



**UNIVERSIDADE DE BRASÍLIA (UnB)**  
**FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE (FACE)**  
**DEPARTAMENTO DE CIÊNCIAS CONTÁBEIS E ATUARIAIS (CCA)**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CONTÁBEIS (PPGCONT)**

DAVI FANTINO DA SILVA

**COMPARATIVO DO PODER PREDITIVO DE MODELOS VAR EM MERCADOS  
DESENVOLVIDOS E EMERGENTES: GESTÃO DO RISCO E CLUSTERS DE  
VOLATILIDADE**

BRASÍLIA – DF

2018



**UNIVERSIDADE DE BRASÍLIA (UnB)**  
**FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE (FACE)**  
**DEPARTAMENTO DE CIÊNCIAS CONTÁBEIS E ATUARIAIS (CCA)**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CONTÁBEIS (PPGCONT)**

DAVI FANTINO DA SILVA

COMPARATIVO DO PODER PREDITIVO DE MODELOS VAR EM MERCADOS  
DESENVOLVIDOS E EMERGENTES: GESTÃO DO RISCO E CLUSTERS DE  
VOLATILIDADE

Dissertação apresentada como requisito parcial de avaliação para a conclusão do mestrado em Ciências Contábeis e Mercado Financeiro.

Linha de pesquisa: Contabilidade e Mercado Financeiro

Orientador:  
Prof. Dr. Bruno Vinícius Ramos  
Fernandes.

Brasília, DF  
2018

## Ficha Catalográfica

Silva, Davi Fantino

COMPARATIVO DO PODER PREDITIVO DE MODELOS VAR EM MERCADOS DESENVOLVIDOS E EMERGENTES: GESTÃO DO RISCO E CLUSTERS DE VOLATILIDADE

/ Davi Fantino da Silva – Brasília 2018.

100f

Orientador: Prof. Dr. Bruno Vinícius Ramos Fernandes

Dissertação (mestrado) – Universidade de Brasília, Faculdade de Economia, Administração e Ciências Contábeis e Atuariais – FACE. Programa de Pós-Graduação em Ciências Contábeis, Brasília, 2018.

Bibliografia.

DAVI FANTINO DA SILVA

COMPARATIVO DO PODER PREDITIVO DE MODELOS VAR EM MERCADOS  
DESENVOLVIDOS E EMERGENTES: GESTÃO DO RISCO E CLUSTERS DE  
VOLATILIDADE

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Ciências Contábeis do Programa de Pós-Graduação em Ciências Contábeis da Universidade de Brasília.

Data da aprovação: \_\_\_/\_\_\_/\_\_\_\_\_

BANCA EXAMINADORA:

---

Prof. Dr. Bruno Vinícius Ramos Fernandes  
Orientador – UnB

---

Prof. Dr. José Alves Dantas  
UnB

---

Prof. Dr. Pedro Henrique Melo Albuquerque  
UnB

Brasília, DF

**Universidade de Brasília (UnB)**

**Reitora:**

Márcia Abrahão Moura

**Vice-reitor:**

Enrique Huelva

**Decano de Pesquisa e Pós Graduação:**

Helena Eri Shimizu

**Diretor da Faculdade de Economia, Administração e Contabilidade:**

Eduardo Tadeu Vieira

**Chefe de Departamento de Ciências Contábeis e Atuariais:**

José Antônio de França

**Coordenador de Pós-Graduação em Ciências Contábeis**

Professor Doutor Cesar Augusto Tibúrcio da Silva

## AGRADECIMENTOS

Ao Professor Bruno Vinícius Fernandes pela paciência, horas desprendidas em orientação e atenção dada na avaliação. Não apenas pela ajuda técnica professor-aluno, mas também pela ajuda humana nos momentos difíceis, os conselhos e *feedbacks* ofertados, os quais me ajudaram nessa caminhada. Ainda vale menção a toda representação em minha causa que foi feita durante as diversas situações não convencionais de meu curso, tais como o apoio no Mestrado sanduíche na Alemanha e o estudo de Métodos Quantitativos na Espanha.

Agradeço ao departamento de PPGCont pelo tratamento diferenciado e tolerância com meus erros e escolhas equivocadas. Seguramente não teria chegado a esse ponto sem a compreensão e confiança depositadas em mim, seja dos membros do conselho do departamento, seja do orientador, seja do coordenador. Em especial agradeço a Inês, pelo atendimento sempre simpático, as informações sempre precisas e, principalmente, pelos conselhos ofertados e ajuda nos momentos sensíveis e finais do curso.

Agradeço as lideranças do Banco do Brasil (COGER) por permitirem ausentarme durante o período de meu Mestrado. Em especial agradeço a Eslei, por incentivar-me a iniciar essa pós graduação e a buscar aprimoramento constante na área contábil.

Por fim, agradeço a minha família pela paciência e apoio. Em especial agradeço à minha mãe, Esa Carolina, por ajudar-me sempre que precisei, independente do problema apresentado, seja com conselhos ou com atitudes. E claro, a *mi novia* Elisabeth Puertas, que esteve comigo em toda etapa dos estudos na Espanha, ajudando-me em tudo necessário e motivando-me. Seguramente que sem vocês eu não teria terminado este trabalho.

## RESUMO

Definir métodos confiáveis de predição de oscilações dos retornos dos ativos se apresenta como um desafio, ainda mais quando se trata de predição de eventos extremos. Estudou-se 5 métodos de cálculo do *Value-at-risk (VaR)* e comparou-os de modo a definir a acurácia destes frente a volatilidade de algumas das principais bolsas de valores no mundo. Os métodos foram o *Monte Carlo Simulation with Jump Diffusion (MCS-JD)*, o *Valued Weighted Moving Average (VWHS)*, o *Extreme Value Theory with Generalized Pareto distribution (EVT-GPD)*, o *Extreme Value Theory Integrated Generalized autoregressive conditional heteroscedasticity (EVT-IGARCH)* e o *Liquid-VaR.(L-VaR)*. Os modelos foram escolhidos por já terem sido testados em circunstâncias diferentes por outros estudos e apresentado bons resultados preditivos. Os modelos ainda necessitam ser testados entre si, utilizando-se dos mesmos parâmetros e possibilitando a comparação entre eles. A amostra inclui países desenvolvidos – Alemanha, Canadá, Estados Unidos, Inglaterra – e emergentes – Brasil, China e Índia –, e analisou-se o desempenho dos modelos para prever oscilações dos retornos, assim como oscilações extremas dos retornos, representado pelos clusters de volatilidades. Os resultados foram avaliados conforme um *backtesting* baseado nos índices de violações, na volatilidade e na análise dos gráficos. Os resultados apontaram a dominância dos modelos MCS-JD para previsões de retornos em momentos de baixa volatilidade, enquanto o VWHS foi unânime na aderência às volatilidades da amostra, em todos os mercados apontados. Outros modelos também foram aprovados nos *backtestings* propostos, confirmando sua confiabilidade preditiva.

**Palavras-chave:** Value-at-risk. *Clusters* de volatilidade. *Extreme value theory*.

## ABSTRACT

*Define reliable prediction methods of the assets returns is presented as a challenge, more so when it focus on the prediction of extreme events. This study used five different methods of Value at risk (VaR) and made a comparison between them to evaluate their accuracy based on the volatility of the stock exchange chambers of some of the most important countries in the world. The methods were Monte Carlo Simulation with Jump Diffusion (MCS-JD), Valued Weighted Moving Average (VWHS), Extreme Value Theory with Generalized Pareto distribution (EVT-GPD), Extreme Value Theory Integrated Generalized autoregressive conditional heteroscedasticity (EVT-IGARCH) and Liquid-VaR.(L-VaR). The methods selected showed good prediction power on other researches, which motivated their choice. These methods needed to be tested on similar conditions, using the same parameters and allowing comparison. The sample included developed countries – Germany, Canada, United States and England – and emerging countries – Brazil, China and India –, and the research analyzed the performance of the models in predicting changes in the returns, and also extreme events, represented by the volatility clusters. The results were evaluated through a backtesting based on a violation ratio, on volatility and in graphic analysis. The results pointed to the dominance of the MCS-JD for predictions in moments with low volatility, while the VWHS model was unanimous in following the volatility changes in the sample, in all countries. Other models were also approved by the backtestings proposed, which confirms their prediction reliability.*

**Keywords:** Value-at-risk. Volatility Clusters. Extreme value theory.



## Lista de Abreviaturas

|            |  |
|------------|--|
| HS         | <i>Historical Simulation</i>   |
| BDSS       | <i>Bangia, Diebold, Schuermann e Stroughair</i>  |
| VWHS       | <i>Volatility Weighted Historical Simulation</i>   |
| MCS-JD     | <i>Monte Carlo Simulation with Jump Diffusion</i>  |
| MCS        | <i>Monte Carlo Simulation</i>  |
| L-VAR      | <i>Liquid Value at Risk</i>  |
| VaR        | <i>Value at Risk</i>   |
| ES         | <i>Expected Shortfall</i>  |
| EVT        | <i>Extreme Value Theory</i>  |
| EWMA       | <i>Equally Weighted Moving Average</i>   |
| GARCH      | <i>Generalized autoregressive conditional heteroscedasticity</i>                                 |
| IGARCH     | <i>Integrated Generalized autoregressive conditional heteroscedasticity</i>                      |
| EVT-GPD    | <i>Extreme Value Theory Generalized Pareto distribution</i>                                      |
| EVT-IGARCH | <i>Extreme Value Theory Integrated Generalized autoregressive conditional heteroscedasticity</i> |
| VR         | <i>Violation Ratio</i>   |

## Lista de Tabelas

|  |    |
|--|----|
| Tabela 1: Países componentes da amostra.....                               | 35 |
| Tabela 2: Estatística descritiva dos retornos.....                         | 49 |
| Tabela 3: <i>Ranking</i> modelos Alemanha e <i>Backtesting</i> .....       | 49 |
| Tabela 4: <i>Ranking</i> Modelos Alemanha.....                             | 51 |
| Tabela 5: <i>Ranking</i> modelos Canadá e <i>Backtesting</i> .....         | 53 |
| Tabela 6: <i>Ranking</i> Modelos Canadá.....                               | 54 |
| Tabela 7: <i>Ranking</i> modelos Estados Unidos e <i>Backtesting</i> ..... | 55 |
| Tabela 8: <i>Ranking</i> Modelos Estados Unidos.....                       | 56 |
| Tabela 9: <i>Ranking</i> modelos Inglaterra e <i>Backtesting</i> .....     | 57 |
| Tabela 10: <i>Ranking</i> Modelos Inglaterra.....                          | 58 |
| Tabela 11: <i>Ranking</i> modelos Brasil e <i>Backtesting</i> .....        | 60 |
| Tabela 12: <i>Ranking</i> Modelos Brasil .....                             | 60 |
| Tabela 13: <i>Ranking</i> modelos China e <i>Backtesting</i> .....         | 61 |
| Tabela 14: <i>Ranking</i> Modelos China.....                               | 62 |
| Tabela 15: <i>Ranking</i> modelos Índia e <i>Backtesting</i> .....         | 63 |
| Tabela 16: <i>Ranking</i> Modelos Índia.....                               | 64 |

