelados anteriormente. Essa característica pode indicar melhoria na capacidade do modelo de refletir a dinâmica dos dados. Os resultados indicam que a inclusão da variável qualitativa melhorou alguns aspectos do modelo, como os coeficientes e a variabilidade dos resíduos, e também introduziu mudanças estruturais nos resíduos ao longo do tempo, como evidenciado pelo aumento nos pontos de quebra no gráfico CuSum.

O índice “MOEX Russia Index”, representado pelo código IMOEX.ME representa a bolsa de Moscow, da Rússia. Para avaliar as mudanças que uma variável qualitativa pode

causar no modelo ARIMAX(2,1,1)(BTC, LTC, XRP)-IGARCH(1,1) foi selecionada a qualitativa focos de queimadas semanais acontecidas na Rússia no mesmo período do estudo.


Tabela 10 – Comparação do modelo ARIMAX(2,1,1)(BTC, LTC, XRP)-IGARCH(1,1) para a série IMOEX.ME antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Rússia.

Coeficientes	Modelo sem qualitativa	Modelo com qualitativa	Critérios	
			Modelo sem qualitativa	Modelo com qualitativa
AR1	-1,08219300	-1,08065000		
AR2	-0,10184550	-0,10094110	AIC_value	-2405,244
MA1	0,98973760	0,98930950	BIC_value	-2396,665
BTC	-0,00065670	-0,00067479	Resíduos	
XRP	-0,00021502	-0,00021587	Mínimo	-0,09909500
LTC	0,00044322	0,00043646	Primeiro Quartil	-0,01483700
Queimadas		0,00060448	Mediana	0,00115700
ω	0,00004202	0,00004199	Média	0,00207800
α_1	0,28814310	0,28776400	Terceiro Quartil	0,01588300
β_1	0,71185690	0,71223600	Máximo	0,29498000

Fonte: Autores (2024).

A qualitativa possui como quantidade mínima de focos semanais 6 e máxima 856.278, os dados selecionados geraram uma média de 35.826,17 focos semanais. O terceiro quartil foi de 41.636,5, que delimita o início do valor “1” na *dummy*. Os coeficientes do modelo sofreram uma redução no valor e a amplitude dos resíduos aumentou o que indica que a variabilidade dos erros do modelo aumentou, e que a qualitativa pode gerar aumento na complexidade do modelo. O aumento na média e na mediana dos resíduos indica que, após a inserção da variável qualitativa, os resíduos ficaram centrados em torno de valores mais altos, o que pode ser uma mudança no padrão médio dos resíduos. Esses resíduos estão apresentados na Figura 17.

Figura 17 – Resíduos do modelo ARIMAX(2,1,1)(BTC, LTC, XRP)-IGARCH(1,1) para a série IMOEX.ME antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Rússia.




Fonte: Autores (2024).

A mudança que ocorre nos resíduos do segundo gráfico, em relação ao primeiro, pode ser visualizada na Figura 17. Nesses resíduos foram aplicados os gráficos de controle CuSum

modificado que não identificaram mudanças na quantidade de pontos de quebra, conforme Figura 18.

Figura 18 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(2,1,1)(BTC, LTC, XRP)-IGARCH(1,1) para a série IMOEX.ME antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Rússia.



Fonte: Autores (2024).

A manutenção da quantidade de pontos de quebra nos gráficos CuSum modificado, Figura 18, indica que, apesar das alterações nos resíduos, a estrutura geral em relação ao tempo não sofreu mudanças significativas. A melhoria nos coeficientes é positiva, indicando uma adaptação mais precisa aos dados. No entanto, o aumento na amplitude, média e mediana dos resíduos pode indicar que a variável qualitativa pode ter inserido complexidade adicional não totalmente capturada pelo modelo.

O modelo ARIMAX, ARIMAX(1,1,0)(BTC, LTC, XRP), foi definido para a série “JSE Limited” – JSE.JO, da bolsa de valores de Johannesburg localizada na África do Sul. A variável qualitativa é referente aos focos de queimadas na África do Sul com a mesma periodicidade e intervalo de tempo das séries do estudo. Na Tabela 11 constam os modelos sem e com a inserção da variável.

Tabela 11 – Comparação do modelo ARIMAX(1,1,0)(BTC, LTC, XRP) para a série JSE.JO antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na África do Sul.


Coeficientes	Modelo sem qualitativa	Modelo com qualitativa	Critérios	
			Modelo sem qualitativa	Modelo com qualitativa
ARI	-0,12730000	-0,12790000	AIC_value	-2122,37
BTC	0,01430000	0,01430000	BIC_value	-2100,93
XRP	0,00330000	0,00330000	Resíduos	
LTC	0,00890000	0,00920000	Mínimo	-0,13510580
Queimadas		0,00410000	Primeiro Quartil	-0,02045020
			Mediana	0,00030300
			Média	-0,00088830
			Terceiro Quartil	0,02035520
			Máximo	0,11597240

Fonte: Autores (2024).

Pelos resultados indicados na Tabela 11 identifica-se que os coeficientes possuem valores mais baixos antes da inserção da variável qualitativa, ou seja, pode indicar a contribuição da variável na explicação da variabilidade dos dados. A amplitude dos resíduos

diminui, então a variabilidade dos erros do modelo diminuiu. A média e a mediana dos resíduos também diminuiram, após a inserção da variável os resíduos estão mais centrados em torno de valores mais baixos. A representação dos resíduos consta na Figura 19.


Figura 19 – Resíduos do modelo ARIMAX(1,1,0)(BTC, LTC, XRP) para a série JSE.JO antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na África do Sul.



Fonte: Autores (2024).

O segundo gráfico da Figura 19 apresenta a redução da amplitude, isso pode indicar uma melhoria na precisão do modelo em prever as médias observadas, resultando em resíduos mais próximos de zero. Os gráficos CuSum modificados que complementam a análise do modelo estão na Figura 20.

Figura 20 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(1,1,0)(BTC, LTC, XRP) para a série JSE.JO antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na África do Sul.



Fonte: Autores (2024).

A Figura 20 apresenta o resultado dos gráficos CuSum modificado para os modelos, em que não foram encontradas modificações na quantidade de pontos de quebra, ou seja, a variável não gerou mudanças no comportamento dos resíduos em relação ao tempo. Neste caso, essa inserção pode estar apenas aumentando a complexidade do modelo e não capturando as características.

A série KLSE refere-se ao índice “FTSE Bursa Malaysia KLCI” da bolsa de valores da Malásia, o modelo que foi definido para representar a série foi ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(3,3) *with drift*. A série da variável qualitativa é de focos de queimadas semanais ocorridas na Malásia, os resultados dos modelos antes e depois da inserção da variável estão na Tabela 12.


Tabela 12 – Comparação do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(3,3) *with drift* para a série KLSE antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Malásia.

Coeficientes	Modelo sem qualitativa	Modelo com qualitativa		
			Modelo sem qualitativa	Modelo com qualitativa
μ	-0,00293622	-0,00469461		
AR1	0,06076391	-0,50778040		
MA1	-0,12524090	0,45637370		
BTC	0,00000966	0,00073029		
XRP	-0,00053006	-0,00007332		
LTC	0,00089632	-0,00045648		
Queimadas		0,00251913		
ω	-2,84896000	-0,41909060		
α_1	-0,01419000	-0,14164330		
α_2	-0,00657385	0,03915781		
α_3	0,00101217	0,02921444		
β_1	-0,91810690	0,62448740		
β_2	0,70513840	0,87120170		
β_3	0,88422240	-0,54483640		
γ_1	0,37498660	0,07553032		
γ_2	0,43160200	0,07092590		
γ_3	0,11376960	0,14479030		
			Critérios	
			AIC_value	-3160,19 -3158,684
			BIC_value	-3151,611 -3150,105
			Resíduos	
			Mínimo	-0,05512440 -0,05450100
			Primeiro Quartil	-0,00727580 -0,00659090
			Mediana	0,00054500 0,00098370
			Média	-0,00029910 0,00046460
			Terceiro Quartil	0,00792770 0,00888020
			Máximo	0,08905770 0,08889110

Fonte: Autores (2024).

A variável de focos de queimada na Malásia apresentou a quantidade mínima de 2 focos, máxima de 6.067 focos, média de 433,37 focos e o valor que define o terceiro quartil é de 516 focos. Os resultados apresentados pela Tabela 12 indicam que após a inserção da variável qualitativa melhorou os coeficientes do modelo, ou seja, a qualitativa modificou a estrutura. As estatísticas resumidas dos resíduos também indicam mudanças. A mediana aumentou, sugerindo uma alteração na distribuição central dos resíduos. Os resíduos estão representados graficamente na Figura 21.

Figura 21 – Resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(3,3) *with drift* para a série KLSE antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Malásia.




Fonte: Autores (2024).

Na Figura 21 percebe-se que a amplitude dos resíduos diminuiu, o que pode ser uma indicação positiva, pois o modelo ajustado com a variável qualitativa está conseguindo

capturar melhor a variabilidade nos dados, resultando em resíduos mais concentrados em torno de zero. Na Figura 22 esses resíduos são demonstrados no gráfico CuSum modificado.

Figura 22 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(3,3) *with drift* para a série KLSE antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Malásia.



Fonte: Autores (2024).

Pela comparação dos gráficos de controle aplicados aos resíduos dos modelos fica evidenciada a existência de pontos de quebra após a inserção da variável qualitativa. Esses pontos indicam mudanças estruturais nos resíduos ao longo do tempo, ou seja, a variável qualitativa acrescentou complexidade ao modelo ou mostrou padrões não identificados no modelo anterior. Em suma, a inclusão da variável qualitativa parece trazer benefícios para o modelo, contribuindo para uma melhor explicação e previsão dos dados.

O índice KS11, “Korea KOSPI Composite Index”, da Coreia do Sul foi modelado pelo ARIMAX(5,1,1)(BTC, LTC, XRP)-EGARCH(2,4) e a variável selecionada para qualitativa foi focos de queimadas semanais da Coreia do Sul.


Tabela 13 – Comparação do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-EGARCH(2,4) para a série KS11 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Coreia do Sul.

Coeficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
AR1	0,81435940	0,80756890		
AR2	0,01542939	0,01545689		
AR3	-0,06479295	-0,06497740		
AR4	0,04561343	0,04580403		
AR5	-0,03629034	-0,03641249		
MA1	-0,79072640	-0,78375200		
BTC	-0,00005867	-0,00004558		
XRP	0,00051605	0,00052382		
LTC	0,00026598	0,00024824		
Queimadas		-0,00015234		
ω	-0,54216360	-0,54179050		
α_1	-0,14308320	-0,14298750		
α_2	-0,10538270	-0,10540860		
β_1	0,17407510	0,17441720		
β_2	0,51756190	0,51678440		
β_3	0,57455090	0,57551280		
β_4	-0,33564460	-0,33612890		
γ_1	0,34335090	0,34445500		
γ_2	-0,11900930	-0,11953010		
			Critérios	
			AIC_value	-2710,654 -2710,66
			BIC_value	-2702,075 -2702,081
			Resíduos	
			Mínimo	-0,14544870 -0,14529600
			Primeiro Quartil	-0,01167990 -0,01172000
			Mediana	-0,00102380 -0,00108300
			Média	0,00031410 0,00032100
			Terceiro Quartil	0,01195490 0,01192500
			Máximo	0,13957350 0,13960800

Fonte: Autores (2024).

