

VALUE AT RISK NA GESTÃO DE RISCO DOS ÍNDICES SETORIAIS DA BOLSA DE VALORES BRASILEIRA

VALUE AT RISK IN THE RISK MANAGEMENT OF THE SECTORAL INDICES OF THE BRAZILIAN STOCK EXCHANGE

Gabriele de Vasconcelos Paula

Bacharel em Finanças – Universidade Federal do Ceará - UFC
E-mail: gabrielevasconcelos_paula@hotmail.com

Paulo Rogério Faustino Matos

Docente da Universidade Federal do Ceará - UFC
E-mail: paulomatos@caen.ufc.br

Iana Bezerra Jucá

Docente da Universidade Federal do Ceará - UFC
E-mail: ianajuca@ufc.br

Danielle Augusto Peres

Docente da Universidade Federal do Ceará - UFC
E-mail: danifeaac@gmail.com

Recebido em 20 de outubro de 2023
Publicado em 12 de janeiro de 2024

RESUMO

Este estudo propõe-se a encontrar o modelo *Value at Risk* (VaR) com número de violações satisfatório, a partir dos retornos de sete índices setoriais da B3, de 2008 a 2022. São eles: Índice de Consumo (ICON), Energia Elétrica (IEE), Financeiro (IFNC), Materiais Básicos (IMAT), Imobiliário (IMOB), Setor Industrial (INDX) e Utilidade Pública (UTIL). Estimou-se quatro tipos de VaR: Gaussiano Incondicional e Condicional; *Best Fitting* Incondicional e Condicional. Considerou-se média e desvio padrão fixos (incondicionais) e variáveis (condicionais), modelos Gaussianos e não Gaussianos (representados por distribuições de probabilidade que apresentaram bom ajuste para os dados). O teste de violações reprovou os Gaussianos Incondicionais a 99% de confiança para todos os índices, porém aprovando-os a 95%; reprovou os modelos *Best Fitting* Incondicionais a 99% de confiança para o IEE, IMAT, IMOB e UTIL; porém aprovando-os para todos os índices a 95%; e aprovou todos os índices nos modelos condicionais, tanto os Gaussianos quanto *Best Fitting*, em ambos os intervalos de confiança.

Palavras-chave: *Value at Risk*; índices setoriais; gestão de risco.

ABSTRACT

This study aims to find the Value at Risk (VaR) model with a satisfactory number of violations, based on the returns of seven B3 sectoral indices, from 2008 to 2022. They are: Consumption Index (ICON), Electric Energy (IEE), Financial (IFNC), Basic Materials (IMAT), Real Estate (IMOB), Industrial Sector (INDX) and Public Utility (UTIL). Four types of VaR were estimated: Unconditional and Conditional Gaussian; Best Fitting Unconditional and Conditional. Fixed (unconditional) and variable (conditional) mean and standard deviation were considered, Gaussian and non-Gaussian models

(represented by probability distributions that presented a good fit to the data). The violations test failed the Unconditional Gaussians at 99% confidence for all indices but approved them at 95%; failed the Unconditional Best Fitting models at 99% confidence for IEE, IMAT, IMOB and UTIL; however, approving them for all indices at 95%; and approved all indices in the conditional models, both Gaussian and Best Fitting, in both confidence intervals.

Keywords: Value at Risk; sectoral indices; risk management.

1. INTRODUÇÃO

De acordo com Jorion (2010), desde a década de 70, a gestão de risco nos mercados financeiros foi cada vez mais se aperfeiçoando em razão do aumento da volatilidade nos mercados a nível mundial. Sucessivos episódios causaram crises no setor financeiro que influenciaram uma maior oscilação nos preços dos ativos e instabilidade também nas Bolsas de Valores internacionais, o que inclui a Bolsa brasileira, chamada B3.

Sendo assim, um investidor ou gestor de uma carteira de investimentos precisa considerar, como instrumento de análise na tomada de decisão de investimento, não apenas as estratégias que permitirão a maximização de ganhos, mas também metodologias que proporcionem o controle de risco e minimização de perdas que estão sujeitos à volatilidade nos preços dos ativos.

Dessa forma, o *Value at Risk* (VaR) se apresenta como uma ferramenta largamente utilizada para administrar o risco dos investimentos, pois permite uma estimativa da maior perda esperada para um ativo ou carteira de investimentos, associada a um nível de confiança, durante determinado intervalo de tempo.

O presente estudo analisa, através do VaR, o risco de mercado de sete índices setoriais da B3, durante o período de janeiro de 2008 a dezembro de 2022. São eles o Índice de Consumo (ICON), Índice de Energia Elétrica (IEE), Índice Financeiro (IFNC), Índice de Materiais Básicos (IMAT), Índice Imobiliário (IMOB), Índice do Setor Industrial (INDX) e Índice Utilidade Pública (UTIL).

Para as séries diárias de retornos dos índices analisados, foram estimados quatro tipos de VaR, abrangendo o primeiro e segundo momentos estatísticos (média e desvio padrão) em condições denominadas incondicionais (fixos ao longo do tempo) e condicionais (variáveis ao longo do tempo). Outro aspecto considerado, na estimativa desses modelos, diz respeito à distribuição de probabilidade das séries de retornos. Foram estimados modelos Gaussianos e não Gaussianos, estes últimos foram representados por distribuições teóricas de probabilidade que apresentaram um bom ajuste para os dados. Sendo assim, os quatro modelos são: VaR Gaussiano Incondicional, VaR Gaussiano Condicional, VaR *Best Fitting* Incondicional e VaR *Best Fitting* Condicional. A média de retornos e a volatilidade condicional foram modeladas a partir de modelos econométricos do tipo ARMA-GARCH. A eficácia dos valores de VaR obtidos foi medida por meio de um teste de violações.

O objetivo principal do presente estudo é, a partir de uma base composta por diferentes setores da economia brasileira, encontrar o modelo VaR com resultado satisfatório no teste de validação e, adicionalmente, fazer inferências acerca da aplicabilidade da distribuição normal para as séries em observação.

2. REVISÃO DE LITERATURA

2.1 Índices setoriais no mercado acionário

Os índices setoriais representam carteiras teóricas compostas por ativos de maior negociabilidade e representatividade no setor ao qual fazem parte. Dessa forma, os índices se apresentam como importantes indicadores do comportamento agregado do segmento econômico considerado, o que permite um acompanhamento do desempenho de cada setor.

O ICON representa o comportamento das ações das empresas mais relevantes do setor de consumo cíclico e não-cíclico. O IEE, primeiro índice setorial criado pela BM&FBovespa, abrange as principais ações do setor de energia elétrica. O IFNC é o índice composto por ações de empresas relevantes dos setores de intermediários financeiros, serviços financeiros diversos, previdência e seguros. O IMAT mede o desempenho das empresas mais representativas do setor de materiais básicos. O IMOB trata do comportamento das principais ações de empresas dos setores de atividade imobiliária, como exploração de imóveis e construção civil. O INDX mede o desempenho das ações mais representativas do setor industrial e, por fim, o UTIL é responsável por representar o desempenho das empresas mais relevantes do setor de utilidade pública, que abrange energia elétrica, água, saneamento e gás.

Na literatura, há trabalhos que se propuseram a estudar o mercado de ações sob uma perspectiva setorial. De acordo com Baca et al. (2000), os movimentos setoriais, foram considerados instrumentos mais precisos para explicar a volatilidade de sete importantes mercados de ações, a nível mundial, quando comparados aos movimentos dos próprios países. Os autores verificaram que, em 20 anos, a influência de elementos específicos de cada país no desempenho dos mercados analisados estava diminuindo, enquanto os elementos setoriais se mantiveram constantes ou crescentes. Adicionalmente, L. Costa & M. Costa (2018) dedicaram-se ao estudo dos impactos de fatores macroeconômicos sobre os índices de ações setoriais.

Segundo Ramos (2003), analisar as performances setoriais também é importante devido ao aumento da quantidade de fundos de investimentos adotando estratégias setoriais. Tendo em vista que ações de empresas de um mesmo setor, por estarem expostas ao mesmo mercado e arcabouço regulatório, estão sujeitas a riscos semelhantes.

Nessa perspectiva, Jubert et al. (2008) consideram que, nos períodos de crise, a diversificação representa uma estratégia eficiente para minimizar o risco das carteiras de investimentos, destacando também que é intuitivo supor que existam setores mais resilientes a momentos de instabilidade no mercado. Embora Monte (2019) sinalize que existe uma interdependência dos índices setoriais a curto prazo, de forma que efeitos positivos e negativos podem ser disseminados entre os índices, o que impacta, por conseguinte, a tomada de decisão de investimentos dos *stakeholders*.

Já Freire et al. (2017) realizaram um estudo que concilia tanto os índices setoriais quanto o risco dos investimentos. O objetivo era identificar a contribuição marginal de risco dos setores brasileiros ao risco sistêmico, considerando elementos relevantes da economia brasileira e internacional, mostrando que além do setor financeiro, existem outros setores com potencial para causar crises sistêmicas.

Tratando da análise de padrões de volatilidade, Medeiros (2012) estudou o comportamento dos índices setoriais de energia elétrica (IEE), de telecomunicações (ITEL), do setor industrial (INDX) e financeiro (IFNC), concluindo que os modelos que consideram o

efeito assimetria resultaram em melhor desempenho quando comparados aos que não o consideraram. Além disso, também obteve a conclusão de que o comportamento da variância condicional ao longo do tempo é bastante semelhante entre os índices estudados.

2.2 Histórico de crises no mercado financeiro e gestão de risco

Até a década de 80, as evidências de calote e crises financeiras eram escassas, os episódios eram espaçados e os volumes de capital envolvidos eram considerados bastante modestos em relação aos Produtos Internos Brutos (PIBs) dos países na época. Por esse motivo, havia poucos instrumentos financeiros disponíveis no mercado, que, até então, era incipiente, de caráter amador e não necessitava de uma gestão de risco mais institucional e organizada.

A partir de 1980, foram surgindo, com maior frequência, crises que ocasionaram impactos mais expressivos no setor bancário. Pode-se citar a crise das instituições de poupança e empréstimo nos EUA. O colapso de várias instituições financeiras nos EUA, conhecidas como *Savings and Loans* (S&Ls), resultou em uma crise no sistema bancário e custou bilhões de dólares aos contribuintes. Um exemplo notável é o caso do *Lincoln Savings and Loan Association* (Kane, 1989).

Na década de 1990, pode-se citar a crise financeira no Japão, conhecida como "década perdida", que revelou fragilidades no setor bancário japonês, incluindo problemas de inadimplência e insolvência de instituições financeiras, como o caso do banco *Long-Term Credit Bank of Japan*. Essa crise incentivou a busca por regulamentações mais sólidas e práticas de gestão de risco no setor bancário (Hoshi & Kashyap, 1999).

Em razão de eventos assim, os países entenderam que era preciso uniformizar instrumentos de gestão de risco e proporcionar maior estabilidade e segurança ao sistema financeiro mundial. Principalmente quando se trata do setor bancário, muito suscetível a efeito contágio, conforme discutido amplamente na literatura por autores como Claessens & Forbes (2004), Rochet & Tirole (1996), e outros que exploraram o fenômeno de contágio no setor bancário, abordando aspectos teóricos e empíricos relacionados à transmissão de riscos entre instituições financeiras e como isso pode levar a crises financeiras mais amplas.

Dessa forma, foram implementados os acordos de Basileia, que representaram um marco histórico na regulação bancária a nível mundial, contribuindo para a solidez e robustez do sistema financeiro. A partir do primeiro acordo, em 1998, o foco regulatório passou a ser na solvência das instituições financeiras, com o objetivo de evitar o advento de crises sistêmicas originárias do setor bancário. Nessa perspectiva, foram estabelecidas exigências sobre o capital dos bancos em relação ao risco dos seus ativos, dessa forma, quando surgissem períodos de instabilidade no mercado que resultasse em uma desvalorização súbita dos ativos da instituição, essa companhia não perderia sua capacidade de honrar com seus compromissos com terceiros e dessa forma, evitaria riscos sistêmicos (Sobreira & Martins, 2011).