# Sumário

|         |  |    |
|---------|--|----|
| 1       | INTRODUÇÃO .....                                   | 13 |
| 1.1     | Problema de Pesquisa.....                          | 15 |
| 1.2     | Objetivos .....                                    | 16 |
| 1.3     | Relevância.....                                    | 17 |
| 2       | REFERENCIAL TEÓRICO .....                          | 18 |
| 2.1     | Risco.....   | 18 |
| 2.2     | Tipos de Risco.....                                | 19 |
| 2.2.1   | Risco Operacional e Risco de Modelo .....          | 19 |
| 2.2.2   | Risco de Crédito e o Risco de Liquidez .....       | 20 |
| 2.2.3   | Risco de Mercado e o Risco Sistêmico .....         | 21 |
| 2.3     | Gestão do Risco e o <i>Value-At-Risk</i> .....     | 22 |
| 2.4     | A Relevância do Método para o Cálculo do VaR.....  | 23 |
| 2.5     | Modelos de VaR e suas Capacidades Preditivas ..... | 25 |
| 2.6     | Risco de liquidez e o modelo VaR.....              | 28 |
| 2.7     | Clusters de Volatilidade.....                      | 30 |
| 2.8     | Hipóteses de Pesquisa.....                         | 30 |
| 3       | METODOLOGIA.....                                   | 32 |
| 3.1     | Dados.....   | 33 |
| 3.2     | Volatilidade.....                                  | 34 |
| 3.3     | <i>Backtesting e análise gráfica</i> .....         | 34 |
| 3.4     | Descrição dos modelos .....                        | 36 |
| 3.4.1   | VWHS.....  | 37 |
| 3.4.2   | MCS-JD.....  | 39 |
| 3.4.3   | Teoria dos Valores Extremos (EVT).....             | 41 |
| 3.4.3.1 | EVT-GPD .....                                      | 42 |
| 3.4.3.2 | EVT-IGARCH.....                                    | 43 |
| 3.4.4   | L-VaR .....  | 43 |
| 4       | ANÁLISE DE RESULTADOS.....                         | 45 |
| 4.1     | Estatísticas descritivas dos dados.....            | 45 |
| 4.2     | Análise de desempenho dos modelos VAR.....         | 47 |
| 4.2.1   | Desempenho nos países desenvolvidos .....          | 48 |
| 4.2.1.1 | Alemanha.....                                      | 48 |
| 4.2.1.2 | Canadá.....  | 50 |

|         |   |    |
|---------|---|----|
| 4.2.1.3 | Estados Unidos.....                       | 52 |
| 4.2.1.4 | Inglaterra.....                           | 53 |
| 4.2.2   | Desempenho nos países emergentes .....    | 55 |
| 4.2.2.1 | Brasil.....                               | 55 |
| 4.2.2.2 | China .....                               | 56 |
| 4.2.2.2 | Índia.....                                | 58 |
| 4.2.3   | Desempenho geral dos modelos .....        | 60 |
| 5       | CONSIDERAÇÕES FINAIS.....                 | 62 |
| 6       | REFERÊNCIAS .....                         | 64 |
| 7       | APÊNDICES.....                            | 70 |
| 7.1     | Gráficos de volatilidade do VAR .....     | 70 |
| 7.1.1   | Alemanha.....                             | 70 |
| 7.1.2   | Brasil.....                               | 74 |
| 7.1.3   | Canadá.....                               | 77 |
| 7.1.4   | China .....                               | 81 |
| 7.1.5   | Estados Unidos.....                       | 84 |
| 7.1.6   | Índia .....                               | 87 |
| 7.1.7   | Inglaterra .....                          | 91 |
| 7.2     | Códigos utilizados na programação R ..... | 94 |

## 1 INTRODUÇÃO

A volatilidade nas bolsas de valores é característica persistente e remonta a diversas situações importantes na análise financeira de um país. As crises financeiras e os *bear markets* são exemplos de situações de grande volatilidade, e a predição desses valores extremos são tema de interesse do mercado. Nesse sentido, torna-se relevante estudar a aplicação dos métodos e ferramentas envolvidas na gestão do risco e predições de volatilidades. O estudo dessas mudanças extremas permite um aprofundamento da avaliação do risco e como os diversos tipos de risco estão interconectados. Essa avaliação do risco interessa a reguladores, supervisores, investidores, tomadores; enfim, a todo mercado (HOANG; FAFF; HAQ, 2014).

Ao se falar em risco, nos referimos aos eventos que podem gerar impactos negativos/positivos. Os eventos de impacto negativo podem impedir a criação de valor ou mesmo destruir o valor existente, e os mesmos podem ser contrabalanceados por eventos positivos. No âmbito financeiro, o risco se refere a propensão de perda/ganho financeiro devido a mudanças não previstas nos fatores de risco (DOWD, 2005).

Sendo assim, diante da existência de mudanças abruptas nos fatores e nas variáveis de risco, é coerente aprimorar e avaliar as formas de medição utilizadas pelos atores do mercado. Almeida, Frascarolli e Cunha (2012) explicam que o *Value-at-Risk* (VaR) se tornou ponto de partida para se apurar o risco de mercado. Jorion (2003) destaca que historicamente o risco era mensurado com ferramentas *ad hoc*, tais como medidas de sensibilidade e análise de cenários, e que embora tais ferramentas fornecessem alguma intuição quanto ao risco, elas falhavam em avaliar a exposição total do portfólio. Como contraponto, o VaR baseia-se no mapeamento dos fatores de risco de um portfólio e que, portanto, o risco pode ser avaliado em uma organização através de uma métrica universal, que se aplica a todas as formas de exposição (ALEXANDER, 2008).

Exposta a relevância do VaR como medida de risco, muitas são as metodologias de cálculo que podem ser aplicadas para obter seu valor. O tratamento que se deseja aplicar aos dados são preponderantes nesse processo, podendo levar a definição de premissas que podem comprometer os resultados. Sendo assim, o estudo de modelos paramétricos, não paramétricos e semi-paramétricos consiste em uma estratégia interessante para dirimir eventuais erros preditivos.

Também é relevante diferenciar o tipo de mercado no qual se aplicam os testes e cálculos de VaR. Mercados emergentes tendem a ser mais voláteis e possuir oscilações históricas mais frequentes que os mercados desenvolvidos, o que pode gerar distorções nos modelo VaR. Estudos sobre crises financeiras e “bolhas”, por exemplo, deflagram a importância de métodos de mensuração confiável, conforme demonstrou Fernandes (2012).

Outro contexto a observar é a relação não apenas do comportamento dos dados econômicos, mas o possível impacto de outros riscos na previsão. Li (2012) esclarece que uma das presunções inerentes do VaR é que o preço de mercado não sofre impactos pelas ações de participantes individuais e que não haveria de ter custos de transação para operações em preço corrente em um intervalo limitado de tempo; presunção errônea. Sendo assim, a incorporação do risco de liquidez também tem ganhado destaque no estudo e análise das metodologias de cálculo do VaR existentes.

Também cabe análise quanto ao poder preditivo que tais medidas de risco têm quando tratamos de eventos raros. A definição de VaR aponta para “a estimação de uma perda máxima, em um horizonte de tempo determinado, no qual há uma baixa e predeterminada probabilidade de que essa perda máxima estimada seja superada” (JORION, 2003, p. 246, tradução livre). Essa definição evidencia a falta de ênfase nas fortes volatilidades, as quais ocorrem com baixa frequência e possuem baixa probabilidade.

Ao se referir a grandes volatilidades, oscilações extremas ou eventos raros, o interesse recai sobre eventos de baixa frequência, mas de alto impacto para o mercado. Para avaliar esses momentos de baixa frequência, deve-se atentar para a cauda (*tail*) da distribuição de probabilidade da variável aleatória de interesse.

Eber *et al* (1999) propõem o uso de uma medida de risco coerente chamada de Expected Shortfall (ES), o qual consiste em avaliar a cauda através de uma média ponderada das probabilidades de perda. Enquanto o VaR é a expectativa de perda caso um evento raro não ocorra, o ES é a expectativa de perda caso esse mesmo evento ocorra (DOWD, 2005). Ressalta-se que embora as duas medidas estejam voltadas para capturar a perda máxima, sua comparação não é possível por se tratarem de métodos distintos.

Uma outra opção para o simples aprimoramento da medida de risco de mercado é complementar a análise de risco através de outras ferramentas como, por exemplo, testes de stress (FERNANDES, 2012). Os testes de stress visam simular um cenário mercadológico em crise e avaliar o grau de exposição do portfólio, e tal abordagem tem ganhado grande atenção da literatura<sup>1</sup>.

Dowd (2005) explica que os testes de *stress* eram vistos como secundários devido sua fragilidade metodológica quando comparada com os métodos de estimação de risco. Mas a crescente literatura envolta no tema reflete a importância que os testes de *stress* adquiriram no mercado, em conformidade com orientações do Comitê de Basileia em seus Princípios para Prática e Supervisão de Testes de *Stress* Seguros (do inglês, *Principles for sound stress testing practices and supervision*).

## 1.1 Problema de Pesquisa

A utilização do VaR como medida de risco é interessante devido a integralização dos fatores de risco e a apresentação de um valor final, o que simplifica a análise (JORION, 2003; ALEXANDER, 2008). No entanto, a facilidade e popularidade do VaR carrega diversos riscos.

Danielsson e Macrae (2011) explicam que as Instituições Financeiras e os Supervisores tendem a superestimar a confiabilidade no VaR e subestimar seus perigos. Esse excesso de confiança na medida pode afetar o julgamento e dificultar a identificação de crises financeiras.

O VaR também possui limitações em seu modelo. Zicovic e Filler (2013) argumentam que a desconfiança em torno do VaR decorre de sua inabilidade de avaliar as perdas em eventos extremos, sendo que tais eventos deveriam ser exatamente o que uma medida de risco deveria apontar. Um erro na estimativa pode gerar uma alocação equivocada do capital, o que mina a confiabilidade e sustentabilidade financeira das instituições (ENGLE; MANGANELLI, 2001).

A premissa de distribuição normal dos retornos dos ativos financeiros é apontada como uma possível causa da fragilidade do VaR pela literatura. Observam-se distribuições com caudas pesadas (*fat tails*), o que tem motivado a aplicação de outras estratégias na mensuração do risco (análise de cenários e testes de *stress*) e

---

<sup>1</sup> Sugere-se os trabalhos de Basu (2011), Düllmann e Kick (2011) e Zayernyuk *et al* (2015).

a aplicação de outras teorias às metodologias (Teoria dos Valores Extremos, por exemplo).