A variável qualitativa referente a Coreia do Sul indicou o mínimo de 1 focos, a média de 298,21 focos, o máximo de 2.923 focos e o terceiro quartil 373 focos, ambos semanais no período do estudo. Com a inserção dos focos de queimadas no modelo, os coeficientes tiveram uma pequena alteração indicando estabilidade nas relações lineares. Como os parâmetros do modelo GARCH mostraram mudanças pequenas entre os modelos, a inserção da variável não afetou a volatilidade condicional na modelagem. Os resíduos estão apresentados na Figura 23.


Figura 23 – Resíduos do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-EGARCH(2,4) para a série KS11 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Coreia do Sul.



Fonte: Autores (2024).

A observação dos gráficos da Figura 23 e resultados da Tabela 13 indicam que a amplitude dos resíduos sofreu redução, ou seja, a variável qualitativa contribui para resíduos mais próximos de zero. Na Figura 24 esses resíduos são aplicados ao gráfico CuSum modificado.


Figura 24 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(5,1,1)(BTC, LTC, XRP)-EGARCH(2,4) para a série KS11 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Coreia do Sul.



Fonte: Autores (2024).

Comparando os resultados da Figura 24 foram observados os mesmos pontos de quebra antes e depois da inserção da variável qualitativa. Se a quantidade de pontos fora do limite de controle no gráfico CuSum permanece a mesma, a variável não foi capaz de gerar


Figura 25 – Resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(5,3) *with drift* para a série MERV antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Argentina.



Fonte: Autores (2024).

Pela Figura 25 a amplitude dos resíduos diminuiu que pode ser interpretado como uma melhoria na capacidade do modelo em explicar e capturar a variabilidade nos dados. A Figura 26 apresenta os gráficos CuSum modificado para os resíduos dos modelos.

Figura 26 – Gráfico CuSum modificado aplicado nos resíduos modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(5,3) *with drift* para a série MERV antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Argentina.



Fonte: Autores (2024).

Após a inserção da variável qualitativa, há a redução na quantidade de pontos de quebra indicadas no segundo gráfico CuSum modificado da Figura 26. Significa que o modelo com a variável qualitativa está mais estável ao longo do tempo e menos suscetível a mudanças abruptas. A inclusão da variável qualitativa parece ter proporcionado melhorias nos critérios de ajuste e nas características dos resíduos, indicando que o modelo com qualitativa pode ser mais apropriado para capturar a estrutura subjacente dos dados.

A série N100 do índice “EURONEXT 100” da bolsa de valores de Paris da França foi modelada pelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(4,1) *with drift*. A variável qualitativa de focos de queimadas ocorridas na França no período foi inserida ao modelo gerando os resultados da Tabela 15.


Tabela 15 – Comparação do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(4,1) *with drift* para a série N100 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na França.

Coefficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
μ	-0,00431779	-0,00392814		
AR1	-1,05695500	-0,27630630		
AR2	-0,08828164	-0,03644867		
AR3	-0,01718803	-0,05033574		
MA1	0,98012440	0,19688250		
BTC	0,00061250	0,00064988		
XRP	0,00001943	0,00009102		
LTC	-0,00064375	-0,00069768		
Queimadas		-0,00131081		
ω	0,00030041	0,00029040		
α_1	0,22727950	0,23291560		
α_2	0,23379160	0,23015170		
α_3	0,00000000	0,00000000		
α_4	0,05871505	0,07897259		
β_1	0,00000004	0,00000004		
			Critérios	
			AIC_value	-2553,586 -2640,102
			BIC_value	-2545,007 -2631,523
			Resíduos	
			Mínimo	-0,11292770 -0,11007010
			Primeiro Quartil	-0,01257330 -0,01104450
			Mediana	-0,00258850 -0,00044980
			Média	-0,00025970 0,00187050
			Terceiro Quartil	0,00931290 0,01143250
			Máximo	0,16393750 0,16990120

Fonte: Autores (2024).

A variável qualitativa pode ser representada pelos valores de mínimo, 9 focos, máximo, 5.426 focos, média, 381,63 focos e terceiro quartil, 471,5 focos. A alteração nos coeficientes indica os efeitos das variáveis na série temporal. O aumento na amplitude dos resíduos pode indicar maior variabilidade nas diferenças entre os valores observados e os valores previstos pelo modelo. Em média, os resíduos são menores após a inserção da variável qualitativa, ou seja, é uma possível redução no viés do modelo. Na Figura 27 tem-se os gráficos dos resíduos antes e depois da inserção da variável.


Figura 27 – Resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(4,1) *with drift* para a série N100 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na França.



Fonte: Autores (2024).

Conforme a Figura 27, há o aumento na amplitude dos resíduos, mas a variação é pequena. Quando isso ocorre, os resíduos estão mais dispersos ou têm uma variação maior em comparação com o modelo anterior. Os gráficos de controle apresentados na Figura 28 servem para detectar mudanças na tendência dos dados.

Figura 28 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(4,1) *with drift* para a série N100 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na França.



Fonte: Autores (2024).

O aumento na quantidade de pontos de quebra do segundo gráfico em relação ao primeiro, da Figura 28, pode indicar que a introdução da variável qualitativa teve um impacto ou causou uma mudança estrutural nos dados. Os resultados indicam que a inserção da variável qualitativa resultou em melhoria no desempenho do modelo.

O modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,2) *with drift* representa a série N225, que é o índice “Nikkei 225 Osaka” da bolsa de valores de Tokyo, no Japão. A variável qualitativa selecionada para a inserção no modelo foi focos de queimadas do Japão no período de estudo. Na Tabela 16 estão os resultados do modelo com e sem a inserção da variável qualitativa.

Tabela 16 – Comparação do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,2) *with drift* para a série N225 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas no Japão.


Coeficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
μ	0,00998478	0,01614568		
AR1	-0,82107966	0,95338464		
AR2	0,00077542	0,05840974		
AR3	-0,00905044	-0,04267423		
MA1	0,80285010	-0,99999999		
BTC	-0,00181985	-0,00237890		
XRP	0,00089063	0,00113104		
LTC	0,00145673	0,00109050		
Queimadas		0,00269870		
ω	0,00016055	0,00010491		
α_1	0,07190229	0,04756112		
α_2	0,14159789	0,11973711		
β_1	0,09039165	0,65432844		
β_2	0,46198149	0,02618336		
			Critérios	
			AIC_value	-2438,608
			BIC_value	-2430,029
			Resíduos	
			Mínimo	-0,11000020
			Primeiro Quartil	-0,01668640
			Mediana	-0,00092250
			Média	0,00037090
			Terceiro Quartil	0,01452860
			Máximo	0,12069630
				0,11196210

Fonte: Autores (2024).

A série de focos de queimadas para o Japão pode ser caracterizada por ter a média de 785,3 focos de queimadas semanais, com no mínimo 19 focos e no máximo 2.483 focos. O terceiro quartil, que delimita o início do valor “1” para a *dummy* é de 990 focos. A variável gera importantes mudanças nos coeficientes, os valores das estatísticas dos resíduos indicam

que o modelo com variável qualitativa possui resíduos menores e mais concentrados em torno da média em comparação com o modelo sem variável qualitativa. Os gráficos desses resíduos estão na Figura 29.


Figura 29 – Resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,2) *with drift* para a série N225 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas no Japão.



Fonte: Autores (2024).

A amplitude total dos resíduos aumenta no modelo com a variável qualitativa ao ser comparado com o modelo sem. No entanto, a média, a mediana e os quartis possuem valores menores, que indicam maior concentração, ou seja, o modelo ajustado pode estar explicando melhor a variação nos dados. Na Figura 30 constam os gráficos CuSum modificado aplicados nos resíduos.

Figura 30 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-SGARCH(2,2) *with drift* para a série N225 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas no Japão.



Fonte: Autores (2024).

Na Figura 30 é possível identificar o aumento na quantidade de pontos de quebra indicados no gráfico CuSum após a inserção da variável qualitativa, o que indica que a mudança na estrutura do modelo pode ter acrescentado variações não capturadas anteriormente. Considerando os resultados, a inserção da variável qualitativa parece melhorar o modelo, conforme evidenciado pelas características dos resíduos e pelos coeficientes diferentes.

O índice NSEI - “Índia NIFTY 50” da Índia foi modelado pelo ARIMAX(1,1,1)-(BTC, LTC, XRP)-EGARCH(2,2) *with drift* e foi inserida a variável qualitativa de focos de queimadas na Índia.


Tabela 17 – Comparação do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(2,2) *with drift* para a série NSEI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Índia.

Coefficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
μ	0,00226521	-0,00656220		
AR1	0,96392870	-0,63313550		
MA1	-1,00000000	0,67336270		
BTC	-0,00002988	0,00004285		
XRP	0,00041770	-0,00056145		
LTC	-0,00091035	0,00022421		
Queimadas		0,00386573		
ω	-0,50504070	-0,42744160		
α_1	-0,23954580	-0,28439030		
α_2	-0,00354883	-0,02411281		
β_1	0,32386820	0,30610690		
β_2	0,61002440	0,63677880		
γ_1	0,09011319	0,10342510		
γ_2	0,22901170	0,31344990		
			Critérios	
			AIC_value	-2625,632
			BIC_value	-2617,053
			Resíduos	
			Mínimo	-0,11655810
			Primeiro Quartil	-0,01322960
			Mediana	-0,00058210
			Média	0,00016020
			Terceiro Quartil	0,01312130
			Máximo	0,16650510

Fonte: Autores (2024).

Os resultados da Tabela 17 indicam a melhoria dos coeficientes, devido ao aumento do valor do parâmetro, essas alterações indicam que a nova variável está influenciando a relação entre as variáveis do modelo. Também resultou na alteração nos resíduos, conforme evidenciado pelos valores mínimo, máximo, quartis e média. Os resíduos estão demonstrados graficamente na Figura 31.


Figura 31 – Resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(2,2) *with drift* para a série NSEI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Índia.



Fonte: Autores (2024).

Pela Figura 31 verifica-se que, ainda que pequeno, há o aumento na amplitude dos resíduos que pode indicar uma maior variabilidade nos erros do modelo, ou seja, o modelo pode não estar capturando toda a variabilidade nos dados ou existem padrões não explicados. Na Figura 32 a análise segue pelos gráficos CuSum modificados.

Figura 32 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(1,1,1)(BTC, LTC, XRP)-EGARCH(2,2) with drift para a série NSEI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Índia.



Fonte: Autores (2024).