Ademais, também foram desenvolvidos instrumentos de gestão de risco como derivativos, seguros, estratégias de diversificação, além de métricas de risco como desvio padrão, *drawdown*, semivariância, beta de mercado e *tracking error volatility*.

Na década de 2000, houve a crise financeira global, no ano de 2008, que abalou o sistema bancário internacional e destacou as limitações nas práticas de gestão de riscos e na regulamentação bancária. Esse episódio, que começou nos Estados Unidos, foi desencadeado pela crise imobiliária no país, que por sua vez foi impulsionada por práticas arriscadas de

empréstimos imobiliários conhecidos como *subprime* (empréstimos de alto risco para mutuários com histórico de crédito fraco), pela securitização e venda desses empréstimos no mercado financeiro, exposição a estratégias com derivativos e pela falta de supervisão e regulamentação adequadas ao setor financeiro (Taylor, 2009).

À medida que a crise imobiliária se intensificou, várias instituições financeiras enfrentaram grandes perdas e dificuldades de liquidez. Isso levou ao colapso ou à falência de instituições financeiras emblemáticas, como o *Lehman Brothers*, *Bear Stearns* e *Merrill Lynch*, e afetou instituições tradicionais como o *Citigroup* e o *Bank of America*.

A crise financeira se espalhou rapidamente para além dos EUA e teve um impacto global. Os mercados financeiros congelaram, o crédito ficou escasso e muitas empresas enfrentaram dificuldades financeiras. Houve uma profunda recessão econômica em várias partes do mundo, com desemprego em massa e uma crise generalizada no setor imobiliário (Reinhart & Rogoff, 2011).

Como resposta à crise, governos e bancos centrais implementaram medidas de resgate e estímulo econômico para tentar estabilizar o sistema financeiro e promover a recuperação econômica, concentrando-se, de acordo com Taylor (2009), em diagnosticar problemas no mercado de crédito bancário, com foco em liquidez. A crise de 2008 teve um impacto duradouro nas políticas regulatórias e nas práticas de gestão de riscos do setor financeiro, com reformas significativas sendo implementadas para evitar eventos semelhantes no futuro.

2.3 A métrica *Value at Risk*

Na gestão de risco, a divulgação do documento técnico intitulado *Riskmetrics* mostrou-se como um marco histórico. Esse documento, elaborado pelo banco de investimentos *J.P. Morgan*, apresentou uma versão simplificada do modelo de gestão de riscos utilizado pelo banco, com ênfase na estimativa da métrica *Value at Risk* (VaR).

Ao longo dos anos e com a consolidação do conceito, o VaR se tornou uma ferramenta amplamente empregada na gestão de risco de mercado, sendo utilizada para atender desde requisitos legais até finalidades gerenciais na avaliação de risco.

De acordo com Kimura et al. (2009), o VaR passou a ser utilizado não apenas por instituições financeiras, mas também por empresas de outros setores, como Petrobras e Braskem, como medida de avaliação de risco de mercado.

Jorion (2010) define o VaR como uma síntese da maior perda esperada da cotação de um ativo, em determinado período de tempo e intervalo de confiança. O grande diferencial dessa métrica está na possibilidade de resumir, em apenas um número, o maior potencial de perda e risco no mercado, tornando-se assim de fácil compreensão e interpretação.

No trabalho de Torres et al. (2008), o VaR é calculado, conforme a metodologia apresentada pelo *Riskmetrics*, para uma carteira teórica formada por uma dezena de ativos e é comparado com o VaR de um índice estruturado a partir desses mesmos ativos. Enquanto Alarcon (2005) analisou três modelos de estimação para o VaR de séries de retornos das ações da Petrobras e da Cia. Vale do Rio Doce. São eles: o modelo de variância incondicional, o de variância condicional – GARCH (1,1) e o de Simulação Histórica.

Por fim, destaca-se Costa (1999) que considerou inicialmente o cálculo do VaR para o mercado de ações pelo modelo Gaussiano tradicional. Porém, constatou que a distribuição normal não se ajusta bem à realidade do mercado acionário, dado que as séries históricas se apresentam, geralmente, como leptocúrticas. Por essa perspectiva, Moralles e Sartoris Neto (2010) divulgaram um estudo calculando o VaR paramétrico do Ibovespa e de determinados ativos da Bolsa após encontrar a distribuição de probabilidade teórica que melhor se ajustava aos dados por meio do teste de aderência de Kolmogorov-Smirnov.

2.4 Modelagem da volatilidade condicional por meio de modelos GARCH

No presente estudo, a análise da volatilidade condicional de uma série diária de retornos é um elemento importante. Para o cálculo do VaR, essa medida será utilizada como parâmetro fixo, sendo representada pelo desvio padrão das séries, e variável ao longo do tempo.

Nessa perspectiva, Furriel (2011) afirma que instrumentos financeiros geralmente revelam comportamentos dinâmicos diferentes com o tempo, oscilando entre momentos de maior e menor volatilidade. Dessa forma, o autor ainda destaca que “compreender e modelar a volatilidade de séries financeiras é importante na medida em que permite refinar a estimação dos parâmetros de um modelo que traduza o comportamento dos dados e conseqüentemente efetuar previsões com maior exatidão”.

No trabalho de Silva et al. (2010), o VaR é aplicado a índices de bolsas de valores latino-americanas, utilizando modelos de previsão de volatilidade GARCH, EWMA e EQMA. Por sua vez, Souza Sobrinho (2001) estimou a volatilidade do IBOVESPA por meio de modelos da família GARCH e de Volatilidade Estocástica, cujos resultados mostraram que ambas as metodologias foram satisfatórias. Assim como Galdi e Pereira (2007) que utilizaram o cálculo do VaR e estimaram a volatilidade de ações preferenciais da Petrobras a partir de modelos EWMA, GARCH e Volatilidade Estocástica.

Destaca-se também o trabalho de Jubert *et al* (2008) que, por meio de modelos ARCH, analisa o padrão de volatilidade dos principais índices financeiros da Bovespa, demonstrando que todos os índices considerados no estudo foram representados por modelos que evidenciaram o fato da volatilidade de um dia presente ser influenciada pela oscilação de mercado do dia anterior.

Não apenas para índices brasileiros, mas Gaio (2009) examinou os índices dos principais mercados de ações do globo para propor; na determinação do VaR, uma análise comparativa de modelos de volatilidade condicional usando a família ARCH.

3. METODOLOGIA

3.1 VaR Gaussiano e *Best Fitting*, condicionais e incondicionais

Neste artigo, para as séries diárias de retornos dos índices analisados, foram estimados quatro tipos de VaR, abrangendo o primeiro e segundo momentos estatísticos (média e desvio padrão) em condições denominadas incondicionais (fixos ao longo do tempo) e condicionais (variáveis ao longo do tempo). Outro aspecto considerado na estimação desses modelos diz respeito à distribuição de probabilidade das séries de retornos. Os modelos são: VaR Gaussiano Incondicional, VaR Gaussiano Condicional, VaR *Best Fitting* Incondicional e VaR *Best Fitting* Condicional. Em seguida, verificou-se quais desses modelos apresentam resultados satisfatórios a partir de um teste de violações.

A versão paramétrica mais simples do *Value at Risk* (VaR Gaussiano Incondicional) usada para assumir que o retorno dos ativos segue uma distribuição normal e momentos estatísticos fixos ao longo do tempo em um determinado nível de confiança c (%), denominada VaR^{GI} , é dada por:

$$VaR^{GI}(c\%) = \mu - \sigma \alpha_{c(\%)} \quad (1)$$

Onde μ é o parâmetro de média da amostra, σ mede o desvio padrão da amostra e $\alpha_{c(\%)}$ é uma constante alfa associada ao nível confiança. Este nível alfa é 1,64485 para o nível de confiança de 95% e 2,32630 para o nível de confiança de 99%.

Essa relação é a função quantil de uma PDF gaussiana, ou seja, o inverso da função de distribuição acumulada associada a uma probabilidade unicaudal de 5% ou 1%. Essa probabilidade está relacionada a um nível de confiança, c (%), segundo a relação dada por $1 - c$ (%).

Uma extensão dessa abordagem gaussiana pode ser obtida ao utilizar outra distribuição de probabilidade, que não seja uma normal. O teste Jarque-Bera confirma que os dados não seguem uma distribuição normal. Sendo assim, ainda mantendo os parâmetros fixos ao longo do tempo, é possível adotar uma função de distribuição de probabilidade com melhor ajuste à série de retorno (VaR *Best Fitting* Incondicional), dada por:

$$VAR^{BFI}(c\%) = F_{BF}^{-1}(1 - c|\hat{E}) \quad (2)$$

Onde \hat{E} é o vetor dos parâmetros da distribuição e F_{BF}^{-1} significa o inverso da função acumulada dessa distribuição, ou seja, sua função quantil. Com o auxílio do software *Easy Fit* e utilizando o teste Kolmogorov -Smirnov como medida de classificação, obteve-se a distribuição que melhor representa cada série temporal a partir do *ranking* gerado e que possuía dois parâmetros, como a distribuição normal. As distribuições selecionadas foram Laplace (para o ICON e IMOB) e Hiperbólica Secante (para os demais índices setoriais). A partir da distribuição com melhor classificação e para os níveis de confiança desejados, são fornecidos os retornos críticos (R^*), que representam os valores em risco para essa medida de VaR.

O terceiro e quarto modelos são classificados como condicionais, pois permitem momentos variáveis no tempo, que se ajustem às evoluções nas séries de retornos, e os incorporam na medida VaR.

Observando a relação (2), torna-se necessário usar uma relação quantílica, $F_{BF}^{-1}(\cdot)$, de modo que seu vetor \hat{E} de parâmetros pode variar no tempo. Para, por exemplo, incorporar momentos variáveis no tempo em uma distribuição gaussiana, uma vez que a média e desvio padrão são os parâmetros da distribuição. Os respectivos parâmetros, μ e σ , respectivamente, foram substituídos por μ_t e σ_t , extraídos usando modelos ARMA-GARCH. Este VaR Gaussiano com momentos condicionais, denotados por $VaR^{GC}(c\%)$, é dado por:

$$VaR^{GC}(c\%) = \mu_t - \alpha_{(c\%)} \sigma_t \quad (3)$$

Para usar outra distribuição, também é preciso substituir o vetor \hat{E} dos parâmetros por μ_t e σ_t . A busca por essa distribuição de melhor ajuste precisou impor uma limitação no intervalo de famílias de distribuição contínua: foram utilizadas apenas as distribuições cujo vetor \hat{E} é tal que $\hat{E} \in \mathbb{R}$. Isto permite a incorporação das séries de momentos condicionais, μ_t e σ_t , extraídas de uma ARMA-GARCH na função quantil da distribuição de melhor ajuste.

Esta evolução na literatura de Value at Risk proposta por Filho et al. (2020), denominada $VAR^{MBFC}(c\%)$, é dada por:

$$VaR^{MBFC}(c\%) = F_{BF}^{-1}(1 - c | \mu_t, \sigma_t) \quad (4)$$

No ranking das distribuições de probabilidade, a distribuição de Laplace mostrou-se ter melhor ajuste para alguns índices estudados, enquanto a Secante Hiperbólica mostrou-se melhor para outros.