Além da importância de se avaliar o modelo, é importante apurar seu comportamento em diversos tipos de mercado (desenvolvidos e emergentes). A maior volatilidade nos mercados emergentes pode impactar na precisão da medida, hipótese que poderia ser testada com os resultados encontrados nos países desenvolvidos. Se faz pertinente, portanto, a aplicação dos testes em diversos mercados: G7 (grupo dos sete países desenvolvidos: Alemanha, Canadá, Estados Unidos, França, Inglaterra, Itália e Japão) e BRICS (Grupo dos cinco países emergentes: Brasil, Rússia, Índia, China e África do Sul); com a devida divisão da amostra em dois blocos (países desenvolvidos e países emergentes).

Para sanar essa limitação, diversos modelos (paramétricos, não paramétricos e semi-paramétricos) para o VaR tem sido propostos e testados pela literatura. Pode-se citar, como sendo os mais comuns, a Simulação de Monte Carlo, Simulação Histórica, Delta-normal, *Risk Metrics*, dentre outros.

Neste sentido, esta pesquisa propõe-se a responder as seguintes questões:

1. Quais modelos VaR possuem maior acurácia na previsão da volatilidade presente nos retornos dos ativos?
2. Quais modelos VaR possuem maior acurácia na previsão da volatilidade presente nos retornos dos ativos, quando se trata de clusters de volatilidade?
3. Como se comportam modelos VaR quando implementados em diferentes tipos de mercado (emergentes ou desenvolvidos)?

## 1.2 Objetivos

O problema descrito resulta na busca do seguinte objetivo geral:

Verificar a acurácia de diversos modelos VaR na previsão de eventos, extremos e não extremos, e risco de mercado em países emergentes e desenvolvidos.

Portanto, os objetivos específicos são:



- I. Apresentar, por ordem de acurácia, os modelos VaR mais adequados a serem aplicados para prever oscilações financeiras, extremas ou não extremas, em mercados desenvolvidos.
- II. Apresentar, por ordem de acurácia, os modelos VaR mais adequados a serem aplicados para prever oscilações financeiras, extremas ou não extremas, em mercados emergentes.
- III. Apurar possíveis discrepâncias entre os modelos mais robustos, quando aplicados à mercados distintos (desenvolvidos e emergentes)

### 1.3 Relevância

Após a definição do VaR feita pelo Comitê de Basileia (1996) como forma de mensuração do risco de mercado, tal medida passou a ser amplamente utilizada e seus efeitos estudados na academia. No entanto, diversos autores apontam para a fragilidade que tal medida apresenta. Jorion (2003), por exemplo, explica que a simplicidade do VaR pode ser perigosa já que o valor apresentado pode provir de diversas distribuições.

O estudo comparativo do VaR foi trabalhado por pesquisas internacionais (vide, por exemplo, Zicovic e Filler, 2013; Basu, 2011; Vee *et al*, 2014). Esses estudos destacaram alguns dos modelos que aparentemente despontam como mais robustos, a exemplo dos baseados na Teoria dos Valores Extremos (da sigla inglês, *Extreme Value Theory* - EVT). No entanto, alguns métodos ainda carecem de testes em cenários distintos, e comparados uns com os outros em contextos similares.

Os modelos baseados no EVT, por exemplo, possuem estudos que corroboram para sua escolha como abordagem mais adequada no que concerne a predição de crises sistêmicas. Zicovic e Filler (2013), Fernandes (2012), Vee *et al* (2014) são alguns dos autores que comprovam essa afirmação. No entanto, outros modelos como o de Weiß e Supper (2013), o qual se baseia na incorporação do risco de liquidez no cálculo do VaR, ou outros modelos baseados em histórico e simulações como a Simulação Histórica com a Volatilidade Ponderada e a Simulação de Monte Carlo com Difusão (da sigla inglês, *Volatility Weighted Historical Simulation* – VWHS e *Monte Carlo Simulation with Jump Diffusion* – MCS-JD, respectivamente), ambos estudados por Basu (2011), também apresentaram bons resultados.

Se faz necessário organizar tais testes e avaliações baseando-se em mercados distintos: desenvolvidos e emergentes. Weiß e Supper (2013) e Basu (2011), por exemplo, apenas aplicaram suas pesquisas em mercados desenvolvidos. Zicovic e Filler (2013) alertam para o risco de se presumir que apenas mercados emergentes carecem de modelos de VaR mais robustos:

Reguladores e investidores devem mudar sua errônea percepção de que a maior volatilidade e menor grau de desenvolvimento dos mercados emergentes os levam a precisar de uma mensuração de risco mais robusta, enquanto os mercados “tranquilos” e “comportados” dos países desenvolvidos estão seguros apenas com o modelo VaR. Um grande período de prosperidade e tranquilidade é exatamente o porquê do modelo VaR ter baixo desempenho. A estabilidade leva a resultados enganosos dos modelos VaR nos mercados desenvolvidos já que, diferentemente dos mercados emergentes, eles carecem de fortes volatilidades e crises por períodos mais longos. A falta de informações fornecidas por essas volatilidades e crises resultam na estimação de parâmetros completamente inadequados.

(ZICOVIC e FILLER, 2013, tradução livre)

Diante da existência de mudanças abruptas nos fatores e nas variáveis de risco é coerente avaliar as formas de medição utilizadas pelos diversos atores do mercado (reguladores, supervisores, investidores, tomadores). Também destaca-se que o estudo do risco carece de unificação. Alexander (2008) cita que o catalizador da crise de 2008 resultou da instabilidade bancária, a qual proveio da falta de princípios contábeis, regulatórios e de gestão de risco integrados e inteligentes. Sua afirmação tem como base o fato de que cada uma dessas disciplinas evoluiu separadamente, cada qual com seu framework próprio, sem uma adequada preocupação com as outras duas disciplinas.

Tendo em vista a importância dada ao VaR pelo sistema regulatório contemporâneo e o impacto que volatilidades extremas podem ter, deve-se ter grande atenção a forma como o VaR é obtido. Analisar e comparar medidas alternativas de cálculo do VaR é relevante na medida que pode-se pontuar a real capacidade de se prever oscilações extremas e *clusters* de volatilidade.

## 2 REFERENCIAL TEÓRICO

### 2.1 Risco

O estudo do risco tem grande importância para o capitalismo e para a estrutura econômica contemporânea. As organizações buscam não apenas apontar fontes de

risco, mas também quantificar tais fontes, mensurando-as através de métodos e medidas estatísticas e probabilísticas.

Capoletto (2006) destaca que a concepção contemporânea de risco remete à quantificação do risco através de valores, pautado em probabilidade, dados históricos e parâmetros futuros. Aebi, Sabato e Schmid (2012) explicam que o foco da gestão do risco está no aprimoramento da mensuração e na gestão de riscos específicos, tais como risco de crédito, risco de liquidez e risco de mercado.

Embora dotado de diversas definições na área financeira, pode-se entender o risco como a propensão de perda/ganho financeira(o) devido a mudanças não previstas nos fatores de risco (DOWD, Chap. 1, p. 1, 2005). Assaf Neto (2007) esclarece que o risco é uma medida de incerteza para se obter o retorno esperado sobre um determinado investimento. Dubecq (2013) complementa que os reguladores fazem clara distinção entre as formas de riscos, apartando o risco de crédito do risco de mercado e do risco operacional.

Sendo assim, se faz importante diferenciar os principais tipos de risco como o risco operacional, de modelo, de liquidez, de crédito, de mercado e sistêmico.

## 2.2 Tipos de Risco

### 2.2.1 Risco Operacional e Risco de Modelo

O Comitê de Basileia reconheceu a importância do risco operacional e propôs manutenção de capital específica para ele. Embora seja, de fato, sensível as perdas ocasionadas pelas operações, surge a dificuldade de identificar como definir tal risco.

Em uma visão mais estreita, pode-se restringir o risco operacional apenas ao escopo de procedimental. Em uma visão mais ampla, é possível defini-lo como um risco residual após a exclusão do risco de mercado e o de crédito (JORION, 2003). Fernandes (2012) propõe definir tal risco não apenas a falha humana, ou o risco de execução, mas também às perdas potenciais provenientes de sistemas inadequados, má administração ou controles defeituosos. Inclui-se no risco operacional as fraudes e também os riscos tecnológicos, os quais decorrerem da necessidade de proteger os sistemas de possíveis invasões/acessos não autorizados.

O risco de modelo tem recebido recentemente mais atenção da literatura. Dubceq (2013) explica que os modelos financeiros devem ser robustos e coerentes.

Robustos remete à ideia de que as premissas do modelo não são alteradas facilmente devido a mudanças no cenário e coerentes pois os modelos não devem apontar ganhos de arbitragem.

Barrieu e Scandolo (2015) explicam que o risco de modelo ocorre ao se trabalhar com um modelo potencialmente inadequado. Argumenta que modelos de mensuração de risco comumente utilizadas, como o VaR Delta-Normal ou métodos de simulação, baseiam-se no mapeamento/escolha de fatores de risco. E mesmo diante de dados históricos, o pesquisador ainda baseia-se em distribuições empíricas propostas pelos modelos, o que exacerba a presença de um risco decorrente de tal escolha.

### 2.2.2 Risco de Crédito e o Risco de Liquidez

O risco de crédito está associado a insolvência do devedor (DUBECQ, 2013), e está atrelado ao cumprimento de obrigações contratuais, e reflete a perda econômica por essa falha. Jorion (2003) explica que o efeito do risco de crédito é medido pelo custo de substituir os fluxos de caixa que deveriam ser recebidos.

A falta de pagamento pode decorrer de uma transação em andamento (*presettlement risk*) ou de uma obrigação futura (*settlement risk*). No primeiro, o devedor pode vir a falhar com suas obrigações durante o tempo de vida de uma operação enquanto o *settlement risk* refere-se a troca de fluxos de caixa.

A importância de se atentar para o risco de crédito é apontado por Bonti *et al* (2006). Os autores explicam que a grande concentração de operações de crédito no portfólio de um banco eleva o risco de crédito, gerando uma necessidade de se manter capital para suprir um eventual problema muito maior do que o necessário para outras categorias de risco.

O risco de liquidez ganhou mais atenção da literatura por ser apontada como precursora da crise imobiliária estadunidense de 2008 (BRUNNERMEIER, 2009; CORNETT; *et al*, 2011). Tal risco está associado ao descasamento entre o vencimento dos passivos em contraposição ao dos ativos, seja por má administração, seja por inadimplência (FERNANDES, 2012).

A falta de liquidez se torna mais perigosa no que concerne os bancos, tendo em vista seu papel de intermediador financeiro. Diamond e Dybvig (1983) explicam que a existência de assimetria da informação permite aos bancos a criação de

liquidez. Isso ocorre pois os poupadores ofertam seu capital a segurança do banco, que oferta tais valores aos tomadores que, também, mantém parte de suas economias aos cuidados da instituição. Essa mecânica permite que o banco oferte mais dinheiro do que de fato possui, já que atua como repositório de valores, tanto para tomadores como para poupadores.