O gráfico com a inserção da variável qualitativa, segundo gráfico da Figura 32, apresenta o aumento na quantidade de pontos de quebra, o que indica uma maior variabilidade nos resíduos ou mudanças estruturais no modelo após a inclusão da variável qualitativa. No geral, os resultados sugerem que a inclusão da variável qualitativa melhorou a qualidade do modelo.

A série identificada pelo código SSE180 referente ao índice “SSE 180 Index” da bolsa de valores de Shanghai na China foi representada pelo modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(2,3) para a série SSE180. Na Tabela 18 podem ser visualizados os resultados do modelo citado e de outro modelo que recebeu a inserção da variável qualitativa focos de queimadas ocorridas na China.

Tabela 18 – Comparação do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(2,3) para a série SSE180 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.


Coefficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
AR1	-0,11969420	-0,11609190		
AR2	-0,01606832	-0,01554114		
AR3	0,00298953	0,00362312		
AR4	-0,06918811	-0,06972961		
MA1	0,05753614	0,05293848		
BTC	-0,00056254	-0,00057712		
XRP	0,00001935	0,00002646		
LTC	0,00130405	0,00127779		
Queimadas		0,00092821		
ω	0,00003344	0,00003317		
α_1	0,07979507	0,07855178		
α_2	0,22802440	0,23106460		
β_1	0,00000111	0,00000041		
β_2	0,38766850	0,39151780		
β_3	0,30127740	0,29636980		
			Critérios	
			AIC_value	-2371,632 -2371,810
			BIC_value	-2363,053 -2363,231
			Resíduos	
			Mínimo	-0,11823600 -0,11807010
			Primeiro Quartil	-0,01547390 -0,01545090
			Mediana	-0,00121670 -0,00105450
			Média	-0,00024970 -0,00026230
			Terceiro Quartil	0,01322350 0,01321780
			Máximo	0,21711740 0,21727280

Fonte: Autores (2024).

Destaca-se, pela Tabela 18 que modelo com a variável qualitativa, os valores dos coeficientes AR1, AR2 e MA1 são um pouco menores do que no modelo sem a variável,

sugerindo uma leve redução desses efeitos. A mudança gerada nas estatísticas dos resíduos é presente, mas pequena. Os gráficos dos resíduos estão presentes na Figura 33.


Figura 33 – Resíduos do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(2,3) para a série SSE180 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.



Fonte: Autores (2024).

A Figura 33 indica que a redução na amplitude dos resíduos foi pequena, as diferenças entre as previsões do modelo e os valores reais tornaram-se um pouco mais consistentes ou menos variáveis. Os gráficos CuSum modificado, que avaliam a mudanças estruturais em séries temporais ou modelos constam na Figura 34.

Figura 34 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-SGARCH(2,3) para a série SSE180 antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na China.



Fonte: Autores (2024).

O aumento na quantidade de pontos de quebra no segundo gráfico CuSum modificado da Figura 34 indica que, com a inserção da variável qualitativa, existem evidências de mudanças ou instabilidades estruturais no modelo. A inserção da variável qualitativa parece ter algum efeito nos resultados do modelo, mas esse efeito é "modesto", ou seja, variável qualitativa tem uma influência, mas não é a única explicação para as variações nos dados.

O modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-EGARCH(1,1) representa a série SSMI do índice "Suíça SMI" da bolsa de valores da Suíça. Na Tabela 19 conta a apresentação desse modelo e do modelo com a inserção da variável qualitativa focos de queimadas na Suíça.


Tabela 19 – Comparação do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-EGARCH(1,1) para a série SSMI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Suíça.

Coeficientes	Modelo sem qualitativa	Modelo com qualitativa		
			Modelo sem qualitativa	Modelo com qualitativa
AR1	0,25113113	0,23567967		
AR2	0,02547208	0,02835795		
AR3	0,06274721	0,06513566		
AR4	0,07375702	0,07356373		
MA1	-0,16320840	-0,14479794		
BTC	0,00027471	0,00032731		
XRP	0,00016837	0,00014679		
LTC	-0,00169274	-0,00169883		
Queimadas		-0,00137494		
ω	-1,10086418	-1,09157339		
α_1	-0,45404651	-0,45103912		
β_1	0,85911171	0,86055116		
γ_1	0,37386765	0,37223997		
			Critérios	
			AIC_value	-2791,964 -2793,05
			BIC_value	-2783,385 -2784,471
			Resíduos	
			Mínimo	-0,10577220 -0,10475130
			Primeiro Quartil	-0,00942780 -0,00950730
			Mediana	0,00034950 0,00031420
			Média	0,00224230 0,00216770
			Terceiro Quartil	0,01284130 0,01272580
			Máximo	0,09958910 0,09938150

Fonte: Autores (2024).

A Tabela 19, apresenta os resultados da inserção da variável qualitativa no modelo, o que causou uma pequena redução nos coeficientes, também há uma pequena mudança nos valores das estatísticas dos resíduos. Na Figura 35 constam os gráficos dos resíduos dos modelos.


Figura 35 – Resíduos do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-EGARCH(1,1) para a série SSMI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Suíça.



Fonte: Autores (2024).

Pela Figura 35 evidencia-se que a amplitude dos resíduos diminuiu, a média e a mediana dos resíduos também diminuíram o que pode indicar a redução da variabilidade, ou seja, o modelo ajustado está melhorando em termos de precisão e acurácia. Na Figura 36 constam os gráficos CuSum modificado para esses resíduos.

Figura 36 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(4,1,1)(BTC, LTC, XRP)-EGARCH(1,1) para a série SSMI antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Suíça.



Fonte: Autores (2024).

O aumento na quantidade de pontos de quebra indicados no segundo gráfico CuSum modificado, da Figura 36, após a inserção da variável qualitativa indica que a inclusão dessa variável teve um impacto ou alterou o comportamento do modelo. A inserção da variável qualitativa gerou efeitos modestos nos coeficientes, estatísticas dos resíduos e parâmetros do modelo.

A série TWII representa o índice “FTSE MIB Index” da bolsa de valores de Milão, localizada na Itália. A inserção da variável qualitativa focos de queimada na Itália gerou outro modelo, a partir do ARIMAX(3,1,1)(BTC, LTC, XRP)-EGARCH(5,5), e ambos estão apresentados na Tabela 20.

Tabela 20 – Comparação do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-EGARCH(5,5) para a série TWII antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Itália.


Coeficientes	Modelo sem qualitativa	Modelo com qualitativa	Modelo sem qualitativa	Modelo com qualitativa
AR1	0,97648940	0,49446470		
AR2	-0,06308714	0,05588823		
AR3	0,07881944	-0,03031105		
MA1	-0,99813800	-0,54379650		
BTC	-0,00029814	-0,00091170		
XRP	0,00011785	-0,00003681		
LTC	0,00008799	0,00109105		
Queimadas		0,00367184		
ω	-0,90234300	-0,62323290		
α_1	-0,13885010	-0,22829480		
α_2	-0,16000120	-0,33753840		
α_3	-0,23045520	-0,15434630		
α_4	-0,05420118	0,08382984		
α_5	-0,22452740	0,08262251		
β_1	0,52038850	-0,54925640		
β_2	-0,46753070	0,99840050		
β_3	0,18826390	0,74235520		
β_4	0,02250456	-0,27496680		
β_5	0,61548930	-0,00115686		
γ_1	0,22151620	0,38468280		
γ_2	0,16065800	0,19953060		
γ_3	0,12361990	-0,15528690		
γ_4	0,30433850	0,14846630		
			Critérios	
			AIC_value	-2709,948 -2719,988
			BIC_value	-2701,369 -2711,409
			Resíduos	
			Mínimo	-0,09535100 -0,08990060
			Primeiro Quartil	-0,01004630 -0,01004500
			Mediana	0,00037890 -0,00064310
			Média	0,00198260 0,00166530
			Terceiro Quartil	0,01247510 0,01281740
			Máximo	0,11760040 0,13067880

γ_5	-0,05937858	0,25021930
------------	-------------	------------

Fonte: Autores (2024).

Os resultados da Tabela 20 indicam que os coeficientes do modelo com a variável qualitativa são diferentes em muitos casos, indicando uma alteração na estrutura do modelo. A variável qualitativa impactou especialmente os coeficientes relacionados ao AR1, AR2, AR3 e MA1. A amplitude dos resíduos aumentou, ou seja, os resíduos tornaram-se mais dispersos. A média dos resíduos diminuir pode indicar uma melhoria na capacidade do modelo em prever os valores observados. Os resíduos são apresentados no Figura 37.


Figura 37 – Resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-EGARCH(5,5) para a série TWII antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Itália.



Fonte: Autores (2024).

Na Figura 37 fica evidenciado o aumento da amplitude dos resíduos, ou seja, a variação aumentou. A sequência da análise é verificada na aplicação dos gráficos CuSum modificado na Figura 38.

Figura 38 – Gráfico CuSum modificado aplicado nos resíduos do modelo ARIMAX(3,1,1)(BTC, LTC, XRP)-EGARCH(5,5) para a série TWII antes e depois da inserção da variável qualitativa de focos de queimadas ocorridas na Itália.



Fonte: Autores (2024).

A redução na quantidade de pontos de quebra, apontada pela Figura 38, indica que o modelo com a variável qualitativa está apresentando uma menor evidência de mudanças significativas na estrutura em comparação com o modelo sem a variável qualitativa. As

quantidades de pontos fora de controle identificadas e descritas em todos os gráficos CuSum das séries foram conferidas pela geração de relatório de pontos fora do controle emitido pelo *software*. O modelo com a variável qualitativa parece ter uma melhor capacidade de prever os dados, com resíduos mais homoganeamente distribuídos e menos evidência de mudanças estruturais significativas. Na Tabela 21 consta um compilado dos principais resultados gerados pelos modelos.