Os parâmetros da distribuição de Laplace são μ e λ , e seu desvio padrão é dado por $\sigma = \sqrt{2}/\lambda$. Neste caso, tornou-se possível derivar modelos ARMA-GARCH multivariados baseados em Laplace, denominados $VaR^{MLapC}(c\%)$, dados por:

$$VaR^{MLapC}(c\%) = \mu_t + \sigma_t \frac{\ln(2(1-c\%))}{\sqrt{2}} \quad (5)$$

Na distribuição Secante Hiperbólica, a média e desvio padrão são dados diretamente pelos parâmetros μ e σ . Sendo assim, é possível derivar o modelo ARMA-GARCH, denotado por $VaR^{MHSC}(c\%)$, dado por:

$$VaR^{MHSC}(c\%) = \mu_t + 2\sigma_t \frac{\ln\left\{\tan\left[\frac{\pi(1-c\%)}{2}\right]\right\}}{\pi} \quad (6)$$

As medidas VaR obtidas nos quatro modelos foram comparadas, por meio do teste de violações. Por meio desse teste, uma medida VaR é rejeitada se o número de violações for maior que 1%, ao nível de confiança de 99%. Adotando o nível de confiança de 95%, uma medida VaR é rejeitada se o número de violações for maior que 5%.

3.2 Estimação dos momentos condicionais

Nos modelos condicionais, a média e volatilidade não permanecem constantes ao longo do tempo. Para estimar a volatilidade condicional, utilizou-se o modelo apresentado por Bollerslev (1986), denominado GARCH (*Generalized Autoregressive Conditional Heterocedasticity*), que é uma generalização do modelo ARCH introduzido por Engle (1982). O modelo GARCH (p,q) pode ser definido por:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (7)$$

$$h_t = \alpha_0 + \sum_{i=1}^m \alpha_i r_{t-i}^2 + \sum_{j=1}^n \beta_j h_{t-j} \quad (8)$$

Em que ε_t são i.i.d., com média zero, $\alpha_0 > 0$, $\alpha_i \geq 0$, $i = 1, \dots, m - 1$, $\beta_j \geq 0$, $j = 1, \dots, n - 1$, $\beta_n > 0$, $\sum_{i=1}^q (\alpha_i + \beta_i) < 1$, $q = \max(m, n)$. Supõe-se que ε_t são normais. Segundo Matos *et al* (2013), adotar essas restrições ao modelo é necessário para assegurar a estacionariedade e positividade da variância condicional.

O modelo GARCH foi utilizado, pois representa uma alternativa mais parcimoniosa à dependência temporal da variância condicional. Ademais, acerca das séries de retornos, aquelas que possuíam a presença de autocorrelação, foi necessário eliminá-la através de modelos lineares (Morettin, 2011). O teste Ljung-Box foi utilizado para verificar a existência de autocorrelação nas séries.

O teste de raiz unitária (ADF) foi realizado e uma vez testada a estacionaridade das séries e confirmada a presença de autocorrelação, a média da série de retorno foi modelada por um modelo autoregressivo e de médias móveis (ARMA) e os resíduos desse modelo por um GARCH. Para um modelo ARMA(p,q)-GARCH(m,n), têm-se:

$$r_t = \varphi_0 + \sum_{i=1}^p \varphi_i r_{t-i} + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (9)$$

$$\varepsilon_t = \sigma_t v_t \quad v_t \sim N(0,1) \quad (10)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^n \beta_j \sigma_{t-j}^2 \quad (11)$$

Na busca da especificação mais adequada, foram estimados os modelos ARMA pelo *software R Studio*, enquanto os modelos GARCH foram estimados por meio de comparações entre todas as combinações possíveis até a defasagem 2, conforme recomendado por Morettin (2011). Os modelos foram selecionados de acordo com o critério de informação de Akaike (AIC).

3.3 Teste de violações

O teste de violações utilizado nesse trabalho é uma maneira para verificar a consistência entre as perdas observadas e as perdas previstas e consiste em comparar o histórico dos retornos dos índices setoriais com as perdas que foram estimadas através do VaR. Em outros termos, consiste em registrar a taxa de exceções, correspondente ao número de vezes em que o retorno observado foi pior que o VaR.

Sendo assim, o modelo foi considerado como bem ajustado quando o número de observações que ultrapassaram os valores de VaR calculados foi apenas até 5% das observações para um nível de confiança de 95%. Adotando um critério mais rigoroso, um modelo considerado como bem ajustado quando o número de observações que ultrapassaram os valores de VaR em até 1%, para o nível de confiança de 99%.

Se há muitas exceções, o modelo subestima o risco. Por outro lado, poucas exceções também refletem um ponto de atenção, pois podem conduzir o investidor a uma alocação de capital excessiva ou ineficiente.

4. ANÁLISE DOS RESULTADOS

4.1 Base de dados e estatísticas descritivas

A base de dados utilizada neste trabalho foi obtida a partir das cotações diárias de fechamento de sete índices setoriais da B3, no período de janeiro de 2008 a dezembro de 2022, totalizando 25.991 observações. São eles: o Índice de Consumo (ICON), Índice de Energia Elétrica (IEE), Índice Financeiro (IFNC), Índice de Materiais Básicos (IMAT), Índice Imobiliário (IMOB), Índice do Setor Industrial (INDX) e Índice Utilidade Pública (UTIL).

A partir das cotações, calculou-se os retornos líquidos nominais diários de cada índice, considerando que esses dados possuem propriedades estatísticas desejáveis, como a estacionariedade. Dessa forma, os retornos representam a base de dados utilizada no presente estudo.

Na tabela 1 estão listadas as principais estatísticas descritivas das séries analisadas nesse estudo. Adicionalmente, o índice Ibovespa foi o *benchmark* de mercado utilizado para calcular as métricas *downside risk*, *tracking error volatility* e beta de mercado.

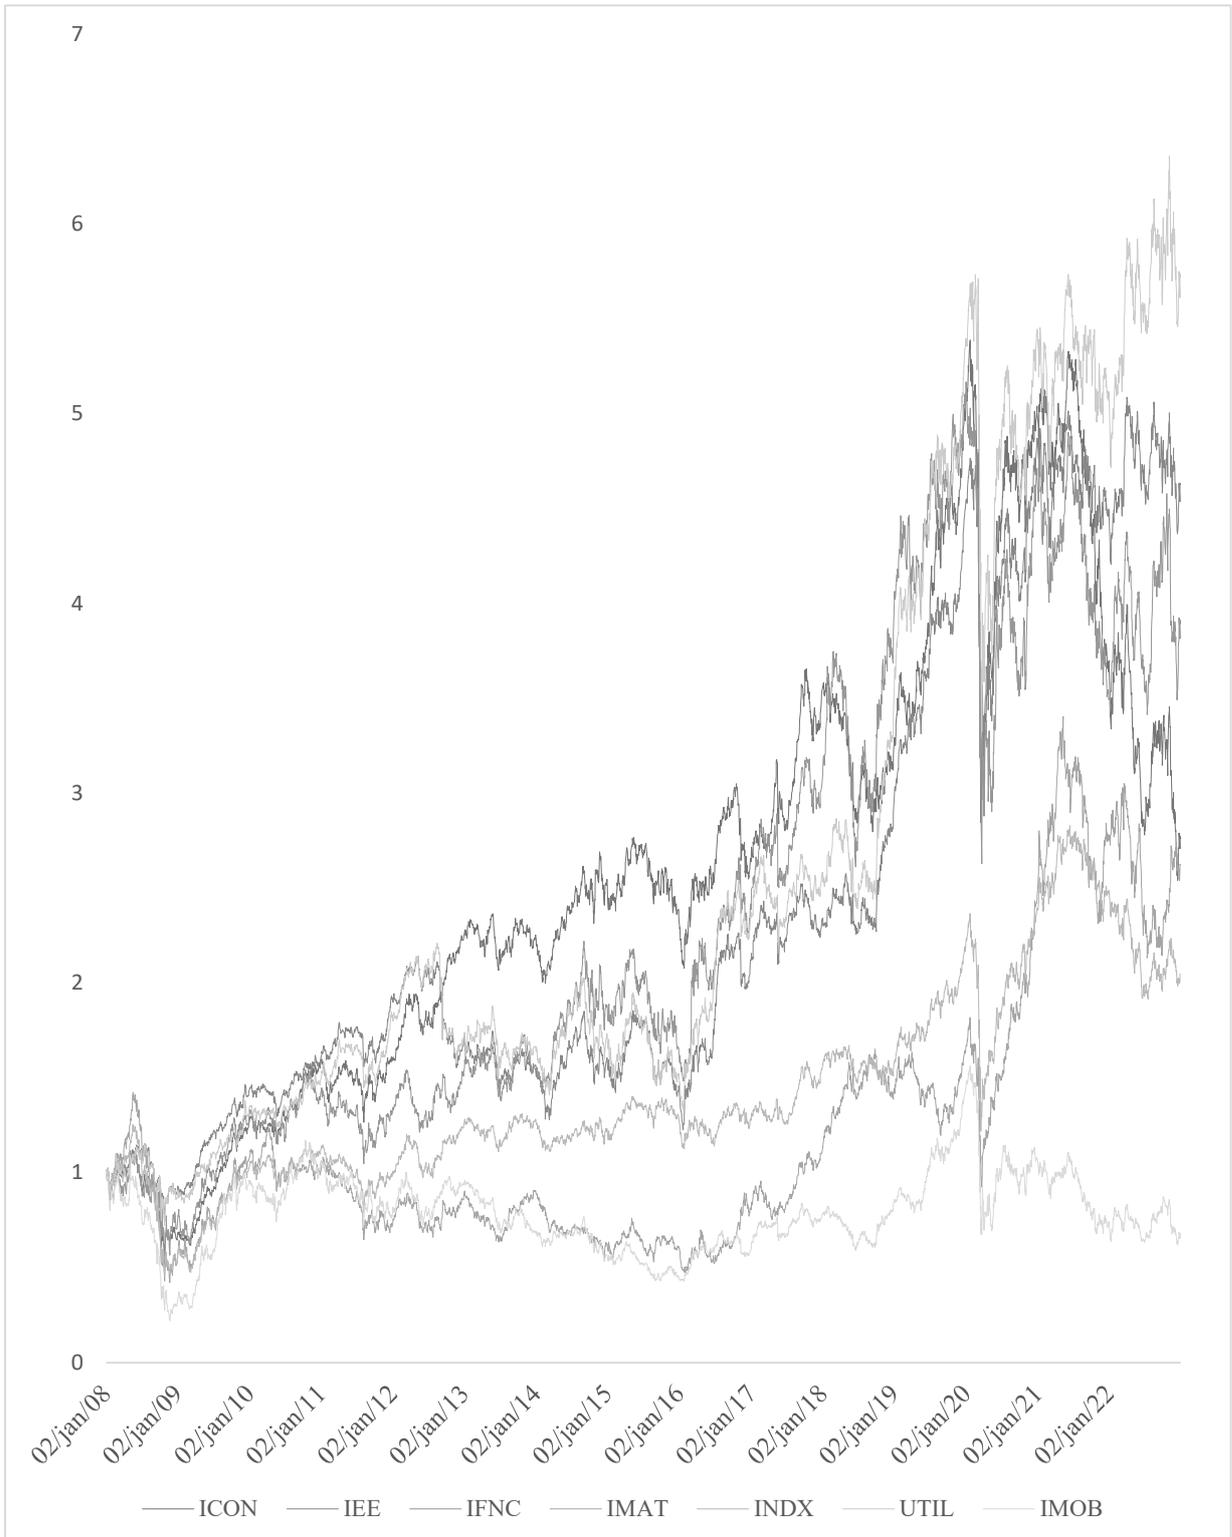
Tabela 1 - Estatísticas descritivas dos retornos nominais diários dos índices setoriais em estudo

Métricas	ICON	IEE	IFNC	IMAT	INDX	UTIL	IMOB
Média	0,039%	0,050%	0,056%	0,047%	0,032%	0,058%	0,015%
Mínimo	-16,153%	-11,592%	-13,282%	-15,810%	-16,755%	-13,584%	-17,686%
Máximo	12,557%	12,298%	20,922%	14,323%	12,558%	12,402%	19,453%
Acumulado	176,124%	362,672%	289,280%	162,340%	104,871%	472,060%	-32,394%
Desvio padrão	1,537%	1,340%	1,983%	2,049%	1,557%	1,513%	2,272%
Semivariância	1,118%	0,973%	1,371%	1,449%	1,137%	1,096%	1,608%
Drawdown	52,851%	42,642%	55,519%	70,385%	63,773%	42,006%	78,586%
Downside risk	0,006	0,008	0,006	0,008	0,006	0,008	0,009
Tracking error volatility	0,913%	1,122%	0,845%	1,211%	0,783%	1,129%	1,327%
Beta de mercado	0,749	0,588	1,024	0,944	0,795	0,665	1,053
Índice de Sharpe	0,010	0,020	0,017	0,012	0,005	0,023	-0,003
Sortino (Semivariância)	0,014	0,028	0,024	0,016	0,007	0,032	-0,005
Sortino (downside risk)	0,014	0,025	0,046	0,020	0,002	0,035	-0,016
Índice de Treynor	0,000	0,000	0,000	0,000	0,000	0,001	0,000
Índice de Calmar	0,000	0,001	0,001	0,000	0,000	0,001	0,000
Information ratio	0,010	0,018	0,030	0,014	0,001	0,025	-0,011
M2	0,000	0,001	0,001	0,000	0,000	0,001	0,000
Assimetria	-0,549	-0,351	0,396	-0,075	-0,581	-0,322	-0,149
Semicurtose	10,600	7,077	4,082	4,842	11,064	7,100	6,353
Curtose	15,666	12,214	11,825	8,966	16,594	12,093	11,346

Fonte: Elaborado pelos autores.