A assimetria da informação atua na crença dos poupadores de que seus valores possuem liquidez imediata. Calvo (2012) explica que enquanto tal equilíbrio for mantido, o sistema financeiro permanece seguro contra “corridas aos bancos” em busca de resgates, uma possível causa de crises decorrentes de falta de liquidez bancária.

O risco de liquidez apresenta ligação direta com o risco de crédito e o risco de mercado. O Comitê de Basiléia sobre Supervisão Bancária (2009) destaca tal ligação, explicando que a liquidez está diretamente conectada ao risco de mercado e de crédito no horizonte sobre o qual os ativos podem ser liquidados. Informação relevante na medida que os gerentes de risco são pressionados a mensurar o risco (através do VaR, por exemplo) utilizando-se de períodos mais longos (BRIGO; NORDIO, 2010 apud GLAU; SCHERER; ZAGST, 2013).

### 2.2.3 Risco de Mercado e o Risco Sistemico

O risco de mercado atenta-se para as variáveis mercadológicas. Jorion (2003) explica que ao mensurar tal risco busca-se quantificar a perda devido a movimentos nas variáveis financeiras do mercado. Dubecq (2013) destaca que o risco decorre da perda devido a flutuações nos preços de mercado referentes a posições da instituição, contábeis ou não. Sendo assim, os riscos de mercado abrangem diversas áreas do mercado financeiro, com destaque ao mercado de ações, ao câmbio, aos juros e a *commodities*.

Fernandes (2012) explica que o risco de mercado abrange os riscos de base e o risco gama. O primeiro remete ao risco decorrente da ineficiência do mercado futuro de refletir os preços do mercado a vista, gerando a possibilidade de ganhos através

de arbitragem<sup>2</sup>; já o risco gama é uma medida de sensibilidade da volatilidade dos preços<sup>3</sup>.

No que tange o risco sistêmico ou crise sistêmica, um cenário nessa situação constitui o que popularmente é chamado de “crise financeira”. Oet, Dooley e Ong (2015) explicam que os conceitos de crise sistêmica e risco sistêmico sempre foram considerados sinônimos, levando a uma medida binária: cenário em crise ou sem crise. Os autores complementam que atualmente, a crise sistêmica é apontada através da apuração da falta de capital ou eventos com propagação nas instituições. Essa definição é coerente com Caprio e Klingebiel (1996), Demirguç e Detragiache (1998) e De Bandt e Hartmann (2000).

Sendo assim, o risco sistêmico é aquele decorrente de eventos que propagam instabilidade financeira ao ponto de impactar de forma generalizada o sistema financeiro inviabilizando o crescimento econômico e sua prosperidade (DUCA e PELTONEN, 2013). Evidencia do impacto de tal risco e seus efeitos adversos podem ser observados na crise imobiliária estadunidense de 2008 (HAKWA, JAGER-AMBROZEWICZ e RUDIGER, 2012).

### 2.3 Gestão do Risco e o *Value-At-Risk*

Ao se referir a gestão do risco, o maior alvo recai sobre os bancos. Rodrigues-Moreno e Pena (2013) destacam a importância que os bancos tem para o sistema financeiro e reiteram que o risco sistêmico surge quando um mal funcionamento geral ocorre nesse sistema. Listam algumas das causas, como as expansões excessivas de crédito no setor público ou privado, as bolhas financeiras, os contágios, a falência de bancos demasiadamente grandes e a quebra nas comunicações gerando paralizações no mercado interbancário.

A importância das entidades bancárias para a estabilidade do sistema financeiro levou ao desenvolvimento de ferramentas que possibilitassem aglomerar os fatores de risco e mensurá-los. Dowd (2005) esclarece que a mensuração do risco busca quantificar a possibilidade de ganho ou perda devido a mudanças não previstas nos fatores de risco. Diversos métodos e modelos foram desenvolvidos e utilizados

---

<sup>2</sup> Sugere-se a leitura de Gorton *et al* (2012), Chang (2012) e Lucas (2009) que estudaram o risco de base presente no mercado futuro e na negociação de diversas *commodities*.

<sup>3</sup> Para aprofundamento do cálculo e uso do risco gama, sugere-se Alexander (2008).

no meio corporativo no sentido de apurar esse risco, tais como: *Gap Analysis*, *Duration Analysis*, *Scenario Analysis*. Tais estudos culminaram no desenvolvimento do *Value-at-Risk*, ainda na década de 70.

Difundida no início dos anos 90 e adotado como forma de medida pelo Comitê de Basileia<sup>4</sup>, o VaR se consolidou como principal método de mensuração do risco (ALMEIDA; FRASCAROLLI; CUNHA, 2012). Jorion (2003) destaca que historicamente o risco era mensurado com ferramentas *ad hoc* tais como medidas de sensibilidade e análise de cenários, e que embora essas ferramentas fornecessem alguma intuição quanto ao risco, falhavam em avaliar a exposição total do portfólio.

O VaR baseia-se no mapeamento dos fatores de risco de um portfólio e, portanto, o risco pode ser avaliado em uma organização através de uma métrica universal que se aplica a todas as formas de exposição (ALEXANDER, 2008). O VaR se apresenta como diferenciado na medida que apresenta um valor de exposição, o que seria o valor em risco, baseado em uma abordagem estatística. É possível, portanto, integralizar diversos tipos de risco tais como o risco de crédito e o risco de liquidez, ao risco de mercado, gerando uma medida única de risco.

Alexander (2008) explica que o mapeamento dos fatores de risco é interessante, pois normalmente os portfólios são muito grandes para se avaliar o risco individual de cada item na carteira. O uso dessa estratégia torna possível a mensuração do risco.

## 2.4 A Relevância do Método para o Cálculo do VaR

Ao calcular o VaR, os modelos fazem uso de dados históricos ou hipotéticos, e podem se basear em diversas presunções acerca do mercado. Essas presunções desencadeiam a escolha de modelos específicos, os quais possuem grande sensibilidade a erros e premissas imprecisas. Levam consigo um risco inerente, decorrente da possibilidade de inadequação dos modelos, da conclusão quanto ao comportamento dos dados e suas distribuições, quanto à aplicação das premissas econométricas previamente definidas, e outras escolhas referentes às medidas de

---

<sup>4</sup> O acordo de Basileia foi assinado em 1988 pelos bancos centrais de diversos países (Bélgica, Canadá, França, Alemanha, Itália, Japão, Holanda, Suécia, Estados Unidos, Grã-Bretanha) e estabelecia valor mínimo de capital próprio, ponderados pelo grau de risco incorrido.

risco financeiro. A utilização de um modelo inadequado é conhecida como risco de modelo.

A aplicação de um determinado modelo de apuração do risco deve considerar diversos fatores para comprovação de confiança no resultado. A literatura têm estudado e enfatizado três abordagens mais comumente para se avaliar a apuração do risco. A primeira abordagem dos pesquisadores tenta avaliar o risco que a escolha do modelo acarreta em si (risco de modelo), e busca auxiliar a escolha prévia deste modelo. A segunda abordagem de estudo se pauta na adequação estatística dos modelos, comparando os diversos métodos disponíveis para se calcular a medida de risco e averiguando qual o mais robusto. Uma terceira enfatiza modelos que permitem testar os resultados dos modelos (*back testing*), e apontar a capacidade preditiva deles.

Representantes da primeira abordagem, Barriou e Scandolo (2015) destacam que o resultado final de uma análise de risco possui valores diversificados dependendo do modelo adotado. Fazem menção a crise financeira estadunidense de 2008, e ressaltam a importância de se reavaliar os modelos utilizados pelos reguladores para apurar os requisitos de capital mínimos das instituições financeiras. Já Boucher *et al* (2014) propõe um *framework* para corrigir uma possível imperfeição no cálculo de medidas de risco (como por exemplo, o VaR) através da análise do risco de modelo.

Já Zicovic e Filler (2013) e Fernandes (2012), enquadrados no segundo grupo, testam diversos modelos VaR e comparam seus poderes preditivos através de um determinado *backtest*. Enquanto Ziggel *et al* (2014), adepto da terceira abordagem, enfatiza a forma como o *backtest* é aplicado e o quão adequado o mesmo é na comparação de modelos.

Também é importante diferenciar a análise do risco de modelo da análise do quanto um determinado modelo é robusto. No primeiro caso, busca-se encontrar um número que possa refletir a probabilidade de o modelo estar erroneamente definido. Já a análise de robustez do modelo tem o intuito de apontar estatisticamente a acurácia daquele modelo.

As três abordagens citadas se complementam e fica claro a sinergia existente entre os três grupos. Não obstante, o trabalho atual se relaciona com a segunda abordagem, no qual tenta-se definir o modelo mais preciso dentre diversos disponíveis



para apuração do VaR. O modelo será testado por um *backtest* baseado em um índice de violação, o qual será explicado adiante no trabalho. A análise da robustez do *backtest* em si será deixada para futuros estudos.

A seguir, serão demonstrados os modelos de VaR utilizados nesta pesquisa e suas características específicas, tais como: conceituação teórica, formulação matemática e aplicação empírica.

## 2.5 Modelos de VaR e suas Capacidades Preditivas

A existência de uma grande variedade de modelos para o cálculo do VaR suscitaram alguns estudos comparativos. Basu (2011) calculou o VaR e o ES com seis metodologias diferentes<sup>5</sup> e aplicou cenários em *stress* para avaliar os modelos. Seu estudo buscou apurar qual modelo poderia prever mais precisamente picos de volatilidade (*volatility clustering*) e quebras de correlação (*correlation breakdown*). O *stress* foi feito no mercado cambial, com a utilização do euro e dólar frente a moeda local indiana, em três patamares percentuais distintos (5, 10 e 15%).

Neste estudo, Basu (2011) concluiu que o VWHS (da sigla inglês, *Volatility Weighted Historical Simulation* – VWHS daqui em diante) é mais eficiente para capturar os *clusters de volatilidade do ativo financeiro ao longo do tempo*. Argumenta que tal modelo combina caudas pesadas com a presença de picos de volatilidade em ambientes voláteis (estressados) nessas caudas. No VWHS, presume-se que choques históricos ou simulados podem ocorrer no futuro, sendo assim, a ponderação da cauda torna esse modelo mais preciso.

Já o MCS-JD (da sigla inglês, *Monte Carlo Simulation with Jump Diffusion* – MCS-JD daqui em diante), respectivamente apresentou melhores previsões para a repartição de correlação (*correlation breakdown*). Basu (2011) avalia que os ativos em um portfólio passam a apresentar redução em sua correlação a medida que o cenário se torna mais volátil, reduzindo os benefícios da diversificação. O modelo MCS-JD baseia-se em uma distribuição Gaussiana, a qual é mais sensível a picos de volatilidade, gerando perdas maiores a medida que o cenário econômico declina. Tal

---

<sup>5</sup> Simulação histórica (HS), Simulação de Monte Carlo (MCS), Simulação histórica com a volatilidade ponderada (VWHS), Simulação histórica híbrida (Hybrid HS), Simulação de Monte Carlo com Difusão (MCS-JD) e Teoria dos valores extremos não condicional (EVT-HS).

característica gera grande impacto nos retornos dos portfólios, o que comprova a diminuição dos benefícios da diversificação.