Tabela 21 – Resumo da análise dos resultados obtidos para a inserção da variável qualitativa focos de queimadas nos modelos de séries temporais de índices de bolsas de valores

Código	Situação do modelo com a variável qualitativa
159903.SZZ	Os coeficientes melhoram, a amplitude dos resíduos diminui, a média e a mediana dos resíduos sofrem uma pequena redução e a quantidade de pontos de quebra indicadas no gráfico CuSum também permanece a mesma.
AXAT	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos diminui, a média dos resíduos passou a ser positiva, a mediana aumentou, após a inserção da variável qualitativa há a pontos de quebra indicadas no gráfico CuSum.
BSESN	Os coeficientes do modelo sofrem pequena alteração, a amplitude dos resíduos diminui, a média e a mediana dos resíduos diminuíram, a quantidade de pontos fora do limite de controle do gráfico CuSum permanece a mesma.
DAX	Os coeficientes melhoram, a amplitude dos resíduos diminui, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
FNCMX	Os coeficientes melhoram, a amplitude, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há a redução na quantidade de pontos de quebra indicadas no gráfico CuSum.
FTSE	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos aumentou, a média dos resíduos passou a ser positiva, a mediana diminuiu, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
HSI	Os coeficientes melhoram, a amplitude dos resíduos aumentou, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
IBOV	Os coeficientes melhoram, a amplitude dos resíduos diminui, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
IMOEX.ME	Os coeficientes do modelo sofrem alteração, a amplitude dos resíduos sofreu discreto aumento, a média e a mediana dos resíduos aumentaram, a quantidade de pontos de quebra indicadas no gráfico CuSum permaneceu a mesma.
JSE.JO	Os coeficientes melhoram, a amplitude dos resíduos diminui, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa a quantidade de pontos de quebra indicadas no gráfico CuSum permaneceu a mesma.
KLSE	Os coeficientes melhoram, a amplitude dos resíduos diminui, a média e a mediana dos resíduos aumentaram, após a inserção da variável qualitativa há pontos de quebra indicadas no gráfico CuSum.
KS11	Os coeficientes melhoram, a amplitude dos resíduos diminui, a média dos resíduos aumentou e a mediana diminuiu, após a inserção da variável qualitativa a quantidade de pontos de quebra indicadas no gráfico CuSum permaneceu a mesma.
MERV	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos diminuiu, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há a redução na quantidade de pontos de quebra indicadas no gráfico CuSum.
N100	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos aumentou, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
N225	Os coeficientes melhoram, a amplitude dos resíduos aumentou, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade

	de pontos de quebra indicadas no gráfico CuSum.
NSEI	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos aumentou, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
SSE180	Os coeficientes do modelo sofrem alteração, a amplitude dos resíduos reduziu discretamente, a média dos resíduos diminuiu e a mediana aumentou, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
SSMI	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos diminuiu, a média e a mediana dos resíduos diminuíram, após a inserção da variável qualitativa há o aumento na quantidade de pontos de quebra indicadas no gráfico CuSum.
TWII	Os coeficientes do modelo sofrem alteração melhorando, a amplitude dos resíduos aumentou, a média dos resíduos diminuiu e a mediana aumentou, após a inserção da variável qualitativa há a redução na quantidade de pontos de quebra indicadas no gráfico CuSum.

Fonte: Autores (2024).

Os descritores analisados na Tabela 21, considera-se vantajosa em termos de ajuste do modelo, a inserção da variável qualitativa nas séries 159903.SZZ, AXAT, BSESN, DAX, FNCMX, HSI, IBOV, KLSE, MERV, N100, N225, NSEI, SSE180, SSMI, TWII. Nas séries citadas as *dummies* são estatisticamente significativas no modelo.

Os dois modelos ARIMAX, das séries FTSE e JSE.JO, não apresentaram melhoria para a variável qualitativa queimadas, o que pode indicar que para modelos desse tipo essa inserção não é positiva. No entanto, como foram testados apenas dois modelos desse tipo para fazer essa afirmação são necessários mais testes com outras séries ou ainda com outras variáveis qualitativas explicativas que possam melhorar o desempenho do modelo. Essa característica também pode indicar que a aplicação da variável qualitativa é melhor modelada nos casos de modelos aplicados a séries com maior complexidade, pois auxilia na captura de padrões para aprimorar a representação dos dados.

Entretanto, a não geração de melhoramento do modelo por parte da qualitativa, para os modelos em estudo não indica que a utilização de variável qualitativa é inválida, visto que, para esses indicadores de bolsa em questão podem existir outra variável qualitativa que melhor represente a influência do que focos de queimadas. Neste caso, podem ser testadas mais variáveis a depender do perfil de composição do índice e do mercado ao qual pertence. A seleção da variável qualitativa para o modelo decorreu da descoberta efetuada em estudo anterior, o qual unia objetivos comuns (SENNA; SOUZA, 2023).

O resultado geral do estudo concorda com os estudos de (EKONG et al., 2021; LI; LI; LI, 2020; MIAO et al., 2023; WANG; HE; ZHAO, 2021) que utilizaram variáveis *dummy* para a geração de melhorias em modelos de previsão. No caso de (LI; LI; LI, 2020) as *dummies* foram aplicadas para melhorar a precisão dos modelos AGB baseados em

sensoriamento remoto combinando o *Operational Land Imager* (OLI) do Landsat 8 e a densidade da copa da floresta (FCD).

Na metodologia de (MIAO et al., 2023) as *dummies* foram introduzidas no modelo de degradação com base no algoritmo de regressão linear multivariada (MLR), resultando em um modelo com um desempenho comparável e pode ser válido na realidade. As *dummies* também foram utilizadas em análise de regressão e nos índices de correlação canônica (EKONG et al., 2021). O impacto nos índices de correlação canônica é maior do que nos coeficientes de regressão. O modelo baseado em variáveis *dummy* sazonais se mostrou mais preciso do que modelos de previsão tradicionais (WANG; HE; ZHAO, 2021).

Os resultados apresentados pelas séries modeladas indicaram que a inserção de uma variável qualitativa aos modelos de séries temporais, que já são considerados bastante precisos, é válida. A inserção de uma variável qualitativa pode gerar melhoramento nos modelos e ampliar a precisão das previsões. Assim, como no caso da seleção de variáveis exógenas quantitativas, a seleção das qualitativas deve ser efetuada considerando o contexto do conjunto de variáveis e a capacidade de explicação da série a ser modelada.

4 CONSIDERAÇÕES FINAIS

Os modelos de previsão de séries temporais tradicionais são bastante precisos e tem sua utilização disseminada em várias áreas do conhecimento, por isso buscar aprimorar esses modelos é um desafio para os pesquisadores. Nesse estudo o objetivo foi utilizar variáveis qualitativas para aprimorar os modelos ajustados e conseqüentemente obter previsões mais precisas.

Nesta pesquisa a inserção de variáveis *dummies* por meio da padronização da variável número de queimadas que é expressa em número de ocorrências, foi padronizada por meio dos quartis, o que possibilitou identificar acima do terceiro quartil focos de maior magnitude, visto que quanto mais focos de queimadas ocorrem maior é a emissão de gases causadores do efeito estufa. Este diferencial trouxe melhoria nos modelos ajustados e nos parâmetros estimados, revelados pelas estatísticas AIC e BIC. O procedimento de monitoramento dos resíduos por meio dos gráficos de controle CuSum, revela que a inserção da variável número de queimadas via *dummies*, trouxe assertividade aos modelos finais ajustados.

Os resultados obtidos indicaram que os modelos elaborados do tipo ARIMAX-GARCH apresentam melhores desempenhos com a inserção da variável qualitativa. Os dois modelos ARIMAX, que não continham volatilidade, testados não apresentaram melhora no

desempenho. Para esses modelos serão necessários testes com outras séries ou outras variáveis qualitativas.

A principal limitação encontrada para o desenvolvimento deste estudo foi a escassez de séries temporais com periodicidades similares, tanto em relação às variáveis qualitativas quanto às quantitativas. Isso restringiu a capacidade de explorar plenamente o potencial das variáveis qualitativas na modelagem. Como sugestão para pesquisas futuras, recomenda-se a investigação e inclusão de outras variáveis qualitativas relevantes para enriquecer ainda mais os modelos de previsão. Essa abordagem poderia proporcionar uma compreensão mais abrangente e precisa dos fenômenos em estudo, contribuindo para avanços significativos na área.

OPTIMIZATION OF FORECASTS WITH THE INTEGRATION OF QUALITATIVE VARIABLES IN TIME SERIES MODELS

ABSTRACT

Traditional assets are typically traded on stock exchanges, recognized as safe environments for conducting transactions. However, the introduction of new assets and qualitative variables, such as unexpected climatic events, can influence the behavior of these markets. In this scenario, the objective of the study is the development of a time series predictive model improved by inserting qualitative variables into the model to optimize solutions. To achieve this, quantitative exogenous variables from three cryptocurrencies and a qualitative variable related to wildfire incidents were incorporated into the ARIMAX, ARIMAX-ARCH, and ARIMAX-GARCH time series models. This approach resulted in improvements in model performance. Models with the presence of volatility were enhanced by including a qualitative dummy variable, indicating the occurrence of wildfires above the third quartile of observations. These improvements demonstrate the relevance and effectiveness of considering qualitative variables in predictive models, especially in a context where unforeseen events can have substantial impacts on financial markets. This enhanced approach contributes to the robustness and accuracy of predictions, enabling a more comprehensive and informed analysis of market behavior.

Key Words: time series models, qualitative variables, dummy variables, wildfire.

5 REFERÊNCIAS BIBLIOGRÁFICAS

AIKEN, L. H. et al. Nurse staffing and education and hospital mortality in nine European countries: a retrospective observational study. **The Lancet**, v. 383, n. 9931, p. 1824–1830, 24 maio 2014.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716–723, dez. 1974.

ARIA, M.; CUCCURULLO, C. bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v. 11, n. 4, p. 959–975, 1 nov. 2017.

- BDQueimadas - Programa Queimadas - INPE.** Disponível em: <<http://terrabrasilis.dpi.inpe.br/queimadas/bdqueimadas/#graficos>>. Acesso em: 1 dez. 2023.
- BLANCHARD, O. J. et al. **Monetary Policy Matter? A New Spirit of Friedman and Schwartz.** [s.l.] MIT Press, 1989. v. Title
- BOLLERSLEV, T. GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSKEDASTICITY. **Journal of Econometrics**, v. 31, n. 3, p. 307–327, 1986.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control.** 3. ed. New Jersey: Printice Hall, 1994.
- BROOKS, C. **Introductory Econometrics for Finance.** Disponível em: <<https://www.amazon.com.br/Introductory-Econometrics-Finance-Chris-Brooks/dp/052169468X>>. Acesso em: 10 out. 2020.
- BURGOYNE, J.; JAMES, K. T. Towards best or better practice in corporate leadership development: Operational issues in mode 2 and design science research. **British Journal of Management**, v. 17, n. 4, p. 303–316, dez. 2006.
- ÇAĞDAŞ, V.; STUBKJÆR, E. Design research for cadastral systems. **Computers, Environment and Urban Systems**, v. 35, n. 1, p. 77–87, jan. 2011.
- CAUCHICK-MIGUEL, P. A. et al. **Metodologia de pesquisa em engenharia de produção e gestão de operações.** 3. ed. Rio de Janeiro: Elsevier, 2018.
- CORRAR, L. J.; PAULO, E.; DIAS FILHO, J. M. **Análise Multivariada: Para Os Cursos De Administração, Ciências Contábeis E Economia.** 1. ed. São Paulo: Atlas, 2014.
- CORSI, F.; PIRINO, D.; RENÒ, R. Threshold bipower variation and the impact of jumps on volatility forecasting. **Journal of Econometrics**, v. 159, n. 2, p. 276–288, 1 dez. 2010.
- DEGIANNAKIS, S. ARFIMAX and ARFIMAX-TARCH realized volatility modeling. **Journal of Applied Statistics**, v. 35, n. 10, p. 1169–1180, out. 2008.
- DICKEY, D. A.; FULLER, W. A. Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. **Econometrica**, v. 49, n. 4, p. 1057, jul. 1981.
- DING, Z.; GRANGER, C. W. J.; ENGLE, R. F. A long memory property of stock market returns and a new model. **Journal of Empirical Finance**, v. 1, n. 1, p. 83–106, 1 jun. 1993.
- DUEKER, M. Dynamic Forecasts of Qualitative Variables. **Journal of Business & Economic Statistics**, v. 23, n. 1, p. 96–104, jan. 2005.
- EKONG, N. et al. A Comparative Study of the Impact of Dummy Variables on Regression Coefficients and Canonical Correlation Indices: An Empirical Perspective. **International Journal of Analysis and Applications**, v. 19, n. 4, p. 576–586, 17 jun. 2021.
- ENDERS, W. **Applied Econometric Time Series.** Disponível em: <<https://www.wiley.com/en-us/Applied+Econometric+Time+Series%2C+4th+Edition-p-9781118808566>>. Acesso em: 10 out. 2020.
- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987, jul. 1982a.
- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987, jul. 1982b.