As médias de retornos apresentaram-se coerentes com a teoria financeira por serem próximas de zero. Na figura 1, consta o ganho acumulado dos índices setoriais, com destaque para a *performance* do UTIL e IEE, que apresentam boas relações risco-retorno. Em contrapartida, o IMOB foi o único que apresentou retorno acumulado negativo, no período.

Figura 1 - Retorno acumulado dos índices setoriais.



Fonte: Elaborado pelos autores.

Também constam na tabela 1 algumas métricas de risco. Para o desvio padrão, quanto maior o seu valor, maior é o risco associado ao ativo. Por sua vez, a semivariância consiste na variância das observações com retorno menor que o retorno médio, dessa forma, a métrica

penaliza apenas os retornos piores que o esperado. Enquanto o *drawdown* representa a maior queda acumulada do ativo no período analisado.

Para as métricas de risco associadas ao *benchmark*, tem-se o *downside risk* que calcula os desvios negativos dos ativos quando eles são menores que o do *benchmark* utilizado (Ibovespa), quanto maior for o seu valor, mais o ativo tem desempenho pior que o Ibovespa. Dessa forma, essa métrica mede apenas a volatilidade indesejada pelo investidor, ou seja, aquela que gera perdas. O IMOB seguido pelo IMAT, apresentaram os piores valores para ambas as métricas.

Tracking error volatility é uma métrica útil para investidores e gestores, pois permite avaliar a consistência e a estabilidade do desempenho em relação ao índice de referência. Uma baixa *tracking error volatility* pode indicar que o ativo está seguindo de perto o comportamento do índice, enquanto uma alta *tracking error volatility* pode indicar uma gestão mais ativa, com maior potencial de retorno, mas também com maior risco. O beta de mercado, também é uma métrica importante para ser considerada nas tomadas de decisão de investimento, pois mede a sensibilidade do ativo em análise em relação ao *benchmark*. Sendo assim, permite que o investidor avalie o risco sistêmico do investimento.

Ademais, foram apresentadas, na tabela 1, algumas métricas de *performance* que analisam o desempenho de risco associado ao retorno. O índice de Sharpe mede o quanto o retorno excedente de um investimento em relação a um ativo livre de risco proporciona em relação ao risco (desvio padrão). O ativo livre de risco considerado nesse estudo foi a poupança. O índice de Treynor, por sua vez, considera apenas o risco sistêmico (beta de mercado). Enquanto o índice de Calmar considera o *drawdown* como medida de risco e o índice de Sortino mensura o retorno excedente em relação ao *benchmark* dada uma métrica de risco (a semivariância e o *downside risk*).

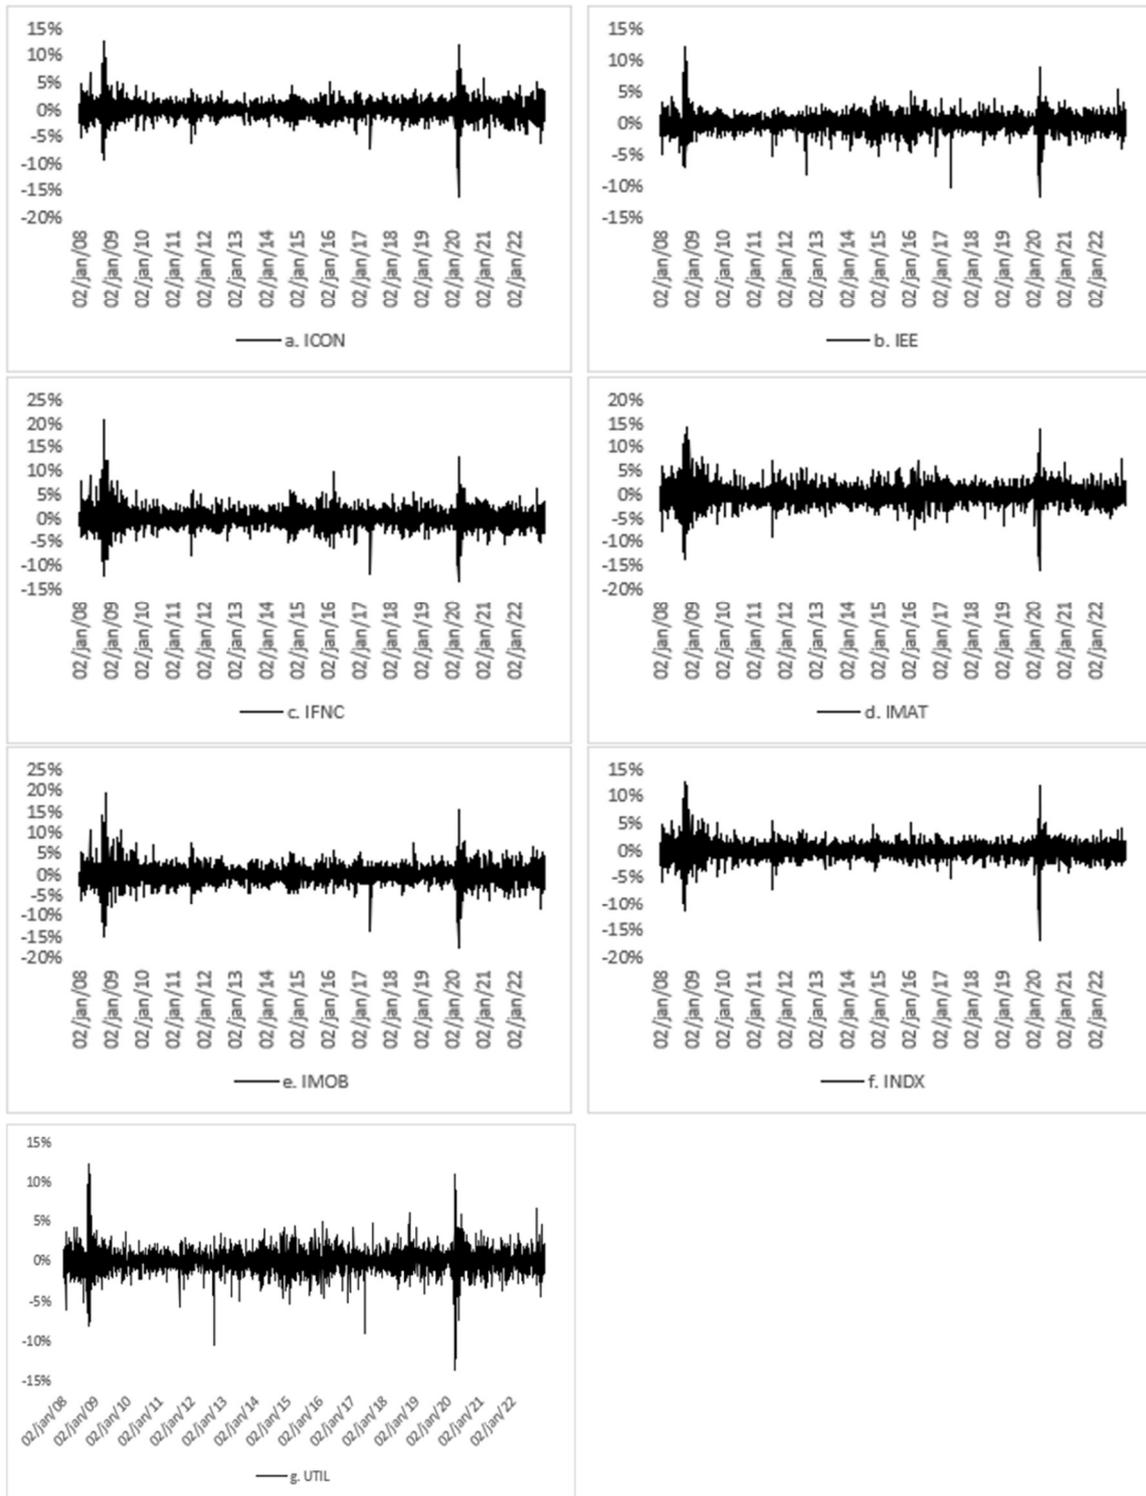
Para todos os índices setoriais, em termos de *performance*, destaca-se o IEE e UTIL com melhores desempenhos. O IFNC também se destaca em métricas como information ratio e M2 (índice de Modigliani) que avaliam o desempenho ajustado ao risco dos investimentos.

Em termos de momentos de terceira e quarta ordem, obteve-se assimetria à esquerda para a maioria dos índices, exceto o IFNC que apresenta assimetria (caudas longas) à direita, indicando maior probabilidade de ocorrerem valores extremos altos na sua série, o que pode ser observado também pelo ganho máximo no período analisado ter sido alcançado pelo índice IFNC. Para a curtose (bilateral) e semicurtose (unilateral, considera apenas as perdas), é possível observar excesso (caudas pesadas) em relação à distribuição normal em todos os índices setoriais, indicando que a chance de valores extremos negativos é alta, com destaque para o INDX e ICON.

Na figura 2, estão retratados os gráficos dos retornos líquidos nominais diários dos sete índices setoriais. Pode-se observar acentuados picos de volatilidade principalmente em 2008, em razão da crise internacional desse ano, e em 2020, pela crise advinda com a pandemia COVID-19.

Ao longo do tempo, houve outros momentos pontuais de volatilidade, porém, menos relevantes.

Figura 2- Retornos líquidos nominais diários dos índices setoriais.



Fonte: Elaborado pelos autores.

4.2 Modelos *Best Fitting*

A fim de testar a hipótese nula de normalidade dos retornos, realizou-se o teste de Jarque-Bera, cujos resultados estão apresentados na tabela 2.