Zicovic e Filler (2013) ranquearam diversas metodologias de VaR e ES. Incluíram em sua análise diversos *backtesting* para fazer essa comparação. Seus dados incluíram índices da bolsa de valores de oito países, desenvolvidos e emergentes. Os autores identificaram uma melhor capacidade preditiva dos modelos EVT, tanto para o VaR quanto para o ES. Destaca-se que os autores testaram tanto o EVT não condicional (estático) proposto por McNeil (1997) quanto o condicional (dinâmico), apresentado por McNeil e Frey (2000), sendo que o não condicional apresentou melhor desempenho.

Achados aderentes ao de Zicovic e Filler (2013) são os de Fernandes (2012). O autor testou cinco modelos de VaR e aplicou o *backtest* proposto por Kupiec e adotado pelo Comitê de Basileia (1996) para avaliar o desempenho dos modelos. Seu estudo abrangeu mercados emergentes (BRICS) e desenvolvidos (G7). Seus resultados apontaram para o melhor desempenho do modelo EVT. No entanto, os modelos testados foram modelos mais simples, diferentes dos propostos no presente estudo.

Outros exemplos da capacidade do EVT foram ofertadas por Totic *et al* (2011). Os autores compararam também cinco modelos VaR e novamente concluíram quanto ao melhor desempenho do EVT condicional.

O EVT dinâmico, conforme apresentado por McNeil e Frey (2000), recebeu especial atenção da literatura. Pode-se citar Vee *et al* (2014) que calculou o VaR utilizando o EVT juntamente com três modelos GARCH (da sigla inglês, *Generalized autoregressive conditional heteroscedasticity*), proposto por Bollerslev (1986), no intuito de descrever a volatilidade do ativo financeiro analisado. Seu estudo abrangeu mercados de fronteira e incluiu os IGARCH ou GARCH Integrado, o GJR-GARCH e o GARCH estático convencional (NORMAL-GARCH). Seus resultados apontam para uma melhor adequação do IGARCH, o qual teve bom desempenho na amostra empregada.

De modo similar Salado *et al* (2010) investigaram o poder preditivo do modelo EVT dinâmico, aplicando três metodologias distintas: GARCH, GJR-GARCH e o GARCH exponencial (da sigla inglês, *Exponential generalized autoregressive*

*conditional heteroscedasticity* – EGARCH). Sua amostra abrangeu dados da bolsa do México durante a crise do subprime de 2008.

Houve também propostas de aplicações diferenciadas do EVT. Kabundi e Muteba (2011) calcularam o VaR dos valores extremos generalizados (da sigla inglês, *Generalized extreme values* – GEV) através da abordagem “bloco máximo” (*Blocks Maxima*), em contraponto ao utilizado em Fernandes (2012), Zicovic e Filler (2013) e Vee *et al* (2014) que aplicaram o “excesso sobre o limiar” (da sigla em inglês, *Peaks-over-thresholds* – POT) o qual leva a distribuição generalizada de Pareto (da sigla inglês, *Generalized Pareto distribution* – GPD). Aplicaram seu modelo a diversos países desenvolvidos e na África do Sul, além de testarem também o câmbio rand-dólar e concluíram quanto a maior capacidade dos modelos EVT frente a modelos tradicionais de variância-covariância.

Bali (2007) testou os modelos EVT baseados em GPD e em uma distribuição GEV mais genérica utilizando a transformação Box-Cox (1964), tanto para modelos condicionais como para não condicionais. Usou NORMAL-GARCH e o GJR-GARCH para calcular os limites (*thresholds*) para os EVT condicionais. Os EVT estáticos partiram da premissa de uma distribuição normal e uma *assimétrica t*. Seus resultados apontam para um fraco desempenho das não condicionais, e destaca a superioridade do uso do Box-Cox GEV frente o GPD.

Aparte do EVT e de sua comprovada capacidade de apontar predições mais adequadas para crises financeiras, outras abordagens e metodologias tem sido propostas. Bangia *et al* (1999) incorporaram a liquidez no cálculo do risco de mercado através do VaR, assim como Berkowitz (2002) e Qi e Ng (2009). Seu modelo teve bons resultados para *bid-ask spreads*<sup>6</sup> e retornos intradiários (*intraday returns*<sup>7</sup>).

Outros autores aprimoraram ou adaptaram os modelos baseados em liquidez, e também obtiveram bons resultados. Weiß e Supper (2013), Li (2012) e Heude e Wynedaele (2001) são alguns exemplos.

A literatura também buscou apurar o comportamento dos modelos VaR diante do estudo de variáveis externas. Dias (2013) comparou diversos modelos, condicionais e não condicionais, e os efeitos de suas habilidades preditivas diante do

---

<sup>6</sup> Os *bid-ask spreads* referem-se a diferença entre o menor valor que o vendedor deseja vender seu ativo e o maior valor que o comprador está disposto a pagar pelo mesmo ativo.

<sup>7</sup> Os retornos intradiários são os retornos gerados por um ativo no decorrer das horas regulares de negociação diária.

valor de mercado (*market capitalization*) do portfólio. O autor concluiu quanto a influência do *market capitalization*, resultado também apontado por Halbleib and Pohlmeier (2012).

Bellini (2013) propôs um modelo estatístico para integralizar mais riscos além do risco de liquidez. Argumenta que a mensuração do risco é feita de forma modular, mas que a soma desses riscos calculados independentemente pode ser menor que o risco do portfólio. Sendo assim, se faz pertinente incluir outros riscos na mensuração do risco como, por exemplo, através do VaR.

No Brasil algumas pesquisas enfatizam comparações entre modelos VaR e análises dos modelos mais consistentes. Fernandes (2012) foi o precursor do estudo no país, aplicando os comparativos previamente citados, enquanto Ferreira (2013) estudou modelos alternativos para cálculo dos testes de adequação (*backtests*) dos ES.

Mais recentemente, Pinheiro (2017) comparou a aplicação de modelos VaR tais como o HS e o MCS, a diferentes classes de ativos como o dólar e o Ibovespa. Seus resultados apontaram melhores previsões para o GARCH, além de questionar o tamanho da janela de estimação, levantando a hipótese de que janelas menores podem apresentar resultados e estimativas melhores.

## 2.6 Risco de liquidez e o modelo VaR

A importância do risco de liquidez e sua incorporação ao cálculo do VaR decorre de uma tendência do mercado. Essa tendência é reflexo da preferência que investidores e gerenciadores de portfólio têm por posições mais líquidas, permitindo a saída de suas posições rapidamente, sem aumentos significativos dos custos de transação (WEIß; SUPPER, 2013).

Essa preferência por liquidez se inter-relaciona com as crises financeiras na medida que uma das funções do sistema bancário é o de prover liquidez imediata. Os tomadores tem acesso a empréstimos enquanto os poupadores podem retirar suas reservas imediatamente, tornando o banco sensível a oscilações na demanda por liquidez o que, em contrapartida, pode desestruturar todo sistema financeiro (CORNETT; *et al*, 2011).

Essa relação pode ser apurada analisando-se a crise imobiliária de 2007-2009 nos EUA. Cornett *et al* (2011) explica que a comercialização de papéis no mercado

americano passou por oscilações na medida que as incertezas em torno do valor e da liquidez dos títulos imobiliários passou a subir. Analisando-se o TED *spread*<sup>8</sup> pode-se notar que o mesmo atingiu picos altíssimos no ano de 2007 e manteve-se alto e volátil por toda a crise.

Pode-se, portanto, dividir o risco de liquidez em dois tipos: o risco de liquidez proveniente do mercado (*market liquidity risk*) ou aquele proveniente dos bancos (*funding liquidity risk*). Aquele proveniente dos bancos decorre do papel intermediador, conforme explicado anteriormente. Já o risco proveniente do mercado é oriundo das posições de grandes investidores que tem capacidade de influenciar o mercado devido suas decisões (LI, 2012). Caso haja um efeito manada em função das decisões dos grandes investidores, o risco de liquidez sobe, o que faz com que os investidores se deparem não apenas com o risco de mercado relativo aos preços dos ativos, mas também a liquidez desse mercado, conforme pontua Li (2012).

Outro ponto relevante concerne ao objetivo no uso do VaR. Tal modelo busca apurar o risco de mercado através da incerteza dos retornos dos ativos, mas ignorando quaisquer riscos de liquidez (BANGIA *et al*, 1999).

Essa correlação entre risco de liquidez e o risco de mercado gerou tentativas de integraliza-los ao VaR. Bangia *et al* (1999) propõem em seu modelo a incorporação dos riscos de liquidez proveniente de componentes exógenos. Argumentam que o levantamento dos dados dos riscos de liquidez exógenos, diferentemente dos endógenos, são bem mais fáceis devido a publicidade destes. Também explicam que tais riscos são caracterizados pela volatilidade dos *spreads* observados, independentemente de suas realizações. Por fim, os autores apresentam resultados no qual a não incorporação do risco de liquidez gera imprecisões na ordem de 25-30%.

O modelo de Bangia *et al* foi batizado de BDSS tendo em vista as iniciais dos autores Bangia, Diebold, Schuermann e Stroughair e foi alterado/aprimorado por outros autores. Weiß e Supper (2013) propuseram introduzir um modelo econométrico baseado em copulas (*vine copulas*), enquanto Li (2012) adaptou o BDSS para aplicação no mercado chinês.

---

<sup>8</sup> TED *spread* é a diferença entre a taxa interbancária de Londres (da sigla em inglês, LIBOR) e a taxa dos títulos públicos (*Treasury rate*), ambos de curto prazo (três meses). TED é um acrônimo formado por "T-bill", o qual se refere aos títulos públicos americanos de curto prazo, e "ED", o símbolo para os contratos futuros *Eurodollar*.

## 2.7 Clusters de Volatilidade

A importância de se estudar a volatilidade de um ativo está conectado à sua relevância ao mercado. Uma predição de tais mudanças determina estratégias de hedge além de captar momentos de grande incerteza ao mercado (ARAÚJO, 2010).

Um exemplo dessas incertezas são as crises financeiras. Esses eventos possuem duas características marcantes: permanência histórica e uma característica cíclica.

Fernandes (2012) esclarece que os ciclos econômicos se apresentam de forma contínua, que as crises financeiras acontecem, se buscam motivos, se aplicam contramedidas, mas com o passar dos anos os mesmos fenômenos voltam a acontecer. A ideia de permanência histórica é apresentada por Amaral (2009) o qual explica que as crises financeiras precedem o capitalismo e que não terminarão mesmo com o fim de tal sistema.