- ENGLE, R. F.; BOLLERSLEV, T. Modelling the persistence of conditional variances. **Econometric Reviews**, v. 5, n. 1, p. 1–50, 1986.
- ENGLE, R. F.; GRANGER, C. W. J. Co-Integration and Error Correction: Representation, Estimation, and Testing. **Econometrica**, v. 55, n. 2, p. 251, mar. 1987.
- FERNANDES RC, C. F. W. Espacialização temporal dos focos de queimadas e de poluentes atmosféricos (Co , Ch4 , No2 , N2o) em Alagoas. **Ciência e Natura**, p. 287–294, 2013.
- FERREIRA, P. C. et al. **Análise de Séries Temporais em R: Curso Introductório**. 1. ed. Rio de Janeiro: Elsevier, 2018.
- FRANSES, P. H. Primary Demand for Beer in the Netherlands: An Application of ARMAX Model Specification. **Journal of Marketing Research**, v. 28, n. 2, p. 240–245, 6 maio 1991.
- FREITAS, S. R. et al. Emissões de queimadas em ecossistemas da América do Sul. **Estudos Avançados**, v. 19, n. 53, p. 167–185, 2005.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.
- GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. **The Journal of Finance**, v. 48, n. 5, p. 1779, dez. 1993.
- GRANGER, C. W. J. DEVELOPMENTS IN THE STUDY OF COINTEGRATED ECONOMIC VARIABLES. **Oxford Bulletin of Economics and Statistics**, v. 48, n. 3, p. 213–228, 1 maio 1986.
- HANNAN, E. J.; QUINN, B. G. The Determination of the Order of an Autoregression. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 41, n. 2, p. 190–195, jan. 1979.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice (2nd ed)**. Australia: [s.n.].
- JOHANSEN, S. Statistical analysis of cointegration vectors. **Journal of Economic Dynamics and Control**, v. 12, n. 2–3, p. 231–254, jun. 1988.
- KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, n. 1–3, p. 159–178, out. 1992.
- LACERDA, D. P. et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741–761, 26 nov. 2013.
- LARA, L. L. et al. Properties of aerosols from sugar-cane burning emissions in Southeastern Brazil. **Atmospheric Environment**, v. 39, n. 26, p. 4627–4637, 2005.
- LI, C.; LI, M.; LI, Y. Improving estimation of forest aboveground biomass using landsat 8 imagery by incorporating forest crown density as a dummy variable. **Canadian Journal of Forest Research**, v. 50, n. 4, p. 390–398, 2020.
- LIANG, J.; LI, L.; ZENG, D. Evolutionary dynamics of cryptocurrency transaction networks: An empirical study. **PLOS ONE**, v. 13, n. 8, p. e0202202, 17 ago. 2018.
- LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, n. 2, p. 297–303, 1 ago. 1978.
- LOUZADA, F. et al. **Controle Estatístico de Processos-Uma Abordagem Prática para**

- Cursos de Eng. e Administração.** LTC ed. Rio de Janeiro: [s.n.].
- MALHOTRA, N. K. **Pesquisa de Marketing** - 4^a ed. Porto Alegre: Bookman, 2006.
- MARCH, S. T.; SMITH, G. F. **Design and natural science research on information technology Decision Support Systems.** [s.l: s.n.].
- MARCONI, M. DE A.; LAKATOS, E. M. **Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisas, elaboração, análise e interpretação de dados.** 8. ed. São Paulo: Atlas, 2018.
- MIAO, J. et al. A Dummy-Variable Model for Humidity-Influenced DC Film Capacitors Lifetime Estimation. **IEEE JOURNAL OF EMERGING AND SELECTED TOPICS IN POWER ELECTRONICS**, v. 11, p. 1056–1070, 2023.
- MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros.** Rio de Janeiro: [s.n.].
- MORETTIN, P. A. . **Econometria Financeira: um Curso em Séries Temporais Financeiras.** 3. ed. São Paulo: Blucher, 2017.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais.** São Paulo: Blucher, 2004.
- NAKAMOTO, S. **Bitcoin: A Peer-to-Peer Electronic Cash System.** [s.l: s.n.]. Disponível em: <www.bitcoin.org>. Acesso em: 11 out. 2020.
- NELSON, D. B. Conditional Heteroskedasticity in Asset Returns: A New Approach. **Econometrica**, v. 59, n. 2, p. 347, mar. 1991.
- PEARL, J. Fusion, Propagation, and Structuring in Belief Networks. In: **Probabilistic and Causal Inference.** New York, NY, USA: ACM, 1986. v. 29p. 241–288.
- PECICAN, E. S. Forecasting Based on Open VAR Model. **Romanian Journal of Economic Forecasting-1**, v. 1, p. 59–69, 2010.
- PEFFERS, K. et al. A Design Science Research Methodology for Information Systems Research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45–77, 8 dez. 2007.
- PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, v. 75, n. 2, p. 335–346, 1988.
- ROMME, A. G. L. Making a Difference: Organization as Design. **Organization Science**, v. 14, n. 5, p. 558–573, out. 2003.
- SCHWARZ, G. Estimating the Dimension of a Model. **The Annals of Statistics**, 1978.
- SENNA, V. DE; MENDONÇA, A.; SOUZA. **Expense Relation Analysis in Social Program Welfare in Brazil.** Verlag: Éditions universitaires européennes, 2017.
- SENNA, V. DE; SOUZA, A. M. Assessment of the relationship of government spending on social assistance programs with Brazilian macroeconomic variables. **Physica A: Statistical Mechanics and its Applications**, v. 462, p. 21–30, nov. 2016.
- SENNA, V. DE; SOUZA, A. M. Criptomoedas e sistema financeiro: revisão sistemática de literatura. **Revista de Administração de Empresas**, v. 63, n. 4, p. e2022- 0019, 8 set. 2023.
- SIMON, H. A. **The Sciences of the Artificial.** [s.l: s.n.]. v. 11

SIMS, C. A. Macroeconomics and Reality. **Econometrica**, 1980.

SUGIURA, N. Further analysis of the data by Akaike's information criterion and the finite corrections. **Communications in Statistics - Theory and Methods**, v. 7, n. 1, p. 13–26, 1 jan. 1978.

THOMÉ, A. M. T.; SCAVARDA, L. F.; SCAVARDA, A. J. Conducting systematic literature review in operations management. **Production Planning & Control**, v. 27, n. 5, p. 408–420, 3 abr. 2016.

VAN AKEN, J. E. Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules. **Journal of Management Studies**, v. 41, n. 2, p. 219–246, 10 fev. 2004.

WANG, X. Z. et al. Gas Leakage Prediction Model of Large-Scale Explosions in Hard Rock Based on Quantification Theory. **Transport in Porous Media**, v. 95, n. 1, p. 171–183, 28 out. 2012.

WANG, Z.-X.; HE, L.-Y.; ZHAO, Y.-F. Forecasting the seasonal natural gas consumption in the US using a gray model with dummy variables. **Applied Soft Computing**, v. 113, p. 108002, dez. 2021.

WŁODARCZYK, A.; ZAWADA, M. **Modeling the impact of the weather factors on the electrical energy consumption in one of the regions in the southern Poland**. Disponível em: <<https://ieeexplore-ieee-org.ez47.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=5558738>>. Acesso em: 7 nov. 2023.

Yahoo Finanças. Disponível em: <<https://br.financas.yahoo.com/>>.

8 DISCUSSÃO

O estudo segue a metodologia *Design Science Research*, que desobriga o seguimento da ordem direta das etapas propostas, mas indica as necessidades para o desenvolvimento dos estudos. A estruturação foi feita pela divisão dos objetivos em artigos, desta forma cada artigo possui metodologia própria e atende a especificidade dos objetivos específicos numa crescente até o desenvolvimento do modelo proposto e do conhecimento necessário para isso.

O primeiro passo efetuado foi a identificação de um conjunto de séries e a coleta destas para a aplicação de testes. A organização do sistema e a definição das séries em estudo decorre da compatibilidade de período das observações, da quantidade vasta de observações que amplia a capacidade de testes e modelos a serem trabalhados, a facilidade de obtenção de séries econômicas, bem como o interesse e aplicabilidade ao mercado. As Bolsas representam o mercado tradicional de negociação de ativos, as séries selecionadas foram:

O índice AXAT, S&P/ASX ALL *Australian* 200 é um dos principais índices da Bolsa de Valores da Austrália, que é a maior da Oceania, sediada em Sydney (<https://www.asx.com.au/about/corporate-overview.htm>), considerado referência para o desempenho acionário australiano, baseado nas 200 maiores ações listadas que representam mais de 80% da capitalização desse mercado de ações.

O BSESN é o Índia *Bombay* S&P BSE *Sensex*, a *Bombay Stock Exchange* (www.bseindia.com) ou Bolsa de Valores de Bombaim é uma das principais Bolsas de Valores da Índia, o BSE *Sensex* é o principal índice dessa Bolsa. O índice FTSE - London FTSE 100, *Financial Times Stock Exchange* (<http://www.londonstockexchange.com>) é o principal da Bolsa de Valores de Londres, a segunda maior bolsa europeia em volume mensal negociado. As maiores empresas negociadas são Royal Dutch Shell, BHP Billiton, HSBC, Unilever, BP.

HangSeng Index – HKSE, HSI é o principal índice da Bolsa de Valores de Hong Kong, (<https://www.hkex.com.hk/>) a terceira maior Bolsa da Ásia em capitalização de mercado, possui uma dinâmica diferente da Bolsa de Valores de Shanghai, por ser uma colônia inglesa, ou seja, possui maior independência do governo chinês e maior abertura ao investimento estrangeiro. Negocia empresas como Tencent, China Mobile, AIA, CNOOC, Sun Hung Kai Properties.