Tabela 2 - Teste de Jarque-Bera

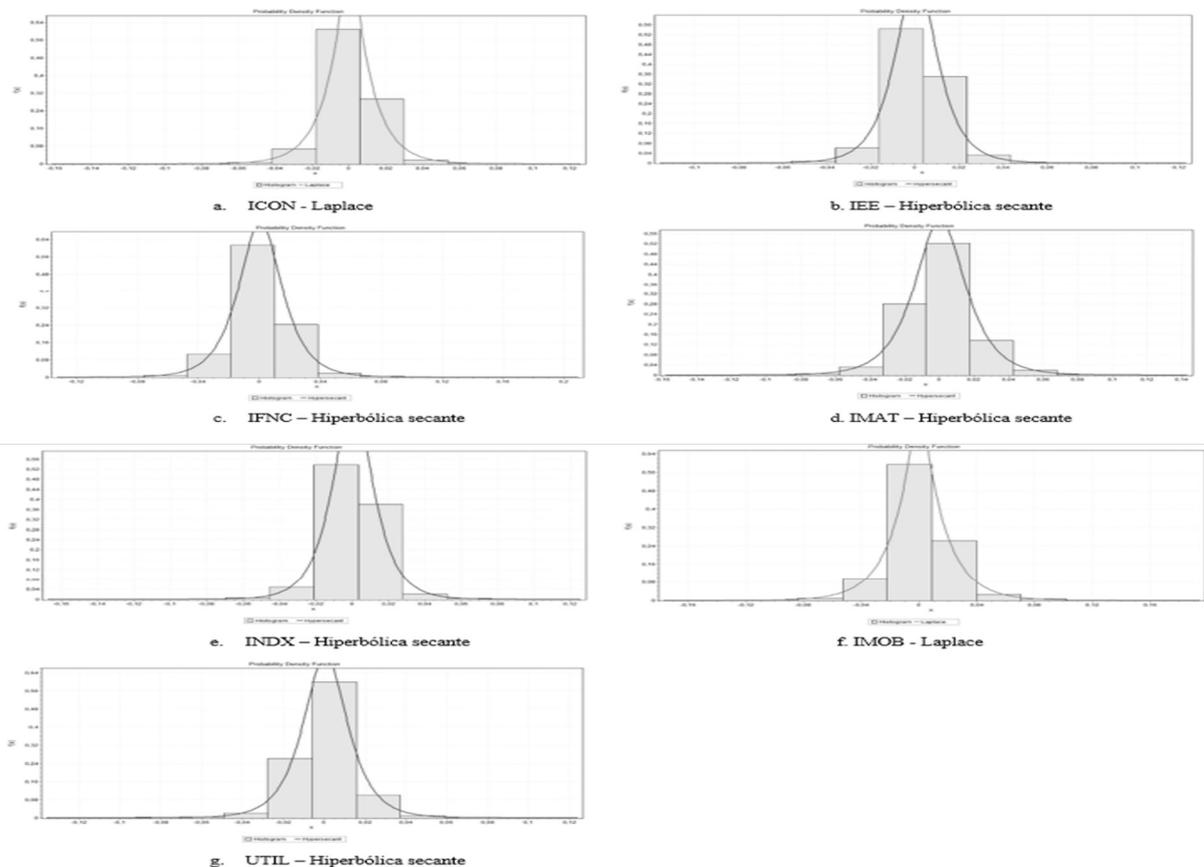
Índices	Estatística	P-valor
ICON	22.271	0.00
IEE	11.969	0.00
IFNC	11.327	0.00
IMAT	5.580,5	0.00
IMOB	11.041	0.00
INDX	30.361	0.00
UTIL	12.756	0.00

Fonte: Elaborado pelos autores

Para todos os índices, a hipótese nula de normalidade do teste foi rejeitada, o que confirma a teoria de que as distribuições de probabilidade das séries de retornos possuem causas mais pesadas que a distribuição normal, sendo observadas ocorrências de valores extremos com frequência maior. (Gourieroux & Jasiak, 2001).

Sendo assim, buscou-se a distribuição de probabilidade com melhor ajuste aos dados, para obter o VaR *Best Fitting* (incondicional e condicional). A figura 3 mostra as funções densidades de probabilidades das distribuições com dois parâmetros que ocuparam a melhor posição no *ranking*.

Figura 3 - Distribuição com dois parâmetros que melhor ajusta as séries.



Fonte: Elaborado pelos autores.

Na tabela 3, é possível observar que a distribuição normal apresenta pior colocação no *ranking* quando comparada à *best fitting* escolhida, sendo assim, a normal não é considerada um bom ajuste para as séries analisadas no presente estudo. Além disso, constam os retornos críticos (r^*) a 99% e 95%, calculados conforme as equações (5) e (6) apresentadas na sessão 3 do presente trabalho.

Tabela 3 - Melhor distribuição para as séries de retorno

Índice	Melhor distribuição	Parâmetros	$r^*(99\%)$	$r^*(95\%)$	Posição da distribuição <i>best fitting</i> no <i>ranking</i>	Posição da distribuição normal no <i>ranking</i>
ICON	Laplace	$\mu=0,039\%$ $\lambda=91,980$	-4,214%	-2,464%	2°	12°
IEE	Hiperbólico a secante	$\mu= 0,050\%$ $\sigma=1,34\%$	-3,494%	-2,119%	3°	13°
IFNC	Hiperbólico a secante	$\mu= 0,056\%$ $\sigma=1,983\%$	-5,188%	-3,153%	5°	13°
IMAT	Hiperbólico a secante	$\mu= 0,047\%$ $\sigma=2,049\%$	-5,144%	-3,280%	4°	11°
IMOB	Laplace	$\mu=0,015\%$ $\lambda=62,249$	-6,269%	-3,684%	5°	11°
INDX	Hiperbólico a secante	$\mu= 0,032\%$ $\sigma=1,557\%$	-4,086%	-2,489%	5°	11°
UTIL	Hiperbólico a secante	$\mu= 0,058\%$ $\sigma=1,513\%$	-3,942%	-2,390%	3°	10°

Fonte: Elaborado pelos autores.

4.3 Modelos ARMA-GARCH

Para obter os valores de VaR condicionais (Gaussiano e *Best Fitting*), foram estimadas média e volatilidade condicionais por meio de modelos ARMA-GARCH.

Os resultados para a estimação dos modelos ARMA referentes às séries de retorno de cada índice setorial estão listados na tabela 4. A série de médias condicionais foi obtida pelo *software EViews*.

Tabela 4 - Modelos ARMA estimados

Índices	Modelo
ICON	AR (1)
IEE	ARMA (2,4)
IFNC	ARMA (3,4)
IMAT	ARMA (4,4)
IMOB	MA (3)
INDX	AR (1)
UTIL	ARMA (2,2)

Fonte: Elaborado pelos autores

Todas as séries são estacionárias, conforme o teste *Augmented Dickey-Fuller* (ADF) apresentado na tabela 5, que rejeitou a hipótese nula de raiz unitária.

Tabela 5 - Teste ADF

Índices	Estatística	P-valor
ICON	-14,146	0,01
IEE	-14,527	0,01
IFNC	-14,060	0,01
IMAT	-14,352	0,01
IMOB	-14,523	0,01
INDX	-13,99	0,01
UTIL	-14,886	0,01

Fonte: Elaborado pelos autores

Também foi realizado o teste de Ljung-Box, apresentado na tabela 6, onde verificou-se a ausência de autocorrelação nos resíduos, pela aceitação da hipótese nula.

Tabela 6 - Teste Ljung-Box

Índices	Estatística	P-valor
ICON	0,2938	0,863
IEE	0,1141	0,998
IFNC	0,2073	0,995
IMAT	0,5059	0,992
IMOB	0,2710	0,873
INDX	0,0124	1,000
UTIL	5,8440	0,120

Fonte: Elaborado pelos autores

Para modelar a volatilidade condicional, estimou-se modelos GARCH, por meio do *software EViews* e segundo o critério de Akaike (AIC), como consta na tabela 7.

Tabela 7 - Modelos GARCH estimados

Índices	Modelo	AIC
ICON	GARCH (2,2)	-5,560
IEE	GARCH (1,1)	-6,009
IFNC	GARCH (1,1)	-5,251
IMAT	GARCH (1,1)	-5,190
IMOB	GARCH (2,2)	-4,764
INDX	GARCH (2,2)	-5,876
UTIL	GARCH (2,2)	-5,816

Fonte: Elaborado pelos autores

4.4 Estimação do VaR e teste de violações

Dessa forma, tornou-se possível estimar os modelos VaR propostos nesse trabalho. São eles: VaR Gaussiano Incondicional, VaR Gaussiano Condicional, VaR *Best Fitting* Incondicional e VaR *Best Fitting* Condicional.

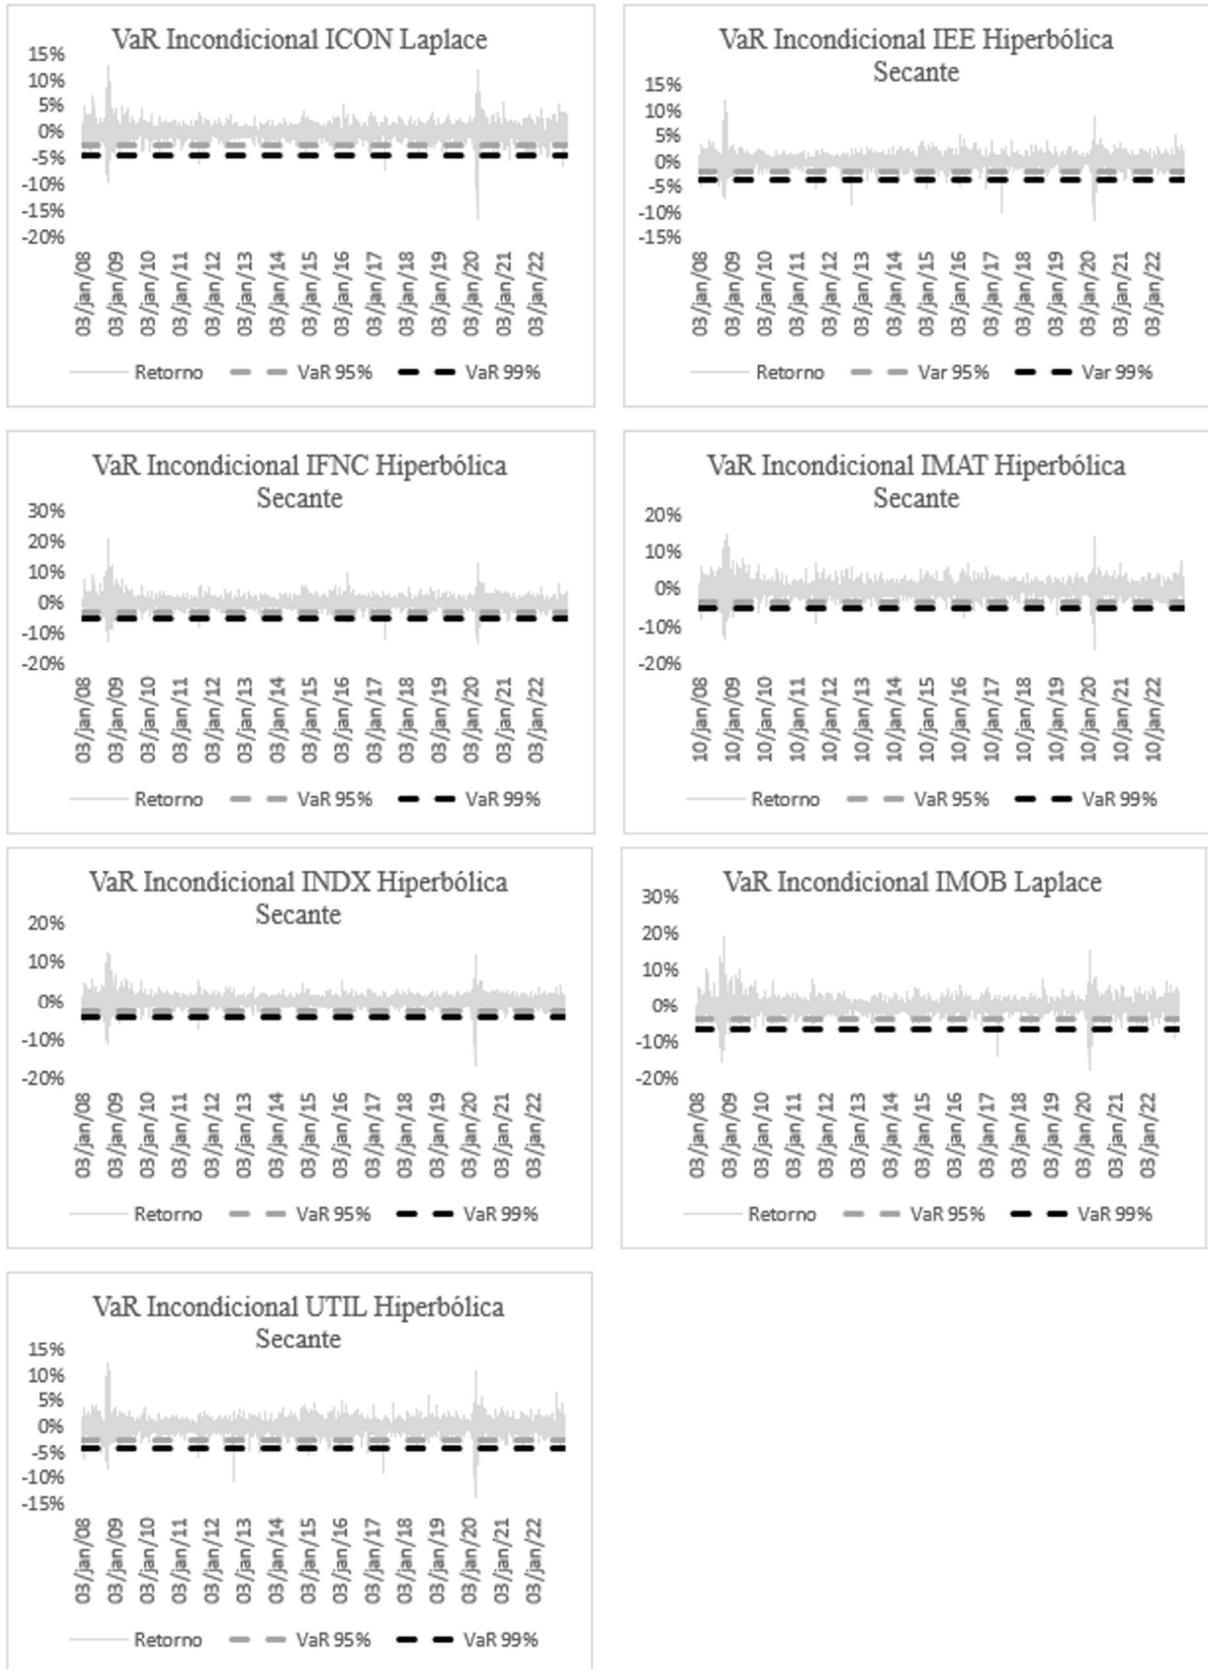
Nas figuras 4, 5, 6 e 7 estão os gráficos das séries de retornos dos índices setoriais estudados e das séries de VaR para os modelos Gaussianos e *Best Fitting*, incondicionais e condicionais, para o nível de confiança de 95% e 99%. Na tabela 7 estão listadas as exceções verificadas para todos os modelos.