Schumpeter (1968) atrela as crises financeiras capitalistas a oferta de crédito ou, em outras palavras, ao endividamento dos empresários. O grau de atuação do estado frente ao controle do crédito exercido pelas instituições bancárias seria fundamental para o surgimento de uma crise. Mesmo com essa ligação entre o crédito e a crise, Fernandes (2012) deixa claro que o termo “crise financeira” ainda carece de definição, mas que interrupções no fluxo de crédito são um fator chave.

Para exemplificar, a crise imobiliária estadunidense teve seu cenário construído em princípio de 2001, atingindo seu ápice 2007 com o congelamento de fundos com garantias de hipotecas americanas. Os títulos hipotecários sem lastro ficaram conhecidos como títulos *subprime* e levaram os investidores a se perguntarem sobre a real liquidez do mercado (FERNANDES, 2012). A observação e predição de como os ativos oscilam é fundamental para a identificar precocemente o surgimento de uma crise.

## 2.8 Hipóteses de Pesquisa

O presente trabalho se prontifica a testar modelos VaR e apresentar o que tenha melhor nível de acurácia. Divide-se o estudo em dois grandes grupos: países desenvolvidos formados por alguns dos componentes do G7, e países emergentes, composto por alguns dos países dos BRICS.

Presume-se que os países, por estarem categorizados em grupos econômicos os levariam a ter resultados similares uns com os outros. Em outras palavras, um país desenvolvido teria um comportamento similar a outro desenvolvido e, portanto, os modelos de predição mais precisos e com melhor resultados preditores seriam os mesmos dentro de cada grupo.

Essa reflexão leva as primeiras hipóteses de pesquisa:

1. *H1: O modelo definido como melhor preditor, com base no teste de percentual de violação (Violation Ratio) e no teste de nível de volatilidade, será o mesmo em cada um dos países desenvolvidos testados.*
2. *H2: O modelo definido como melhor preditor, com base no teste de percentual de violação (Violation Ratio) e no teste de nível de volatilidade, será o mesmo em cada um dos países emergentes testados.*

Ao atentar-se para a volatilidade, o grupo dos países desenvolvidos e o grupo dos países emergentes teriam resultados diferentes entre si, fruto do histórico de volatilidade da amostra. Zicovic e Filler (2013) argumentam que países desenvolvidos possuem maior estabilidade histórica, gerando resultados piores aos modelos baseados em volatilidade, ao comparar-se os resultados destes com os obtidos em países emergentes. Presume-se que modelos como o VWHS e o EVT-IGARCH, por aplicarem ponderação e darem importância a volatilidade encontrada na amostra, teriam resultados melhores em ambientes mais voláteis (mercados emergentes). Somado a isso, Basu (2011) concluiu que o VWHS é aderente aos clusters de volatilidade superando outros modelos. No caso do EVT-IGARCH, a característica do modelo que enfatiza as caudas da distribuição e aplica modelo de volatilidade da família GARCH, o elenca como candidato a resultados superiores.

Formula-se as hipóteses:

3. *H3: Os modelos com melhor aderência aos clusters de volatilidade, com base na análise gráfica, serão diferentes entre os mercados desenvolvidos e emergentes.*

### 3 METODOLOGIA

Diante de diversos modelos e metodologias, propõe-se testar aqueles que obtiveram resultados robustos, mas que ainda não foram testados entre si. Sendo assim, utilizar-se-á o VWHS e o MCS-JD, ambos testados por Basu (2011); comparar os modelos EVT não condicionais baseados em distribuição de Pareto (GPD), conforme estudado por Fernandes (2012) e Zicovic e Filler (2013); e avaliar modelos EVT condicionais calculados a partir do IGARCH, conforme Vee *et al* (2014).

Além da comparação dos modelos listados, também far-se-á o comparativo desses modelos com o modelo VaR imbuído do risco de liquidez (L-VaR). Bangia *et al* (1999) comprovou a influência que o risco de liquidez tem na capacidade preditiva de modelos VaR. Conclusão corroborada por Heude e Wynendaele (2001), Weiß e Supper (2013) e Li (2012), por exemplo.

A escolha dos modelos EVT não condicionais sofrem diversas críticas. Bali (2007) argumenta que utilizar modelos não condicionais é incoerente na medida que eles desconsideram a autocorrelação e a heteroscedasticidade condicional, presente na maior parte dos dados financeiros. Vee *et al* (2014) corroboram com Bali (2007) e pontuam que os retornos financeiros possuem caudas pesadas e alta volatilidade, algo não capturado por modelos não condicionais. No entanto, embora considerados inadequados a primeiro momento, os resultados apontados pela literatura foram fortes o suficiente para motivar utilizá-los nesse estudo, inclusive quando testados contra modelos condicionais (ZICOVIC; FILLER, 2013).

Lista-se, portanto:

1. Simulação de Monte Carlo com Difusão (MCS-JD), conforme testado por Basu (2011)
2. Simulação Histórica com Volatilidade Ponderada (VWHS), conforme testado por Basu (2011)
3. Modelos EVT não condicional, utilizando-se POT e GPD (EVT-GPD), conforme testado por Fernandes (2012).
4. EVT condicional com IGARCH (EVT-IGARCH), conforme testado por Vee *et al* (2014)
5. VAR imbuído do risco de liquidez (L-VAR), conforme proposto por Li (2012)



Para complementar o estudo, incluiu-se também outros dois modelos: a simulação histórica (da sigla inglês, HS – *Historical Simulation*) e o VAR Delta-Linear, modelos mais simples de cálculo do VAR e que servirão como efeito placebo para os demais modelos.

Quanto aos testes de stress, os mesmos estão representados dentro do modelo MCS-JD através dos “pulos”, conforme explicado adiante. A aplicação de outros tipos de testes de stress não é escopo do presente trabalho.

### 3.1 Dados

Os modelos são testados em cima de dois grupos de países, cada qual representando um tipo de mercado: desenvolvidos e emergentes. Os países foram retirados dentre os componentes do G7 e BRICS e considerou-se a disponibilidade de dados para definição dos selecionados (vide Tabela 1).

A amostra utilizada foi composta pelos principais índices de mercado. O período do qual os dados foram coletados foi de janeiro de 1990 a dezembro 2017, com informações diárias dos índices. O banco de dados utilizado foi o DATASTREAM da Thomson Reuters.

Na tabela 1 são listados cada um dos países e os seus respectivos índices das bolsas:

**Tabela 1:** Países componentes da amostra

| Desenvolvidos  |                         | Emergentes |                          |
|----------------|-------------------------|------------|--------------------------|
| País           | Índice                  | País       | Índice                   |
| Alemanha       | DAX 30 Performance      | Brasil     | Ibovespa                 |
| Canadá         | S&P/TSX Composite Index | China      | Shanghai SE Composite    |
| Estados Unidos | S&P 500                 | Índia      | India BSE (100) National |
| Inglaterra     | FTSE 100                |            |                          |

**Fonte:** Elaboração própria

Além dos índices representativas das bolsas, utilizou-se os preços de abertura (*Opening Price*), os preços mais altos (*High Price*), os mais baixos (*Low Price*) e o volume negociado no dia (*Turnover Volume*).

### 3.2 Volatilidade

Se torna apropriado apontar os *clusters* de volatilidade relevantes que surgiram durante o período em análise. Afinal, com os dados de VaR propostos pode-se verificar com mais clareza a força dos modelos ao analisá-los frente a esses momentos, além dos momentos de baixa.

Quanto aos momentos e as datas da volatilidade, há que se avaliar que algumas oscilações nos retornos podem ter ocorrido em momentos distintos nos países, mesmo os que se conectam a mesma origem econômica, a mesma crise ou o mesmo acontecimento político/social. Delimitar uma data fixa, ou um intervalo fixo baseando-se no evento, tiraria a força da análise na medida que o mesmo pode impactar os países de maneira diferentes e com intensidades diferentes; e os países também podem ter políticas mais eficientes para lidar com tais eventos, tornando o intervalo que supostamente representa o início e o fim um intervalo impreciso.

Portanto, analisou-se a volatilidade não por suas possíveis origens histórica e delimitações históricas, mas sim por picos e oscilações no eventos observados nos gráficos. Outro argumento a favor é que a volatilidade pode ser causadas por eventos financeiros de origem externa ou de origem interna, e as observações dos eventos extremos podem ser mais adequados que a delimitação fechada em datas.

Os modelos com melhor resultados nesse quesito foram os que apresentaram uma aderência aos retornos observados, com as previsões “caminhando” próxima as oscilações observadas.

### 3.3 Backtesting e análise gráfica

Para averiguar a acurácia dos modelos, utilizou-se um *backtesting* focado no percentual de violações (*Violation Ratio* – VR) das previsões, assim como a volatilidade de cada modelo. O primeiro critério de análise dos modelos é um VR que se encontre entre 0,8 e 1,2, conforme sugere Danielsson (2011). Em seguida, o nível

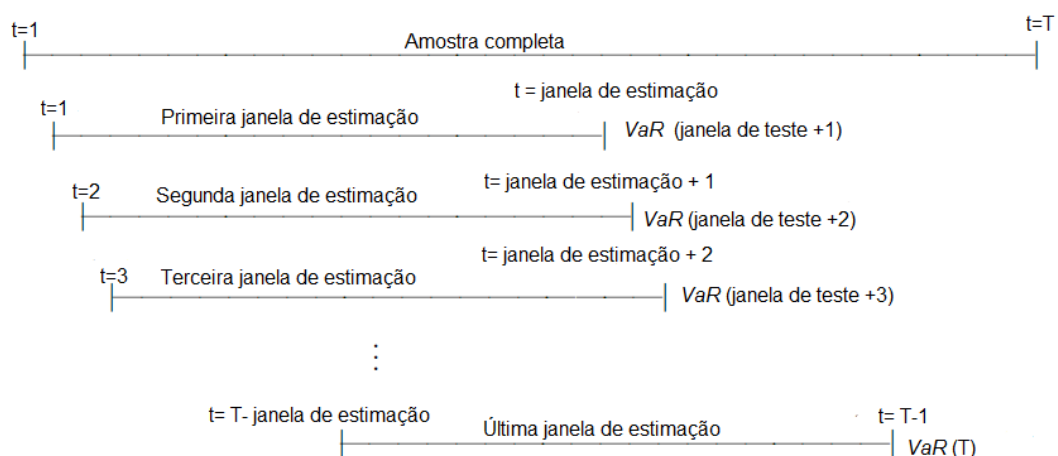
de volatilidade entra como critério de desempate, permitindo ordenar os modelos e elencar o mais acurado ao menos acurado.