O KLSE o índice conhecido como FTSE Bursa Malaysia KLCI, ou seja, é o *Financial Times Stock Exchange Bursa Malaysia Kuala Lumpur Composite Index* compreende as 30 maiores empresas listadas, por capitalização de mercado total. A Bolsa de Valores da Malásia (<https://www.bursamalaysia.com/>) é a principal da ASEAN – Associação das Nações do

Sudeste Asiático, um agrupamento regional que promove a cooperação econômica, política e de segurança entre seus dez membros: Brunei, Camboja, Indonésia, Laos, Malásia, Mianmar, Filipinas, Cingapura, Tailândia e Vietnã.

O *KS11Korea KOSPI Composite Index*. O KOSPI é o índice da Bolsa de Valores da Coreia do Sul, a Korea Exchange ou KRX, ele lista mais de 700 empresas que constam na Bolsa. Esta é a única operadora de câmbio e títulos do país. O índice MERV - Merval é o índice Mercado de Valores (Merval) mede o comportamento das principais ações negociadas na Bolsa de Valores de Buenos Aires (<https://www.bcba.sba.com.ar/>), na Argentina.

Euronext100, o N100 é um dos principais índices da Bolsa de Valores da Europa, a *European New Exchange Technology* (www.euronext.com) essa Bolsa é diferente das demais pois é de múltiplos países, sediada em Amsterdam, possui negociações de ações também em Bruxelas, Paris, Lisboa e Dublin e futuros em Londres. Foi formada em 2000 pela unificação das Bolsas de Amsterdam, Bruxelas e Paris, com o objetivo de obter vantagem da harmonização dos mercados financeiros europeus após a criação da União Europeia.

O Nikkei 225, N225, é o principal índice da Bolsa de Valores de Tokyo (<https://www.jpx.co.jp/>), em Osaka, que é a maior bolsa de valores fora dos Estados Unidos, negocia empresas como Toyota Motor, Softbank, Nippon Telegraph & Telephone, Keyence, NTT Docomo. O *^NSEI* é o índice de referência da Bolsa de Valores da Índia, NIFTY 50 (NSEI) significa *National Index Fifty*, que é a principal Bolsa de Valores da Índia (www.nseindia.com). São negociadas por essa Bolsa empresas como AdaniTransmission, Bajaj Holdings, Divi's Laboratories, HDFC AMC, ICICI Prudential Life Insurance, L&T Finance.

SSE 180 Index, *^SSE180*, representa a Bolsa de Valores de Shanghai (<http://www.sse.com.cn/>) que é a maior Bolsa de Valores da China em capitalização de mercado, negocia empresas como PingAnInsurance, Petrochina, Agricultural Bank of China, Bank of China. O índice principal é SSE Composite. A Bolsa de Shanghai não é completamente aberta aos investidores estrangeiros devido ao controle de capitais realizado pelo governo chinês. O *SSMI*, Suíça *SMI PR* é o índice da Bolsa de Valores da Suíça (<https://www.six-group.com/en/home.html>). A Bolsa é a quarta maior da Europa. Dentre as empresas negociadas nessa Bolsa estão Nestlé, Novartis e Hoffmann-La Roche.

O *STI FTSE Straits Times Singapore* é o *Financial Times Stock Exchange* (FTSE) *Straits Times Index* (STI) um índice de referência para o mercado de ações de Cingapura (<https://www.sgx.com/>). Ele monitora o desempenho das 30 principais empresas listadas na Bolsa de Valores de Cingapura. O *^TWII* é o FTSE *MIB Index Milan* – Índice

Financial Times Stock Exchange de Milão, Itália. É o principal índice de referência para os mercados acionários italianos, é composto por empresas líderes e altamente líquidas. A *Borsa Italiana S.p.A.* é responsável pela organização e gestão da Bolsa de Valores da Itália (<https://www.borsaitaliana.it/homepage/homepage.en.htm>).

O índice 159903.SZ China SZSE *Component Index Fund/ETF* é o principal índice da Bolsa de Valores Shenzhen (<http://www.szse.cn>), a terceira maior da bolsa chinesa. As maiores empresas negociadas são Reliance Industries, Tata Consultancy Services, HDFC Bank, Hindustan Unilever, ITC. O DAX é o índice de maior representatividade da *Frankfurt Global X DAX Germany ETF* – Bolsa de Valores de Frankfurt – Alemanha (<http://deutsche-boerse.com/>). Essa Bolsa é uma das maiores do mundo, a maior entre as sete Bolsas de Valores da Alemanha.

FNCMX, *Fidelity NASDAQ Composite Index* é um dos principais índices da Bolsa de Valores Nasdaq (<https://www.nasdaq.com>). A Nasdaq é a segunda maior bolsa de valores do mundo, sediada em Nova York nos Estados Unidos, algumas das empresas que negocia são Microsoft, Apple, Amazon.com, Alphabet, Facebook. Os principais índices são S&P 500, Dow Jones Industrial, NASDAQ Composite. IBOV ou IBOVESPA é o principal índice da B3 – Brasil Bolsa Balcão a maior Bolsa da América Latina, mas a 18ª entre as mundiais, localizada em São Paulo. Negocia empresas como Petrobrás, Itaú Unibanco, Bradesco, Vale, Ambev.

O *Moscow Exchange Russia Index*, IMOEX.ME, é o índice composto ponderado por capitalização calculado com base nos preços das ações russas mais líquidas dos maiores emissores russos em desenvolvimento dinâmico e com atividades econômicas relacionadas aos principais setores da economia russa apresentados na Bolsa. A Bolsa de Valores de Moscou é a principal Bolsa da Rússia, (<https://www.moex.com/en/>) está entre as 20 principais bolsas do mundo em capitalização total das ações negociadas e também entre as 10 maiores plataformas de troca de títulos e derivativos.

JSE.JO - Johannesburg Preço Adiado, Moeda em Zac é um índice da Bolsa de Valores de Johannesburg (<https://www.jse.co.za/>) localizada na África do Sul, é considerada a maior bolsa do continente africano e a 19ª maior do mundo. As empresas incluídas neste índice são as 40 maiores empresas por capitalização de mercado. TA35.TA é o principal índice da Bolsa de Valores de Tel Aviv, Tel Aviv *Stock Exchange* (<https://www.tase.co.il/en>), é a única bolsa de valores em Israel. O acesso a ela é protegido por altas barreiras à entrada em termos de regulamentação e à necessidade de infraestrutura tecnológica confiável.

As criptomoedas são novos ativos com forma de negociação diferenciada, as séries selecionadas foram BTC – Bitcoin, que é a mais conhecida e comercializada, XRP – Ripple e

LTC – Litecoin. As variáveis qualitativas são referentes aos focos de queimadas ocorridos nos países em que as bolsas de valores estão localizadas, elas foram coletadas no site do INPE.

O segundo passo foi necessário a identificação da existência de relação entre as séries para facilitar a definição de uma variável qualitativa comum a todas. A relação de curto prazo foi evidenciada pelo resultado do teste de causalidade de Granger, e a relação de longo prazo pelo resultado do modelo VEC, explicado pela FIR e pela decomposição de variância. Por este artigo foi possível identificar que as séries se relacionam e que a manutenção delas no conjunto é válida, pois ficou comprovada a possibilidade que as criptomoedas têm de influenciar as Bolsas de Valores.

O *software* usado foi o EViews 10 SV, em função da versão ser livre para estudantes há a limitação que permite no máximo quinze mil dados serem utilizados em uma única análise. Neste caso, as séries foram limitadas a essa quantidade o que reduziu o número de observações por série, de 1.562 para 905. A periodicidade das séries deste estudo foi de observações diárias. A limitação da quantidade de variáveis usadas no Eviews 10 SV forçou a utilização do *software* livre RStudio e, conseqüentemente, novo aprendizado por parte dos pesquisadores.

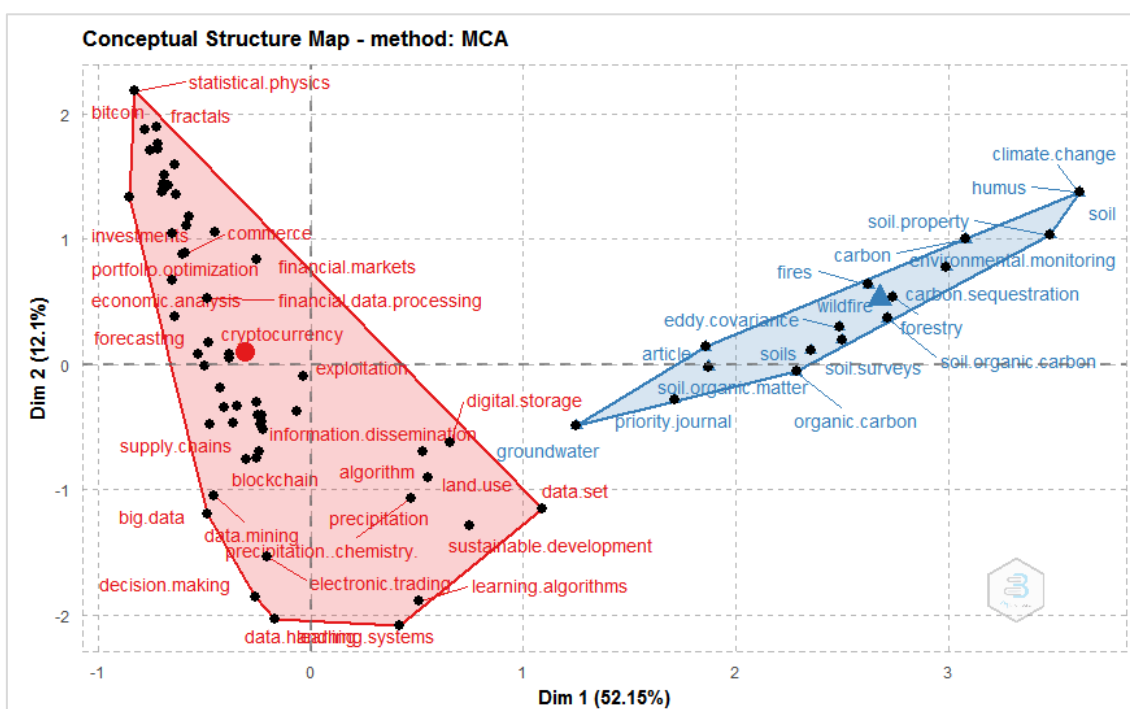
Como terceiro passo do estudo foi a verificação, nas bases científicas *Scopus* e *Web of Science*, de estudos científicos publicados com relação a inserção de variáveis qualitativas em modelos de previsão de séries temporais. Deste artigo foi possível identificar a existência dessa lacuna de conhecimento e a possibilidade de desenvolvimento do estudo. O artigo não esgota as fontes de pesquisa para a temática, mas serve de argumento pela identificação dos estudos já publicados e que estão indexados nessas bases, ou seja, há a identificação de que o tema definido conta com a inovação esperada. O Artigo 1 foi construído na sequência, pois identificada a viabilidade da realização do estudo com as variáveis selecionadas, a criação de estratégias de otimização do modelo passou a ser uma perspectiva viável e compreender o que foi estudado sobre este o tema auxiliou a reforçar a aplicabilidade geral de um modelo que integre variáveis qualitativas e quantitativas.