Figura 4 - Séries de VaR Gaussianas, a 95% e 99% de confiança para modelos incondicionais.



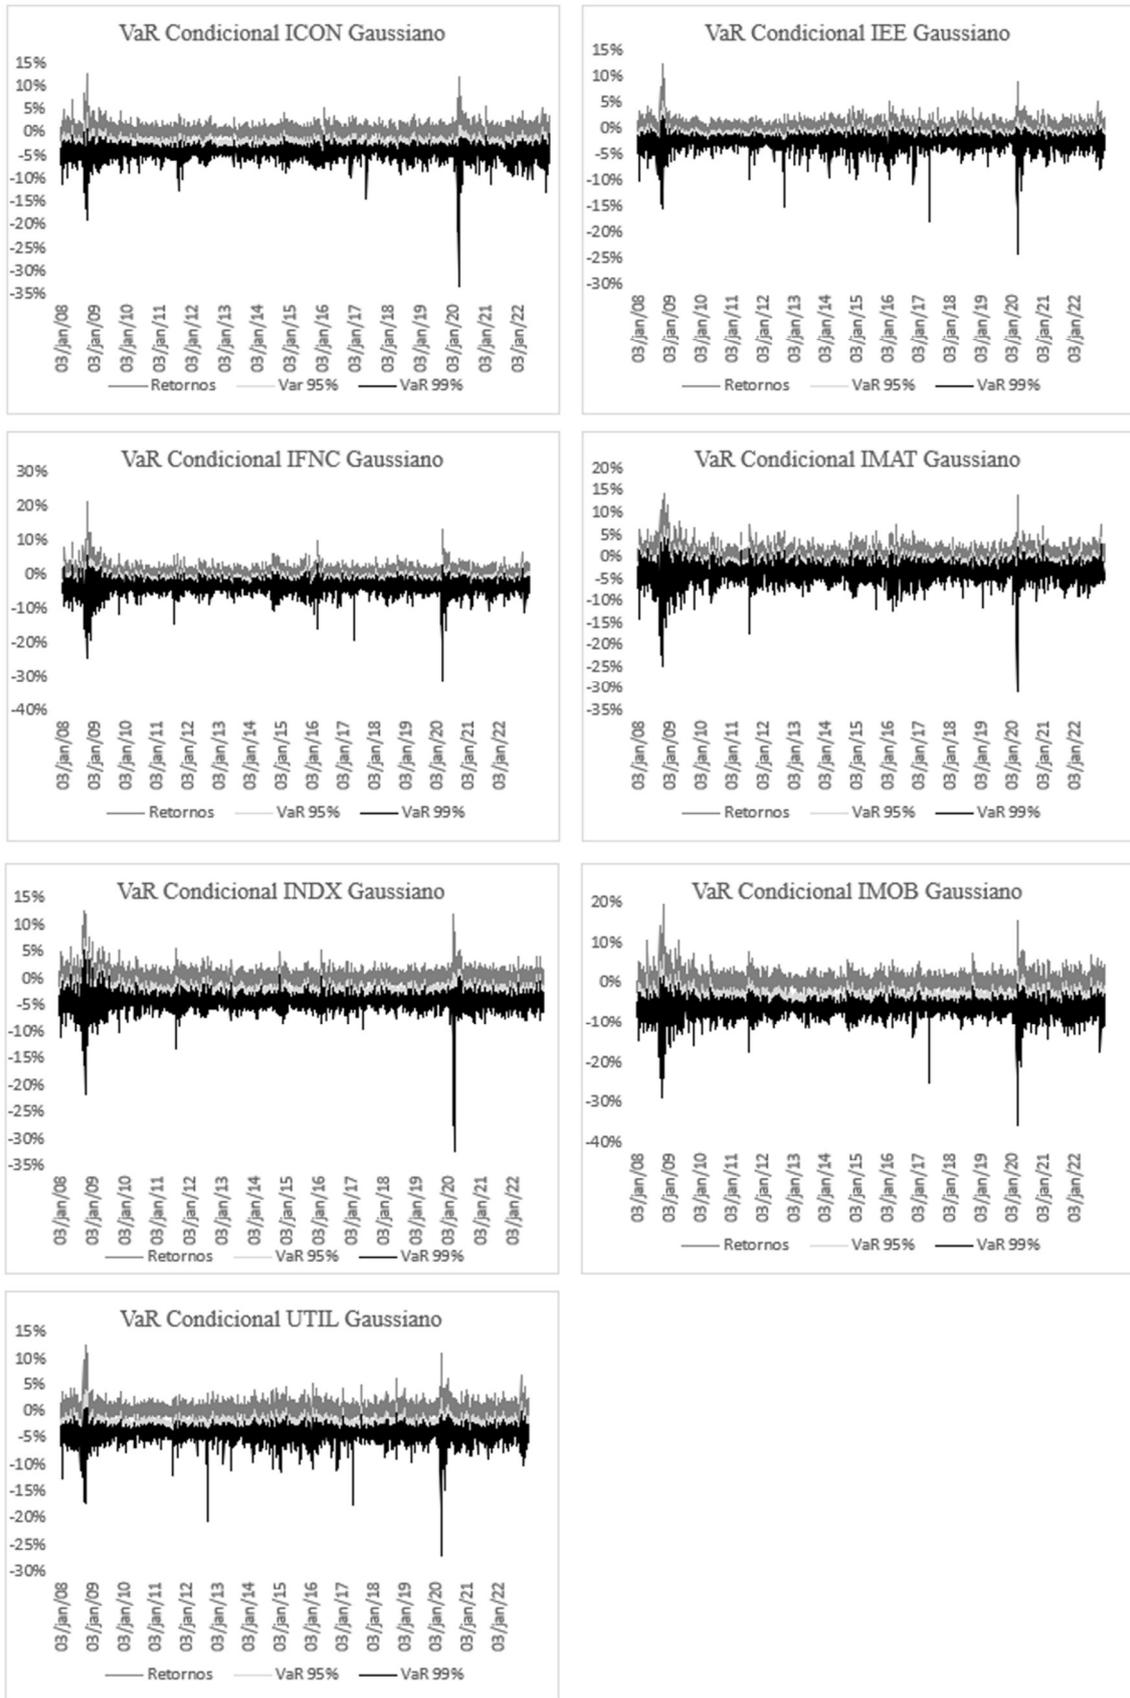
Fonte: Elaborado pelos autores.

Figura 5 - Séries de VaR Best Fitting, a 95% e 99% de confiança para modelos incondicionais.