Para cálculo do VAR e posterior análise do percentual de violações há que se definir inicialmente o tamanho da janela dos dados a ser utilizado. Danielsson (2011) explica que o tamanho da janela está conectado com o tipo de modelo VAR e com a probabilidade utilizada, e que a janela deve ser grande o suficiente para acomodar os critérios específicos de cada modelo. Exemplifica que o EWMA necessita de apenas 30 dias de janela, enquanto o HS necessita de no mínimo 300 observações. Uma janela demasiada grande também pode influenciar os resultados na medida que atribui a mesma importância a dados mais antigos em comparação aos dados contemporâneos. O uso dos modelos EVT, por exemplo, dependem fortemente dos dados disponíveis na cauda e, portanto, uma janela muito pequena geraria dados não confiáveis a tais dados.

Sendo assim, estipulou-se para a janela um tamanho de 1.000 observações, no intuito de permitir uma melhor avaliação dos modelos EVT. Os modelos utilizaram janelas de tamanhos iguais almejando não apenas a confiabilidade dos resultados mas também a comparabilidade dos modelos.

As janelas, a cada dia, são alteradas, excluindo-se o primeiro dia (o dia mais antigo) e incluindo um dia novo. Dessa forma, o número de dias mantém-se constante, conforme apresentado na figura abaixo:

**Figura 1:** Janela de estimação



**Adaptação:** Danielsson (2011)

Todos modelos de VaR foram calculados utilizando-se um intervalo de confiança de 95%. O intervalo a 95% de confiança permite angariar mais dados para o cálculo do VaR, fato que oferta resultados teoricamente melhores e mais precisos já que o tamanho da amostra interfere no resultado. Constatação ainda mais relevante quando se trata de modelos EVT, os quais modelam os dados na cauda (FERNANDES, 2012).

Não apenas do *Backtesting* se avaliou os modelos, mas também através de seu resultado gráfico. A aderência dos modelos aos resultados observados dado pela distância do valor previsto do observado foi fator chave para apuração dos melhores preditores dos momentos mais voláteis da amostra. Também se gerou gráficos invertidos, de modo a facilitar a análise e visualização de violações ao VaR.

### 3.4 Descrição dos modelos

Antes de se analisar as maneiras de se calcular o VaR, importante esclarecer o modelo em sua forma mais simples, além das características que permeiam tal medida de risco. A fórmula apresentada abaixo em (1) é sua forma mais simples de cálculo. Fernandes (2012) explica que existem diversas metodologias para seu cálculo, mas todas convergem em três pontos/etapas: a carteira é avaliada a preço de mercado (*Market-to-market*); estima-se a distribuição dos retornos da carteira; computa-se o VaR.

Quanto às características do VaR são que a posição atual é estática e que o VaR é escalonado (ALEXANDER, 2008). Por posição atual estática entende-se que o Ganho ou Perda (da sigla inglês, *Profit or Loss - P/L*) são expressos em valores presentes. Já o escalonamento ocorre pois o VaR é medido em um curto horizonte de tempo (um dia, por exemplo) e depois escalonado (estendido) para representar horizontes de tempos maiores.

Almeida, Frascarolli e Cunha (2012) definem o VaR matematicamente como:

$$VaR_{\alpha}(X) = -\inf\{x \mid f(x) > \alpha\} \quad (1)$$

Onde  $\alpha$  é o nível de confiança adotado e  $X$  o processo de retornos, admitindo  $F(x) = \Pr(X_i \leq x_i)$ . Os autores explicam que o valor negativo fornece uma medida

simples da chamada 'pior perda', entendido como o quantil da função densidade de probabilidade.

Adiante, explicação detalhada de cada um dos cinco modelos.

### 3.4.1 VWHS

Uma das formas de se calcular o VaR é através da série temporal dos retornos históricos do ativo. Jorion (2003) explica que a vantagem desse método é que não ocorre nenhuma suposição sobre a distribuição dos retornos, o que inclui, portanto, as caudas pesadas. No entanto, ao se utilizar um intervalo para se efetuar inferências nos movimentos dos preços, corre-se o risco de não ter na amostra exemplos de movimentos extremos.

Nesse método, o valor do portfólio atual é dado pela função dos fatores de risco (variáveis mercadológicas que influenciam o valor do portfólio). Conforme explicado, no presente estudo utilizaremos os índices das bolsas de valores dos países, o que congrega os fatores de riscos em apenas um.

O VaR através da simulação histórica é dado pelo valor corrente do portfólio ( $P_t$ ), o qual é uma função dos fatores de risco corrente ( $P_t = P[f_{1,t}, f_{2,t}, \dots, f_{N,t}]$ ), o qual pode ser reescrito em função do único fator de risco ( $P_t = P[f_t]$ ). O tempo presente é dado por  $t$ , com observações indo, portanto, de 1 a  $t$ . Em seguida gera-se uma amostra da distribuição histórica decorrente da movimentação deste fator ( $\Delta f^k = \{\Delta f_1, \Delta f_2, \dots, \Delta f_t\}$ ) e constrói-se valores hipotéticos a partir de um dado atual ( $f^k = f_t + \Delta f^k$ ). A construção do valor hipotético do portfólio é dado por:

$$P^k = P[f^k] \quad (2)$$

É possível, em seguida, calcular as mudanças no valor do portfólio em referência a posição atual  $R^k = (P^k - P_t)/P_t$ . Após ordenar os retornos em  $t$ , separa-se o que corresponde ao quantil  $c$  ( $R_p(c)$ ). O VaR é calculado, enfim, através da diferença entre a média dos retornos e o retorno que se refere ao quantil  $c$ :

$$VaR = Média[R_p] - R_p(c) \quad (3)$$

A inclusão da volatilidade na análise histórica foi discutida por Duffie e Pan (1997) os quais sugeriam a inclusão da volatilidade presente em cada mercado analisado. A estimativa da volatilidade histórica durante um período de  $t$  a  $T$  ( $\hat{\sigma}_{t,T}$ ) pode, então, ser deduzida através dos retornos  $R_t, R_{t+1}, \dots, R_T$ . Temos:

$$\hat{\sigma}_{t,T}^2 = \frac{1}{T-t} \sum_{z=t+1}^T (R_z - \hat{\mu}_{t,T})^2, \quad (4)$$

Onde  $\hat{\mu}_{t,T} = (R_t + R_{t+1} + \dots + R_T)/(T-t)$ . Os autores sugerem que na forma acima, classificada como ingênua, seja aplicado pesos exponenciais dando mais ênfase aos dados históricos mais recentes. Essa medida pode ser interessante, pois a volatilidade histórica está intimamente ligada a características do mercado, fato que se perde em séries históricas muito longas (DUFFIE e PAN, 1998).

Hull e White (1998) propõe um modelo ponderado. Argumentam que a probabilidade da distribuição de uma variável mercadológica, quando escalonada por uma estimativa de sua volatilidade, é normalmente estacionária (HULL e WHITE, 1998). Para captar a variância das variáveis mercadológicas, Hull e White (1998) orientam usar um modelo GARCH ou um modelo EWMA.

Tsay (2005) explica que a cauda do GARCH (1,1) é mais pesada que a cauda de uma distribuição normal, o que leva a crer que o modelo é mais adequado para predição de eventos extremos. Também destaca-se que o modelo apresenta uma simples equação paramétrica, mas que pode descrever a evolução da volatilidade. Fernandes (2012) explica que o modelo EWMA converge para o GARCH, e que em um horizonte de tempo curto (1 dia) as diferenças entre os dois são muitas vezes imperceptíveis.

O procedimento de cálculo do EWMA inicia-se com a volatilidade:

$$\hat{\sigma}_v^2 = \lambda \hat{\sigma}_{t,T}^2 + (1-\lambda)r_t^2 \quad (5)$$

Onde  $\hat{\sigma}_{t,T}^2$  é a volatilidade histórica,  $\hat{\sigma}_v^2$  é a volatilidade a stress,  $r_t^2$  é o tamanho do choque e  $\lambda$  é o fator de decaimento. Basu (2011) aplica um fator de decaimento

fixo  $\lambda = 0,94$ . No entanto, o autor explica que no caso do VWHS, os resultados não dependem da escolha do fator  $\lambda$ .

Após a definição do EWMA, todos os retornos  $R_t$  são escalonados por um fator de volatilidade  $\frac{\sigma_v}{\sigma_{t,T}}$ . Obtém-se, portanto, retornos ajustados pela volatilidade  $\left(R_v = \left(\frac{\sigma_v}{\sigma_{t,T}}\right) R_t\right)$ .

Por fim, calcula-se o VaR e o ES utilizando o valor de mercado corrente. Para tal, multiplica-se todos os retornos ajustados ( $R_v$ ) pelo valor de mercado corrente do portfólio.

No caso do GARCH temos:

$$\hat{\sigma}_v^2 = \alpha + (1 - \alpha)(\lambda \hat{\sigma}_{t,T}^2 + (1 - \lambda)r_{t,T}^2) \quad (6)$$

O mesmo modelo em sua forma mais simples GARCH (1,1), usado por Basu (2011), é reescrito:

$$\sigma_v^2 = \alpha + \beta r_{t,T}^2 + \gamma \sigma_{t,T}^2 \quad (7)$$

Após a apuração da volatilidade, faz-se o escalonamento  $\left(R_v = \left(\frac{\sigma_v}{\sigma_{t,T}}\right) R_t\right)$  e segue-se as etapas anteriormente apontadas para o cálculo do VaR.

Embora exista essa proximidade entre os modelos, outros pontos podem influenciar seus desempenhos. Basu (2011) aplicou as duas metodologias e os resultados sugerem que cada método possui melhores respostas dependendo do instrumento avaliado. Em sua pesquisa, comparou a taxa de câmbio do dólar e do euro, cada qual tendendo para um modelo.

No presente trabalho utilizaremos o GARCH (1,1) devido aos resultados apresentados no trabalho de Basu (2011) serem melhores para esse modelo.

### 3.4.2 MCS-JD

Na simulação de Monte Carlo (da sigla inglês, MCS), atribui-se uma distribuição aos fatores de risco. Para essa atribuição, assume-se que os choque futuros seguem

a mesma distribuição dos eventos passados (BASU, 2011). Jorion (2003) explica que a flexibilidade do modelo permite que os usuários façam inferências quanto o processo estocástico, o que acarreta em risco de modelo conforme discutido anteriormente.

A distribuição conjunta  $g$  normalmente utilizada para essa simulação são a distribuição normal e a *Student-t*. A forma de cálculo segue o mesmo roteiro da Simulação Histórica, exceto que  $P_T = P[f_{1,T}, f_{2,T}, \dots, f_{N,T}]$  é substituído por  $\Delta f^k \sim g(\theta), k = 1, 2, \dots, k$ . A ideia é fazer uso das vantagens que uma amostra significativamente maior pode trazer (DANIELSSON, 2011).