Os artigos estudados descrevem, na maioria dos casos, modelos que consideram as variáveis qualitativas como entrada quantificada por ponderação de especialistas, frequência, probabilidade unida a distribuições, modelagem fuzzy entre outras. A construção dos modelos surge tanto da criação de equações inovadoras, quanto da união de modelos como redes neurais e modelos de séries temporais. Nos casos analisados as conclusões obtidas indicaram a melhora de previsões pela inserção de variáveis qualitativas. Todavia, não foram encontrados modelos que identificassem o impacto dessas variáveis para o modelo.

Na sequência foi efetuada a revisão sistemática de literatura sobre os artigos com o tema criptomoedas e as relações com as Bolsas de Valores para compreender o conhecimento gerado sobre as relações entre sistema financeiro tradicional e novo sistema. As principais relações identificadas com as Bolsas de Valores foram a não correlação do Bitcoin com as classes de ativos tradicionais, pois a criptomoedas foi considerada investimento especulativo. Os retornos do Bitcoin variam mais do que os retornos das ações. Os efeitos dos retornos do ouro são mais importantes para o Bitcoin do que os retornos das ações, das taxas de câmbio, do petróleo e das tendências da Internet. Para o Bitcoin as mudanças de preço são mais complexas do que as mudanças de volume.

Outra informação importante descoberta a partir dessa revisão sistemática de literatura foi a que está contida na Figura 2.

Figura 2 – Mapa da estrutura conceitual das palavras-chave Plus dos artigos coletados na primeira versão do Artigo 2.



Fonte: Autores, (2024).

A Figura 2 foi criada para compor a primeira versão escrita para o Artigo 3, no entanto, após a submissão dele para a publicação, a pedido dos pareceristas, a Figura 3 foi excluída para ser inserida outra no local. Na Figura 2 os parâmetros que definem a análise de múltipla correspondência MCA (*Multiple Correspondence Analysis*) são as 50 palavras-chave Plus que representam os artigos resultantes da pesquisa. A análise gerou dois grupos indicados que são representados nos termos *cryptocurrency* e *wildfire*.

O fator *cryptocurrency* reúne os estudos focados principalmente nas criptomoedas, no mercado financeiro e digital, nas modelagens de previsões e algoritmos e tomada de decisões. O fator *wildfire* aglomera estudos relacionados a incêndios, queimadas, variações climáticas, monitoramento do meio ambiente, carbono orgânico, solo orgânico entre outros. Pela geração do fator *wildfire* que a variável qualitativa do estudo foi definida. Foram investigadas inicialmente duas variáveis a quantidade de focos de queimadas e áreas desmatadas, que foi descartada em função de existirem apenas registros anuais de comparação de áreas, via satélite.

Para chegar ao objetivo do estudo o Artigo 4 foi utilizado como intermediário, visto que, foi preciso definir os modelos mais adequados para as séries selecionadas. A priori buscou-se utilizar as mesmas séries e quantidade de observações utilizadas no Artigo 3, contudo não foi possível encontrar modelos ARIMA para elas. A alternativa encontrada foi refazer a coleta das séries utilizando a periodicidade semanal, na qual a variabilidade das observações reduziu e os modelos foram encontrados.

Na sequência dos modelos ARIMA, no mesmo artigo foram inseridas as criptomoedas como exógenas nos modelos, ampliando o estudo para o modelo ARIMAX. Essa decisão foi tomada porque, além das criptomoedas, uma das alternativas programadas para o Artigo 5 foi a de inserção da variável qualitativa como outra exógena aos modelos. O ARIMAX foi escolhido para fazer parte do estudo pois esse tipo de modelo considera a capacidade de influência de variáveis exógenas na série endógena. Esse é um modelo com padrões mais complexos para as previsões e possui maior flexibilidade em cenários diferentes, características que concordam com a estratégia a ser definida pelo estudo. Devido a volatilidade das séries, apenas em duas das séries foram obtidos modelos ARIMAX, nos demais foram encontradas evidências de volatilidade e os modelos gerados são combinados com um modelo GARCH. Todos os resultados estão anexados ao Artigo 4.

O Artigo 5 foi elaborado a partir dos modelos ajustados no Artigo 4, pois após o ajuste dos modelos do Artigo 4 foram efetuados vários testes de modelos com inserção dos focos de queimadas e, após as comparações de resultados, chegou-se ao indicado no Artigo 5. A melhor composição dos modelos foi através da inserção das variáveis exógenas qualitativas *dummy* referentes aos focos de queimadas juntamente com as exógenas criptomoedas aos modelos ajustados para as séries endógenas dos índices das bolsas de valores e foi verificado o comportamento dos novos modelos.

Os modelos contidos no Artigo 4 que não foram ajustados novamente no Artigo 5 foram das séries STI “FTSE Straits Times Singapore” de Singapura e TA35.TA “TA-35Tel

Aviv” de Israel. As respectivas localidades, nas quais as séries são originadas, possuem registros de focos de queimadas com todos os valores zerados no site do INPE em todo o período definido para o estudo.

O resultado obtido pela inserção das variáveis qualitativas, no formato de *dummies* do tipo “0” ou “1” nos modelos, indicou que as melhorias foram estatisticamente significativas. A aplicação da estratégia de otimização dos modelos poderá gerar modelos mais precisos e auxiliará os especialistas que possuem amplo conhecimento dos cenários dos estudos que estão realizando.

9 CONSIDERAÇÕES FINAIS

O presente estudo abordou a importância da análise das variáveis qualitativas e as influências que elas podem ter sobre determinados cenários e situação. Os resultados obtidos confirmaram a hipótese proposta de que a inclusão adequada de variáveis qualitativas em modelos de previsão de séries temporais resultaria em previsões mais precisas e uma compreensão mais abrangente dos fenômenos estudados. O objetivo proposto foi desenvolver uma estratégia metodológica capaz de captar os efeitos de variáveis qualitativas e otimizar as previsões dos modelos de séries temporais tradicionais. Através da inserção de uma variável qualitativa, do tipo *dummy*, especificamente aplicada ao cenário relacionado às variáveis endógenas, foi possível identificar as melhorias estatisticamente significativas nos modelos ARIMAX-GARCH.

Para chegar a esse resultado foram elaborados objetivos específicos que foram divididos em artigos científicos individuais. O primeiro foi elaborar um panorama sobre os estudos que já foram realizados em que os modelos de previsão tradicionais foram combinados a variáveis qualitativas. Desse modo, foi possível identificar uma lacuna de conhecimento relacionada às variáveis qualitativas e aos modelos ARIMA e suas extensões, de acordo com os resultados do Artigo 1.

O segundo objetivo específico foi estabelecer um conjunto de séries temporais adequadas para a modelagem, com relação de causalidade e que possibilite a aplicação de variáveis qualitativas. Para tanto, foram selecionadas séries de vinte e uma bolsas de valores e três criptomoedas, que acrescentaram caráter globalizado da pesquisa e diversidade de tipos de mercados de atuação, através dos índices, bem como ativos tradicionais e novos tipos de ativos, representados pelas criptomoedas.

Neste caso, foram efetuados os Artigos 2 e 3, em que, no Artigo 2 foram verificadas as referências de literatura sobre as relações já estudadas sobre as séries selecionadas, No Artigo 3, foram verificadas as relações de causalidade, curto e longo prazo entre as séries, indicando que elas se relacionam e a manutenção no conjunto é válida. No Artigo 2 foi possível também atingir o objetivo específico de identificar variáveis qualitativas que possam impactar o conjunto de séries em estudo.

As séries de focos de queimadas dos países em que as bolsas de valores estão localizadas foram definidas como variáveis qualitativas. A escolha dessa variável justifica-se pelo fato de que as queimadas são responsáveis pela emissão de gás carbônico na atmosfera, um dos principais causadores do efeito estufa. Quando os países possuem muitos focos de queimadas ativos ou não conseguem atuar efetivamente no combate ao fogo, a excessiva emissão de gases afeta o desempenho da bolsa de valores e conseqüentemente os índices que demonstram o desempenho geral do mercado financeiro, por meio do comportamento dos ativos neles listados.

Como a variável qualitativa aplicável concomitantemente a todas as séries correspondia a frequência de ocorrência da característica focos de queimadas, a estratégia utilizada foi a transformação dessa série em uma variável do tipo *dummy*. A maioria das séries apresentavam pelo menos um foco semanal durante toda a periodicidade do estudo, então tomou-se por definição a separação das observações em quartis e foi considerada “1” a quantidade de focos de queimadas superiores ao terceiro quartil, visto que são os excessos de focos que geram maiores problemas no mercado financeiro.

O último objetivo específico definido, avaliar o efeito de uma variável qualitativa em modelo de séries temporais para validar a estratégia proposta, foi atingido pelos Artigos 4 e 5. Pelo Artigo 4 foram identificados os modelos ARIMAX e suas extensões e pelo Artigo 5 foram inseridas as variáveis qualitativas nos modelos e identificados os efeitos obtidos.

A obtenção dos resultados foi apoiada no método *Design Science Research*, com o qual foi possível estruturar e dividir o estudo em etapas tornando-o organizado, com compreensão dos próximos passos e necessidades a serem atendidas para a atingir o objetivo geral proposto. Além da metodologia, o estudo utilizou como ferramenta principal o *software livre* RStudio. Por este estudo foram gerados cinco artigos científicos, dos quais três estão publicados em revistas científicas e os outros dois estão em fase de submissão, aguardando retorno dos periódicos.

As implicações teóricas do estudo referem-se à contribuição para a metodologia de análise considerando a abordagem da lacuna de conhecimento relacionada às variáveis qualitativas e aos modelos ARIMA e suas extensões. Também foi possível avançar na no conhecimento sobre modelos de previsão combinados com variáveis qualitativas, em específico com os modelos como ARIMAX-GARCH, contribuindo para o desenvolvimento teórico nesse campo. O estudo foi relevante, visto que, a principal inovação foi relacionada a importância da inserção de variáveis qualitativas, não mensuráveis, nos modelos quantitativos destacando a capacidade de melhorar a precisão dos modelos.

As implicações gerenciais estão relacionadas às melhorias estatisticamente significativas nos modelos ARIMAX-GARCH com a inclusão de variáveis qualitativas, o que pode ser útil para gestores financeiros e investidores na tomada de decisões mais informadas. Fatores externos, como os focos de queimadas, podem afetar o desempenho do mercado financeiro, destacando a importância de considerar essa, e outras variáveis na gestão de riscos e na formulação de estratégias de investimento. Pelo estudo identifica-se o potencial para desenvolvimento de novas estratégias de análise e investimento, mais sofisticadas, levando em conta fatores não tradicionalmente quantificados.

A limitação encontrada foi a disponibilidade de registros de variáveis, tanto quantitativas como qualitativas, em setores diversos, além dos financeiros. Permanece como lacuna a ser estudada a interação entre as séries, ou seja, a aplicação de modelos de múltiplas variáveis simultaneamente. Ademais, considera-se que este estudo possui estrutura, base empírica e referências científicas que possibilitem auxiliar a comunidade científica e civil no desenvolvimento de novos estudos.