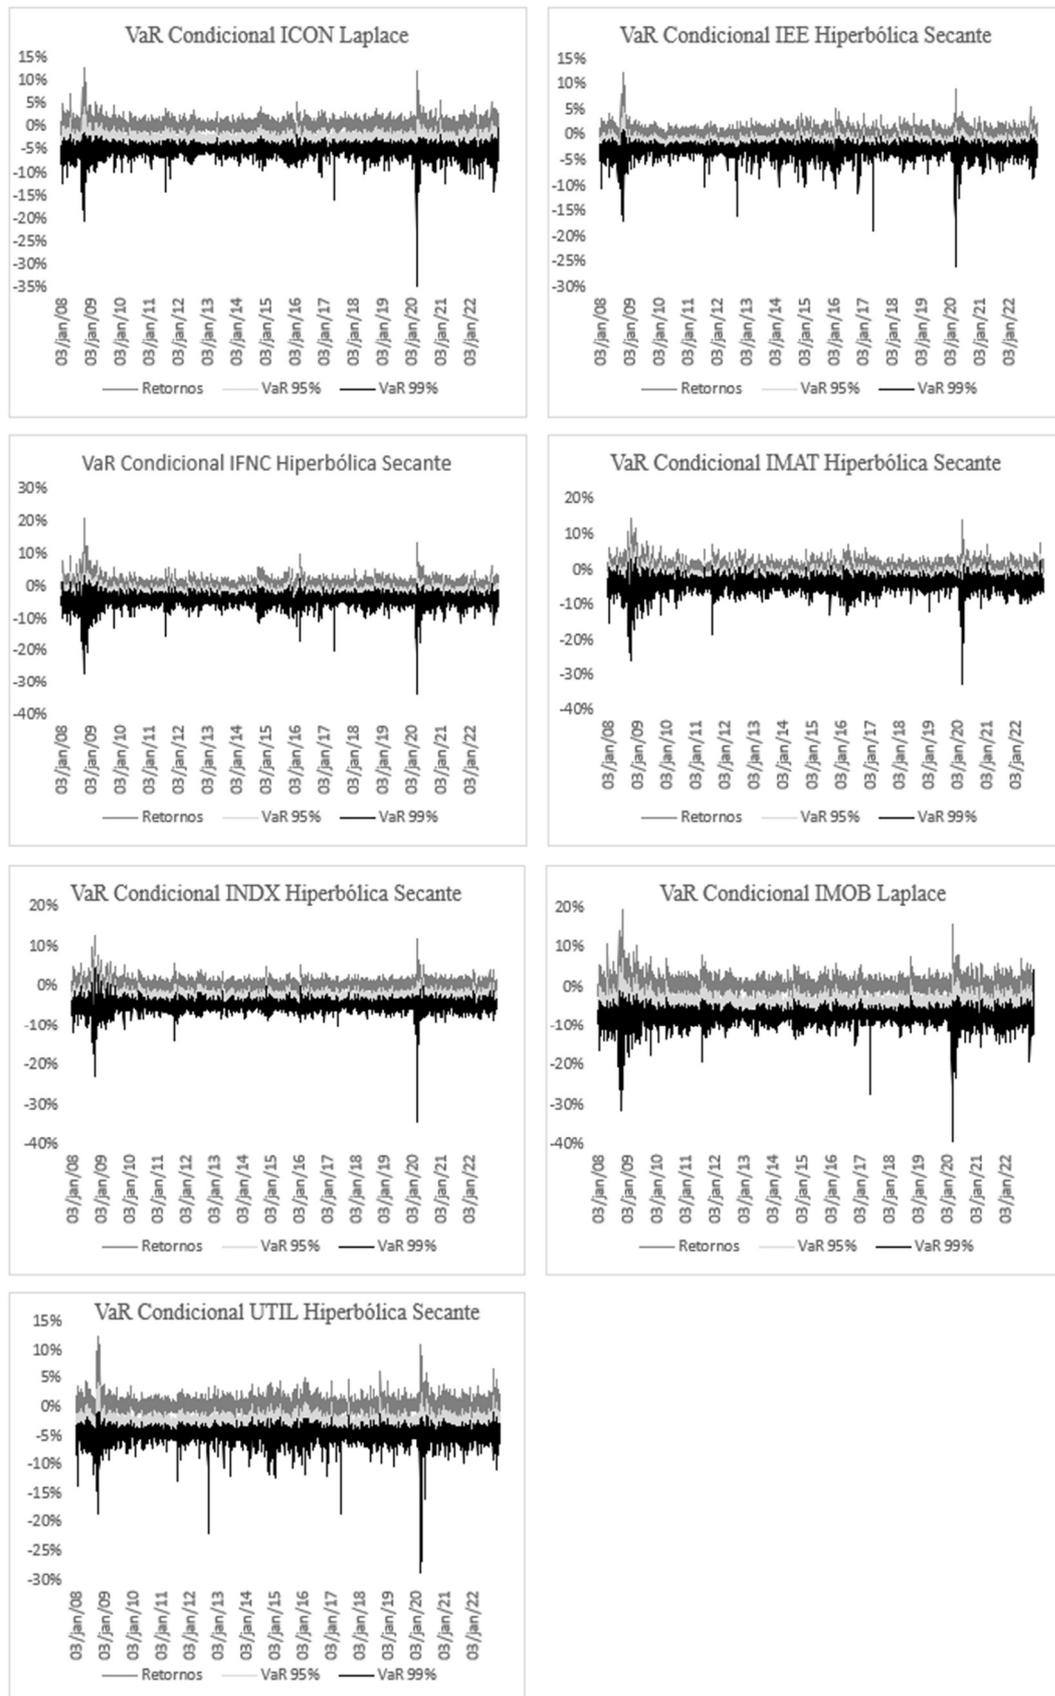
Fonte: Elaborado pelos autores.

Figura 6 - Séries de VaR Gaussiano, a 95% e 99% de confiança para modelos condicionais.



Fonte: Elaborado pelos autores.

Figura 7 - Séries de VaR Best Fitting, a 95% e 99% de confiança para modelos condicionais.



Fonte: Elaborado pelos autores.

Tabela 8 - Número de exceções ao VaR

(continua)

Índices	VaR		Exceções em 25.991 observações diárias	
	Modelo	Nível de confiança	nº	%
ICON	Gaussiano Incondicional	95%	145	3.91%
		99%	56	1.51%
	<i>Best Fitting</i> Incondicional	95%	150	4.04%
		99%	32	0.86%
	Gaussiano Condicional	95%	0	0.00%
		99%	0	0.00%
	<i>Best Fitting</i> Condicional	95%	0	0.00%
		99%	0	0.00%
IEE	Gaussiano Incondicional	95%	134	3.61%
		99%	63	1.70%
	<i>Best Fitting</i> Incondicional	95%	143	3.85%
		99%	39	1.05%
	Gaussiano Condicional	95%	0	0.00%
		99%	0	0.00%
	<i>Best Fitting</i> Condicional	95%	0	0.00%
		99%	0	0.00%
IFNC	Gaussiano Incondicional	95%	126	3.39%
		99%	50	1.35%
	<i>Best Fitting</i> Incondicional	95%	134	3.61%
		99%	33	0.89%
	Gaussiano Condicional	95%	0	0.00%
		99%	0	0.00%
	<i>Best Fitting</i> Condicional	95%	0	0.00%
		99%	0	0.00%
IMAT	Gaussiano Incondicional	95%	140	3.77%
		99%	56	1.51%
	<i>Best Fitting</i> Incondicional	95%	146	3.93%
		99%	38	1.02%
	Gaussiano Condicional	95%	0	0.00%
		99%	0	0.00%
	<i>Best Fitting</i> Condicional	95%	0	0.00%
		99%	0	0.00%
IMOB	Gaussiano Incondicional	95%	132	3.56%
		99%	51	1.37%
	<i>Best Fitting</i> Incondicional	95%	135	3.64%
		99%	38	1.02%
	Gaussiano Condicional	95%	0	0.00%
		99%	0	0.00%
	<i>Best Fitting</i> Condicional	95%	0	0.00%
		95%	0	0.00%

Tabela 8 - Número de exceções ao VaR

(Conclusão)

Índices	VaR		Exceções em 25.991 observações diárias	
	Modelo	Nível de confiança	nº	%
IMOB	<i>Best Fitting</i> Condicional	99%	0	0.00%
	Gaussiano Incondicional	95%	131	3.53%
INDX	<i>Best Fitting</i> Incondicional	99%	52	1.40%
		95%	138	3.72%
	Gaussiano Condicional	99%	37	1.00%
		95%	0	0.00%
	<i>Best Fitting</i> Condicional	99%	0	0.00%
		95%	0	0.00%
UTIL	Gaussiano Incondicional	95%	141	3.80%
		99%	56	1.51%
	<i>Best Fitting</i> Incondicional	95%	148	3.99%
		99%	39	1.05%
	Gaussiano Condicional	95%	0	0.00%
		99%	0	0.00%
<i>Best Fitting</i> Condicional	95%	0	0.00%	
	99%	0	0.00%	

Fonte: Elaborado pelos autores

Considerando os modelos incondicionais apresentados nas figuras 3 e 4, esperava-se que as séries de VaR *Best Fitting* apresentassem menos violações (exceções) quando comparadas às séries de VaR Gaussiano. O número de violações, a 95% de confiança, ficou dentro do percentual esperado (menor que 5%), dessa forma, os modelos incondicionais Gaussianos e *Best Fitting* foram aprovados. Porém, a 99% de confiança, todos os modelos incondicionais Gaussianos foram reprovados e os modelos *Best Fitting* reprovados foram IEE, IMAT, IMOB e INDX. Dessa forma, constatou-se que os modelos VaR Gaussiano e *Best Fitting* incondicionais não são totalmente adequados para modelar os dados do presente estudo.

Ademais, observa-se que a maior parte das violações aconteceram inicialmente em 2008 e diante de um cenário de aumento da volatilidade advindo com a crise financeira global, assim como em 2020 e 2021 em razão da pandemia COVID-19 que abalou o mundo.

Algumas violações aconteceram em 2011, período no qual o Brasil passou por eventos políticos e econômicos internos que contribuíram para a volatilidade na Bolsa, como por exemplo as mudanças na equipe econômica do governo e discussões sobre políticas fiscais.

De 2015 a 2017 também surgiram violações diante de um cenário de instabilidade no país. Em 2015 e 2016 o Brasil enfrentou uma forte crise política que culminou no impeachment da, então presidente, Dilma Rousseff. Essa instabilidade política afeta a confiança dos investidores e aumenta a volatilidade do mercado acionário em razão das incertezas em relação ao governo e políticas econômicas. A desaceleração econômica e recessão também faziam parte desse cenário. A queda nos preços das *commodities*, a fuga de investimento estrangeiro e a redução no consumo interno prejudicaram a atividade econômica, causando baixas expectativas de crescimento e deterioração das condições econômicas (Hillier & Loncan, 2019).

Acrescenta-se, ainda, a instabilidade fiscal e preocupações com as contas públicas, pois, nesse período, o Brasil apresentou déficits fiscais elevados e uma dívida pública crescente, conforme dados históricos disponibilizados pelo Banco Central, o que também impactou a volatilidade na bolsa de valores dadas a incerteza a respeito da capacidade do governo controlar seus gastos.

Ao nível de confiança de 99%, o IEE apresentou o maior número de violações no modelo Gaussiano Incondicional enquanto o modelo *Best Fitting* Incondicional foi mais violado pelo IEE e UTIL, cada um apresentando 39 violações. A violação de maior magnitude foi verificada no IMOB, em 16 de março de 2020, cujo retorno negativo observado foi de 17,69% enquanto a métrica indicava -6,27% de perda, a 99% de confiança. Cerca de 60% das violações nos índices aconteceram nos períodos de intensa volatilidade, nos anos de 2008, 2009, 2020 e 2021.

Para os modelos condicionais apresentados nas figuras 5 e 6, esperava-se que as séries de VaR apresentassem resultados melhores que os modelos incondicionais, tendo em vista que os modelos condicionais consideram as informações passadas, dessa forma as séries de VaR se ajustam conforme a volatilidade do período. Adicionalmente, dentro da classe condicional, esperava-se que os resultados com menores violações fossem para os modelos *Best Fitting*, por utilizar uma distribuição com melhor ajuste aos dados. Os resultados obtidos foram de nenhuma violação tanto nos modelos Gaussiano quanto nos *Best Fitting* condicionais.

Apesar disso, esse resultado traz consigo um importante ponto de atenção, tendo em vista que seriam aceitáveis violações em até 5% das observações, a 95% de confiança, ou em até 1% das observações, a 99% de confiança. Como não foram realizadas nenhuma violação, pode-se supor que as séries de VaR condicionais estão superestimando o risco.

Ademais, nesse caso, como critério de desempate, observou-se a diferença média de magnitude entre o retorno observado e o VaR calculado cujos resultados estão apresentados na tabela 9. O modelo com menor diferença foi considerado mais adequado.

Tabela 9 - Critério de desempate VaR Condicional, a 95% e 99% de confiança

Índice	Modelos			
	Gaussiano 95%	Gaussiano 99%	<i>Best Fitting</i> 95%	<i>Best Fitting</i> 99%
ICON	0,1063%	0,2110%	0,1042%	0,2975%
IEE	0,0485%	0,0956%	0,0470%	0,1231%
IFNC	0,0963%	0,1904%	0,0933%	0,2451%
IMAT	0,0941%	0,1865%	0,0911%	0,2403%
IMOB	0,2313%	0,4618%	0,2266%	0,6525%
INDX	0,1104%	0,2195%	0,1069%	0,2831%
UTIL	0,1042%	0,2062%	0,1009%	0,2656%

Fonte: Elaborado pelos autores

A 95% de confiança, os modelos *Best Fitting* são escolhidos para todos os índices setoriais, pois foram considerados mais adequados dada sua menor magnitude média entre o retorno observado e o VaR calculado. No intervalo de confiança de 99%, os modelos Gaussianos apresentaram menor diferença média e, portanto, foram os escolhidos em detrimento dos modelos *Best Fitting*, nesse intervalo.

5. CONCLUSÕES

Diante do cenário composto por frequentes episódios, a partir da década de 70, envolvendo crises no mercado financeiro internacional com volumes de capital cada vez maiores, mostrou-se necessário estruturar e uniformizar instrumentos de gestão de risco para proporcionar maior estabilidade e segurança ao sistema financeiro mundial.

Dessa forma, o *Value at Risk* (VaR) se apresenta como uma ferramenta largamente utilizada para administrar o risco dos investimentos, pois permite uma estimativa da maior perda esperada para um ativo ou carteira de investimentos, associada a um nível de confiança, durante determinado intervalo de tempo.