REFERÊNCIAS

- AIKEN, L. H. et al. Nurse staffing and education and hospital mortality in nine European countries: a retrospective observational study. **The Lancet**, v. 383, n. 9931, p. 1824–1830, 24 maio 2014.
- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716–723, dez. 1974.
- ARIA, M.; CUCCURULLO, C. bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v. 11, n. 4, p. 959–975, 1 nov. 2017.
- BDQueimadas - Programa Queimadas - INPE**. Disponível em: <<http://terrabrasilis.dpi.inpe.br/queimadas/bdqueimadas/#graficos>>. Acesso em: 1 dez. 2023.
- BLANCHARD, O. J. et al. **Monetary Policy Matter? A New Spirit of Friedman and Schwartz**. [s.l.] MIT Press, 1989. v. Title
- BOLLERSLEV, T. GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSKEDASTICITY. **Journal of Econometrics**, v. 31, n. 3, p. 307–327, 1986.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 3. ed. New Jersey: Printice Hall, 1994.
- BROOKS, C. **Introductory Econometrics for Finance**. Disponível em: <<https://www.amazon.com.br/Introductory-Econometrics-Finance-Chris-Brooks/dp/052169468X>>. Acesso em: 10 out. 2020.
- BURGOYNE, J.; JAMES, K. T. Towards best or better practice in corporate leadership development: Operational issues in mode 2 and design science research. **British Journal of Management**, v. 17, n. 4, p. 303–316, dez. 2006.
- ÇAĞDAŞ, V.; STUBKJÆR, E. Design research for cadastral systems. **Computers, Environment and Urban Systems**, v. 35, n. 1, p. 77–87, jan. 2011.
- CAUCHICK-MIGUEL, P. A. et al. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 3. ed. Rio de Janeiro: Elsevier, 2018.
- CORRAR, L. J.; PAULO, E.; DIAS FILHO, J. M. **Análise Multivariada: Para Os Cursos De Administração, Ciências Contábeis E Economia**. 1. ed. São Paulo: Atlas, 2014.
- CORSI, F.; PIRINO, D.; RENÒ, R. Threshold bipower variation and the impact of jumps on volatility forecasting. **Journal of Econometrics**, v. 159, n. 2, p. 276–288, 1 dez. 2010.
- DEGIANNAKIS, S. ARFIMAX and ARFIMAX-TARCH realized volatility modeling. **Journal of Applied Statistics**, v. 35, n. 10, p. 1169–1180, out. 2008.
- DICKEY, D. A.; FULLER, W. A. Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. **Econometrica**, v. 49, n. 4, p. 1057, jul. 1981.
- DING, Z.; GRANGER, C. W. J.; ENGLE, R. F. A long memory property of stock market returns and a new model. **Journal of Empirical Finance**, v. 1, n. 1, p. 83–106, 1 jun. 1993.

DUEKER, M. Dynamic Forecasts of Qualitative Variables. **Journal of Business & Economic Statistics**, v. 23, n. 1, p. 96–104, jan. 2005.

EKONG, N. et al. A Comparative Study of the Impact of Dummy Variables on Regression Coefficients and Canonical Correlation Indices: An Empirical Perspective. **International Journal of Analysis and Applications**, v. 19, n. 4, p. 576–586, 17 jun. 2021.

ENDERS, W. **Applied Econometric Time Series**. Disponível em: <<https://www.wiley.com/en-us/Applied+Econometric+Time+Series%2C+4th+Edition-p-9781118808566>>. Acesso em: 10 out. 2020.

ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987, jul. 1982a.

ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987, jul. 1982b.

ENGLE, R. F.; BOLLERSLEV, T. Modelling the persistence of conditional variances. **Econometric Reviews**, v. 5, n. 1, p. 1–50, 1986.

ENGLE, R. F.; GRANGER, C. W. J. Co-Integration and Error Correction: Representation, Estimation, and Testing. **Econometrica**, v. 55, n. 2, p. 251, mar. 1987.

FERNANDES RC, C. F. W. Espacialização temporal dos focos de queimadas e de poluentes atmosféricos (Co , Ch4 , No2 , N2o) em Alagoas. **Ciência e Natura**, p. 287–294, 2013.

FERREIRA, P. C. et al. **Análise de Séries Temporais em R: Curso Introductório**. 1. ed. Rio de Janeiro: Elsevier, 2018.

FRANSES, P. H. Primary Demand for Beer in the Netherlands: An Application of ARMAX Model Specification. **Journal of Marketing Research**, v. 28, n. 2, p. 240–245, 6 maio 1991.

FREITAS, S. R. et al. Emissões de queimadas em ecossistemas da América do Sul. **Estudos Avançados**, v. 19, n. 53, p. 167–185, 2005.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. **The Journal of Finance**, v. 48, n. 5, p. 1779, dez. 1993.

GRANGER, C. W. J. DEVELOPMENTS IN THE STUDY OF COINTEGRATED ECONOMIC VARIABLES. **Oxford Bulletin of Economics and Statistics**, v. 48, n. 3, p. 213–228, 1 maio 1986.

HANNAN, E. J.; QUINN, B. G. The Determination of the Order of an Autoregression. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 41, n. 2, p. 190–195, jan. 1979.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice (2nd ed)**. Australia: [s.n.].

- JOHANSEN, S. Statistical analysis of cointegration vectors. **Journal of Economic Dynamics and Control**, v. 12, n. 2–3, p. 231–254, jun. 1988.
- KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, n. 1–3, p. 159–178, out. 1992.
- LACERDA, D. P. et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741–761, 26 nov. 2013.
- LARA, L. L. et al. Properties of aerosols from sugar-cane burning emissions in Southeastern Brazil. **Atmospheric Environment**, v. 39, n. 26, p. 4627–4637, 2005.
- LI, C.; LI, M.; LI, Y. Improving estimation of forest aboveground biomass using landsat 8 imagery by incorporating forest crown density as a dummy variable. **Canadian Journal of Forest Research**, v. 50, n. 4, p. 390–398, 2020.
- LIANG, J.; LI, L.; ZENG, D. Evolutionary dynamics of cryptocurrency transaction networks: An empirical study. **PLOS ONE**, v. 13, n. 8, p. e0202202, 17 ago. 2018.
- LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, n. 2, p. 297–303, 1 ago. 1978.
- LOUZADA, F. et al. **Controle Estatístico de Processos-Uma Abordagem Prática para Cursos de Eng. e Administração**. LTC ed. Rio de Janeiro: [s.n.].
- MALHOTRA, N. K. **Pesquisa de Marketing** -. 4ª ed. Porto Alegre: Bookman, 2006.
- MARCH, S. T.; SMITH, G. F. **Design and natural science research on information technology Decision Support Systems**. [s.l: s.n.].
- MARCONI, M. DE A.; LAKATOS, E. M. **Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisas, elaboração, análise e interpretação de dados**. 8. ed. São Paulo: Atlas, 2018.
- MIAO, J. et al. A Dummy-Variable Model for Humidity-Influenced DC Film Capacitors Lifetime Estimation. **IEEE JOURNAL OF EMERGING AND SELECTED TOPICS IN POWER ELECTRONICS**, v. 11, p. 1056–1070, 2023.
- MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. Rio de Janeiro: [s.n.].
- MORETTIN, P. A. . **Econometria Financeira: um Curso em Séries Temporais Financeiras**. 3. ed. São Paulo: Blucher, 2017.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Blucher, 2004.
- NAKAMOTO, S. **Bitcoin: A Peer-to-Peer Electronic Cash System**. [s.l: s.n.]. Disponível em: <www.bitcoin.org>. Acesso em: 11 out. 2020.
- NELSON, D. B. Conditional Heteroskedasticity in Asset Returns: A New Approach. **Econometrica**, v. 59, n. 2, p. 347, mar. 1991.

- PEARL, J. Fusion, Propagation, and Structuring in Belief Networks. In: **Probabilistic and Causal Inference**. New York, NY, USA: ACM, 1986. v. 29p. 241–288.
- PECICAN, E. S. Forecasting Based on Open VAR Model. **Romanian Journal of Economic Forecasting-1**, v. 1, p. 59–69, 2010.
- PEFFERS, K. et al. A Design Science Research Methodology for Information Systems Research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45–77, 8 dez. 2007.
- PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, v. 75, n. 2, p. 335–346, 1988.
- ROMME, A. G. L. Making a Difference: Organization as Design. **Organization Science**, v. 14, n. 5, p. 558–573, out. 2003.
- SCHWARZ, G. Estimating the Dimension of a Model. **The Annals of Statistics**, 1978.
- SENNA, V. DE; MENDONÇA, A.; SOUZA. **Expense Relation Analysis in Social Program Welfare in Brazil**. Verlag: Éditions universitaires européennes, 2017.
- SENNA, V. DE; SOUZA, A. M. Assessment of the relationship of government spending on social assistance programs with Brazilian macroeconomic variables. **Physica A: Statistical Mechanics and its Applications**, v. 462, p. 21–30, nov. 2016.
- SENNA, V. DE; SOUZA, A. M. Criptomodas e sistema financeiro: revisão sistemática de literatura. **Revista de Administração de Empresas**, v. 63, n. 4, p. e2022- 0019, 8 set. 2023.
- SIMON, H. A. **The Sciences of the Artificial**. [s.l: s.n.]. v. 11
- SIMS, C. A. Macroeconomics and Reality. **Econometrica**, 1980.
- SUGIURA, N. Further analysis of the data by Akaike's information criterion and the finite corrections. **Communications in Statistics - Theory and Methods**, v. 7, n. 1, p. 13–26, 1 jan. 1978.
- THOMÉ, A. M. T.; SCAVARDA, L. F.; SCAVARDA, A. J. Conducting systematic literature review in operations management. **Production Planning & Control**, v. 27, n. 5, p. 408–420, 3 abr. 2016.
- VAN AKEN, J. E. Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules. **Journal of Management Studies**, v. 41, n. 2, p. 219–246, 10 fev. 2004.
- WANG, X. Z. et al. Gas Leakage Prediction Model of Large-Scale Explosions in Hard Rock Based on Quantification Theory. **Transport in Porous Media**, v. 95, n. 1, p. 171–183, 28 out. 2012.
- WANG, Z.-X.; HE, L.-Y.; ZHAO, Y.-F. Forecasting the seasonal natural gas consumption in the US using a gray model with dummy variables. **Applied Soft Computing**, v. 113, p. 108002, dez. 2021.
- WŁODARCZYK, A.; ZAWADA, M. **Modeling the impact of the weather factors on the**

electrical energy consumption in one of the regions in the southern Poland. Disponível em: <<https://ieeexplore-ieee-org.ez47.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=5558738>>. Acesso em: 7 nov. 2023.

Yahoo Finanças. Disponível em: <<https://br.financas.yahoo.com/>>.