O presente estudo se propôs a medir o risco de sete índices setoriais da B3, a partir do *Value at Risk* (VaR), representando distintos setores da economia brasileira. Foram estimados quatro modelos de VaR para cada índice setorial estudado, dentre os quais foram considerados aspectos de parâmetros variáveis e não variáveis ao longo do tempo, combinados a distribuições de probabilidade Gaussiana e *Best Fitting*.

A eficácia dos valores de VaR foi medida por meio de um teste de violações, que i. reprovou os modelos VaR Gaussianos Incondicionais a 99% de confiança para todos os índices estudados, porém aprovando-os a 95% de confiança; ii. reprovou os modelos VaR *Best Fitting* Incondicionais, a 99% de confiança, para os índices IEE, IMAT, IMOB e UTIL; porém aprovando-os para todos os índices a 95%. De acordo com o esperado, os retornos foram considerados não normais, dessa forma os modelos *Best Fitting* mostraram-se uma alternativa mais adequada considerando modelos incondicionais com parâmetros fixos ao longo do tempo.

Resultados mais satisfatórios eram esperados nos modelos condicionais tanto nos Gaussianos como principalmente nos *Best Fitting*, com parâmetros variáveis ao longo do tempo, que consideram a informação passada e se ajustam à volatilidade no período. De fato, o número de violações foi zero para todos os modelos condicionais de todos os índices estudados, mostrando que independente da distribuição de probabilidade que melhor se ajusta aos dados, apenas considerar parâmetros variáveis ao longo do tempo já foi suficiente para metrificar o VaR. Esse resultado de zero violações, porém é um ponto de atenção, pois os modelos podem ter excedido no conservadorismo, superestimando o risco. Adicionalmente, nesse caso, como critério de desempate, observou-se a diferença média de magnitude entre o retorno observado e o VaR calculado. O modelo com menor diferença foi considerado mais adequado. Dessa forma, a 95% de confiança, os modelos *Best Fitting* são escolhidos para todos os índices setoriais. A 99% de confiança, os modelos Gaussianos foram escolhidos para todos os índices estudados.

Para trabalhos futuros, sugere-se avaliar a eficácia dos modelos VaR obtidos por meio de testes específicos para esse propósito, como o teste de Kupiec e Christoffersen como trabalhado por Pessoa (2013). Assim como explorar os efeitos de correlação e causalidade entre o cenário econômico do país com os períodos de maior volatilidade e violações.

6. REFERÊNCIAS

Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19 (6), 716-723. <http://dx.doi.org/10.1109/TAC.1974.1100705>

- Alarcon, C. (2005). *Avaliação de Modelos de Value-At-Risk para ações*. [Dissertação de Mestrado, Universidade Estadual de Campinas]. <https://dx.doi.org/10.47749/T/UNICAMP.2005.345310>
- Baca, S., Garbe, B., & Weiss, R. (2000). The rise of sector effects in major equity markets. *Financial Analysts Journal, Association for Investment Management and Research*, 56 (5), 34 – 40. <https://dx.doi.org/10.2469/faj.v56.n5.2388>
- Bollerslev, T. (1986). Generalised autoregressive conditional heteroscedasticity. *Journal of Econometrics*, 31,307-327. [https://dx.doi.org/10.1016/0304-4076\(86\)90063-1](https://dx.doi.org/10.1016/0304-4076(86)90063-1)
- Brito, G.; Corrar, L.; & Batistella, F. (2006). Fatores determinantes da estrutura de capital das maiores empresas que atuam no Brasil. *Rev. Cont. Fin. USP*, 18 (43), 9 – 19. <https://dx.doi.org/10.1590/S1519-70772007000100002>
- Claessens, S., & Forbes, K. (2004, 15 de novembro). *International Financial Contagion: The Theory, Evidence and Policy Implications*. The IMF's Role in Emerging Market Economies: Reassessing the Adequacy of its Resources, Amsterdam. <http://mitsloan.mit.edu/shared/ods/documents?DocumentID=4943>
- Costa, L., & Costa, M. (2018). Os Impactos de Fatores Macroeconômicos sobre Índices de Ações Setoriais: uma Análise através do Algoritmo de Seleção de Modelos Autometrics. *Revista Evidenciação Contábil & Finanças*, 6 (3), 96–109. <https://dx.doi.org/10.22478/ufpb.2318-1001.2018v6n3.38608>
- Costa, J. (1999). Distribuição Hiperbólica das Rentabilidades Accionárias. *FEUNL Working Paper Series*, 353. <http://hdl.handle.net/10362/89150>
- Engle, R. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation, *Econometrica*, 50 (4), 987-1007. <https://dx.doi.org/10.2307/1912773>
- Filho, J. Matos, & P. Fonseca, R. (2020). The role of contagion and integration in risk management measures. *Global Business Review*. <https://dx.doi.org/10.1177/0972150920933857>
- Freire, A., Silva, A., Ribeiro, O., & Cavalcante, P. (2017). Risco sistêmico: uma análise de quebras estruturais nos índices setoriais brasileiros através do modelo CoVaR *Revista de Globalização, Competitividade e Governabilidade*, 11 (3), 74-89. <https://dx.doi.org/10.3232/GCG.2017.V11.N3.04>
- Furriel, A. (2011). *Modelos Heterocedásticos – ARCH e GARCH*. [Tese de Mestrado, Universidade do Porto]. <https://repositorio-aberto.up.pt/bitstream/10216/57365/2/TeseMestradoMargaridaSepulveda.pdf>
- Gaio, L. (2009). *Gestão de riscos no mercado financeiro internacional: uma análise comparativa entre modelos de volatilidade para estimação do Value-at-Risk*. [Dissertação de Mestrado, Universidade de São Paulo]. <https://dx.doi.org/10.11606/D.96.2009.tde-03052010-173001>

- Galdi, F.; & Pereira, L. (2007). Valor em risco (VaR) utilizando modelos de previsão de volatilidade: EWMA, GARCH e volatilidade estocástica. *Brazilian Business Review*, 4 (1), 74-95. <http://dx.doi.org/10.15728/bbr.2007.4.1.5>
- Gourieroux, C.; & Jasiak, J. (2001). *Financial econometrics: problems, models and methods*. Princeton University Press. <https://dx.doi.org/10.2307/j.ctv9hvt42>
- Hillier, D., & Loncan, T. (2019). Political uncertainty and Stock returns: Evidence from the Brazilian Political Crisis. *Pacific-Basin Finance Journal*, 54, 1-12. <https://dx.doi.org/10.1016/j.pacfin.2019.01.004>
- Hoshi, T., & Kashyap, A. (1999). The Japanese Banking Crisis: Where Did It Come From and How Will It End? *NBER Macroeconomics Annual*, 14, 129-212. <https://dx.doi.org/10.3386/w7250>
- Jarque C., & Bera, A. (1987). A test for normality of observations and regression residuals. *International Statistical Review/Revue Internationale de Statistique*, 55, (2), 163-172. <https://dx.doi.org/10.2307/1403192>
- Jubert, R.; Paixão, M.; Monte, P.; & Lima, W. (2008). Um estudo do padrão de volatilidade dos principais índices financeiros da Bovespa: uma aplicação de modelos ARCH. *Revista UnB Contábil*, 11 (1-2), 221-239. https://www.researchgate.net/publication/49583517_Um_Estudo_do_Padrao_de_Volatilidade_dos_Principais_Indices_Financeiros_do_Bovespa_uma_Aplicacao_de_Modelos_ARCH
- Jorion, P. (2010). *Value at risk: a nova fonte de referência para a gestão do risco financeiro*. Tradução Thierry Barbe. São Paulo: BM&FBOVESPA.
- Kane, E. (1989). *The S&L Insurance Mess: How Did It Happen?* Urban Institute Press.
- Kimura, H.; Suen, A.; Perera, L.; & Basso, L. (2009) *Value-at-risk – Como entender e calcular o risco pelo VaR: uma contribuição para a gestão no Brasil*. Editora Atlas.
- Medeiros, L. (2012). *Análise quantitativa da volatilidade dos índices setoriais da Bovespa através de modelos GARCH univariados*. [Trabalho de conclusão do Curso, Universidade Federal do Rio Grande do Sul]. <http://hdl.handle.net/10183/56103>
- Monte, E. (2019). Inter-relações entre os índices financeiros setoriais da Bolsa de Valores de São Paulo e o índice Ibovespa. *Economia Ensaios*, 33 (2), 250-279. <https://dx.doi.org/10.14393/REE-v33n2a2019-40031>
- Morales, H.; & Sartoris Neto, A. (2010, 12 a 15 de outubro). *Distribuição de Probabilidade e Value-At-Risk (VaR) Paramétrico: examinando a suposição de normalidade para grandes carteiras e ativos individuais num contexto de estabilidade econômica*. XXX Encontro Nacional de Engenharia de Produção. São Paulo.
- Morettin, P. (2011). *Econometria Financeira – Um Curso em Séries Temporais Financeiras*. Editora Blucher.
- Pessoa, F. (2013). *Gestão de Risco Setorial no Mercado de Ações Brasileiro*. [Dissertação de Mestrado, Universidade Federal do Ceará]. https://repositorio.ufc.br/bitstream/riufc/9481/1/2013_dissert_fsopessoa.pdf

- Ramos, M. (2003). A volatilidade do mercado e a instabilidade das correlações entre ações. [Dissertação de Mestrado. Pontifícia Universidade Católica do Rio de Janeiro]. http://www.maxwell.lambda.ele.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=4440@1.
- Sobreira, R., & Martins, N. (2011). Os acordos de Basileia e bancos de desenvolvimento no Brasil: uma avaliação do BNDES e do BNB. *Revista de Administração Pública*, 45 (2), 349 – 376. <http://web.bndes.gov.br/bib/jspui/handle/1408/22384>
- Reinhart, C., & Rogoff, K. (2009). The Aftermath of Financial Crises. *American Economic Review*, 99 (2), 466-472. <https://dx.doi.org/10.1257/aer.99.2.466>
- Reinhart, C., & Rogoff, K. (2011). *This Time Is Different: Eight Centuries of Financial Folly*. Princeton University Press.
- Rochet, J., & Tirole J. (1996). Interbank Lending and Systemic Risk. *Journal of Money, Credit and Banking*, 28 (4), 733-762. <https://dxdoi.org/10.2307/2077918>
- Silva, W., Tardelli, M., Rocha, D., & Maia, M. (2010). Aplicação da métrica *Value at Risk* a índices de bolsas de valores de países latino-americanos: um estudo utilizando os modelos de previsão de volatilidade EWMA, EQMA e GARCH. *Perspectiva, Erechim*. 34 (126), 19-32. https://www.uricer.edu.br/site/pdfs/perspectiva/126_94.pdf
- Souza Sobrinho, N. (2001). Extração da Volatilidade do Ibovespa. *Resenha BM&F*, (144), 17-39. <https://mpr.ub.uni-muenchen.de/id/eprint/15571>
- Taylor, J. (2009). The Financial Crisis and the Policy Responses: An Empirical Analysis of What Went Wrong. *NBER working Paper* 14631. <https://dx.doi.org/10.3386/w14631>
- Tribunal de Contas da União. (2022). Dívida Pública. Disponível em: <https://sites.tcu.gov.br/contas-do-presidente/02-divida-publica.html#:~:text=A%20D%C3%ADvida%20Bruta%20do%20Governo,mensurado%20como%20percentual%20do%20PIB>.
- Torres, A., Silva, A., & Cosenza, H. (2008). Modelagens do VAR no Contexto Brasileiro: O Problema da Sensibilidade à Definição de Parâmetros. *Revista Brasileira de Risco e Seguro*, 4 (7), 65-86. <https://www.rbrs.com.br/arquivos/RBRS7-4%20Adriana%20Cazelgrandi.pdf>