No intuito de incrementar e aprimorar esse modelo, Duffie e Pan (1997) sugerem aplicar pulos (*jumps*), o que equivaleria a adicionar momentos extremos e, portanto, alterar sua cauda. Essa medida busca evitar a normalidade da distribuição. Chen (2013) explica que a presunção de normalidade dos retornos das variáveis mercadológicas não reflete a realidade, já que suas distribuições geralmente apresentam curtose positivas e, portanto, caudas pesadas.

O MCS-JD, assim como a MCS assume para a distribuição futura uma distribuição igual a histórica. Basu (2011) considerou os retornos do MCS-JD histórico como detentores de uma distribuição normal, com média 0 e variância dada por  $\hat{\sigma}_{t,T}^2$ . Para a distribuição dos retornos futuros considerou-se uma distribuição normal com média 0 e variância dada por  $s^2$  por dia, no qual  $s$  é o tamanho do choque e sua frequência esperada  $\alpha$ .

Para aplicação do choque (pulos) se utiliza o modelo EWMA, o qual teve sua fórmula apresenta anteriormente (equação – 4) e é utilizada para se alterar a variância histórica por um choque. Destaca-se que para o MCS-JD a frequência relaciona-se com o fator  $\lambda$  do modelo VWHS de modo a permitir comparar os resultados ( $\alpha = (1 - \lambda) = 0,06$ ).

Para calcular o VaR, primeiramente se faz a simulação da amostra. Seguiu-se o roteiro de Basu (2011), o qual gerou 50.000 dados e sucedeu-se ao cálculo dos retornos de tal dados, dia a dia.

Alguns aspectos utilizados por Basu (2011) foram dispensados, tendo em vista que esse trabalho não fez uso de um portfólio, tornando desnecessário o cálculo da correlação entre ativos e uma posterior reparametrização dos resultados.

Com os dados simulados, calcula-se a variância e aplica-se os pulos, buscando obter o VaR final.



### 3.4.3 Teoria dos Valores Extremos (EVT)

Ao se referir a crises financeiras, estuda-se situações de baixa frequência e, portanto, raros. A EVT foca em eventos extremos, e enfatizam tais momentos cuja distribuição não aderem a normalidade prevista na distribuição de Gauss. Ho *et al* (2000) explicam que a teoria atenta para os retornos, os quais carregam as informações referentes ao eventos extremos.

Fernandes (2012) explica que duas características da EVT destacam-se. O primeiro é que a distribuição assintótica modelada a partir de uma série de máximos e mínimos converge em uma de três distribuições, *Gumbel*, *Fréchet* e *Weibull*. O segundo resultado a se atentar na EVT é a distribuição do excesso de um determinado limiar, os quais são usados para estimar os altos *quantis* (0,9999 e superior).

Em uma amostra de  $n$  observações de retornos diários  $(x_1, \dots, x_n)$ , é feito o ordenamento das perdas  $(m_1, \dots, m_n)$  de tal forma que a pior perda e o maior ganho possam ser considerados como  $m_n = \max(x_1, \dots, x_n)$  e  $m_1 = \min(x_1, \dots, x_n)$ , respectivamente.

Para se determinar a distribuição assintótica, aplica-se:

$$H_{(\xi, \mu, \sigma)} = \begin{cases} \exp\left(-\left[1 + \xi \frac{(y - \mu)}{\sigma}\right]^{-\frac{1}{\xi}}\right) & \text{se } \xi \neq 0 \\ \exp\left(-e^{-\frac{y - \mu}{\sigma}}\right) & \xi = 0 \end{cases} \quad (8)$$

Onde  $\xi$  é o parâmetro de formato da distribuição,  $\mu$  é um padrão de locação e  $\sigma$  é um parâmetro de escala. O  $\xi$ , também denominado índice de cauda, determina o tipo de distribuição: quando igual a zero, a distribuição H corresponde ao tipo *Gumbel*; quando negativo, ao tipo *Weibull*; e quando positivo, ao *Fréchet*. Essa última está associada a caudas grossas.

No que diz respeito aos excessos, deve-se estimar a distribuição condicional. A função da distribuição cumulativa (CDF) das perdas é denotado por  $F(r) = P[R_i \leq r]$ . Para um *threshold*  $u$  alto suficiente, o excesso é dado por  $y = r - u$ . Temos a distribuição de  $y$  escrito de forma simplificada:

$$F(r) = F(u) + [1 - F(u)]F_u(y), \quad (9)$$

A seguir prossegue-se com a explicação da EVT em conjunto com as abordagens relevantes a presente pesquisa. Tratar-se-á a EVT condicional utilizando do POT e GPD (EVT-GPD), conforme testado por Fernandes (2012); e, por fim, a EVT condicional com incorporação do IGARCH para tratar a volatilidade (EVT-IGARCH), conforme testado por Vee *et al* (2014).

### 3.4.3.1 EVT-GPD

Uma das formas de se considerar a EVT é a condicional, utilizando-se POT e GPD (EVT-GPD). O método baseia-se no POT, o qual foca nos excessos  $y$  acima do limiar  $u$ . O teorema de Picklands-Balkema-de Haan (1974, 1975) estabelece que para um  $u$  suficientemente alto a distribuição de  $y$  aproxima-se da distribuição de Pareto. O teorema prova que se o máximo possui uma GEV, então os excessos seguem uma GPD, o qual pode ser escrito com um limiar fixo:

$$G_{(\xi, \sigma)}(y) = \begin{cases} 1 - (1 + \xi y / \sigma)^{-\frac{1}{\xi}} & \text{se } \xi \neq 0 \\ 1 - \exp\left(-\frac{y}{\sigma}\right) & \text{se } \xi = 0 \end{cases} \quad (10)$$

Para que os excessos se distribuam conforme uma GPD a escolha do limiar  $u$  é fundamental. Um limiar muito baixo faz com que os excessos se distanciem da GPD, enquanto um limiar muito alto pode não restar dados suficientes para se fazer uma inferência estatística (FERNANDES, 2012), fato que motivou o uso do quinto percentil.

Os parâmetros da equação  $\xi$  e  $\sigma$  podem ser estimados através do método da máxima verossimilhança tendo em vista a presunção dos máximos serem independentes e identicamente distribuídos (*i.i.d*). A função *log-likelihood* é dada por:

$$L(\xi, \sigma) = \begin{cases} -N \ln(\sigma) - (1 + \frac{1}{\xi}) \sum_{i=1}^N \ln\left(1 + \frac{\xi y_i}{\sigma}\right) & \text{se } \xi \neq 0 \\ -N \ln(\sigma) - \left(\frac{1}{\sigma}\right) \sum_{i=1}^N y_i & \text{se } \xi = 0 \end{cases} \quad (11)$$

Utiliza-se o  $\xi \neq 0$ . Estima-se  $\xi$  e  $\sigma$  que maximize  $L(\xi, \sigma)$  para a amostra definida por  $N$  observações que excedam o limiar. Tais dados excedentes são dados por  $y_i$ . Por fim, calcula-se o VaR.

### 3.4.3.2 EVT-IGARCH

O uso do POT possui duas desvantagens, conforme explicado por Vee *et al* (2014): assume-se que na EVT os dados usados são *i.i.d*, algo não observado nos retornos; e os retornos financeiros são voláteis e com caudas pesadas, algo que um modelo não condicional falha em rastrear. McNeil e Frey (2000) sugerem combinar o GARCH (1,1) juntamente com o GPD no intuito de apurar tal volatilidade. No entanto, outros estudos apontam desempenhos diversos dentre os modelos da família GARCH.

Para o modelo em questão utilizaremos o IGARCH<sup>9</sup>. A diferença entre o GARCH convencional para o integrado refere-se a existência de uma raiz unitária<sup>10</sup>, ou seja, o impacto de choques passados elevados ao quadrado são persistentes (TSAY, 2005).

O IGARCH (1,1), baseado no GARCH (1,1) conforme apresentado na equação (6), tem  $\beta + \gamma = 1$ , no qual a volatilidade  $\beta$  pode ser reescrito como  $\beta = 1 - \gamma$ .

### 3.4.4 L-VaR

Bangia *et al* (1999) propõe um modelo de integração da liquidez ao VaR o qual ficou conhecido como BDSS. O BDSS, embora uma forma robusta de se incorporar a liquidez ao risco de mercado, possui algumas deficiências. Weiß e Supper (2013) explicam que a definição do fator de correção proposta no modelo é difícil quando não há adequação da distribuição dos spreads especificados, os quais divergem fortemente da distribuição normal. Outro ponto sensível do BDSS é que o modelo presume que os eventos extremos dos retornos e os eventos extremos dos spreads ocorrem simultaneamente.

---

<sup>9</sup> Vee *et al* (2014) testou diversos modelos GARCH e concluiu quanto a melhor adequação do GARCH integrado (IGARCH).

<sup>10</sup> A teoria da raiz unitária refere-se a existência de um coeficiente unitário na série temporal  $y_{t-1}$ ; ou  $y_{t-2}$ ; ...; o que implica que a série segue um comportamento do *random walk* (LIBANIO, 2005).

Li (2012) modificou o BDSS, pois no mercado chinês o *bid-ask spread* não está disponível já que tal mercado não contempla *market makers*. Substituiu tais spreads por outros indicadores de liquidez como o spread entre ordens em aberto, o preço de abertura e o preço mais alto, por exemplo.

Também aplica outras duas correções para o modelo BDSS. O primeiro é uma aplicação de um fator de escalonamento no intuito de corrigir a cauda pesada, utilizando distribuições históricas empíricas (aproximação de Cornish-Fisher). O segundo tratamento é considerar a possível imperfeição na correlação entre o risco de mercado e o risco de liquidez.

Outros modelos se propuseram a mitigar as fragilidades do BDSS (HEUDE e WYNEDAELE, 2001; WEIß e SUPPER, 2013; LI, 2012). Utilizou-se o modelo proposto por Li (2012) devido a aplicabilidade ao mercado chinês.

O BDSS possui duas etapas: primeiramente mensura-se o risco de mercado decorrente da desvalorização do capital (PVAR, mas ajustado por Li (2012) como  $VaR_{market}$ ) e, em seguida, analisa-se e mensura-se o risco de liquidez oriundo da intenção de se liquidar tais ativos (COL, mas ajustado por Li (2012) como  $VaR_{liquidity}$ ).

O BDSS já ajustado por Li (2012) é dado por:

$$VaR_{market} + VaR_{liquidity} = P_t(1 - e^{-\tilde{Z}_\alpha \tilde{\sigma}_t}) + \frac{1}{2} P_t(V + \tilde{z}_V \tilde{\sigma}_V) \quad (12)$$

$$P_t = \frac{P_o + P_h + P_l + P_c}{4}, \tilde{S} = \frac{P_h - P_l}{P_t}, V = \frac{\tilde{S}}{tr * V_0} \quad (13)$$

O  $P_o, P_h, P_l, P_c$  referem-se ao preço de abertura, maior preço, menor preço e o preço de fechamento respectivamente, e  $P_t$  representa o preço médio.  $E(r_t)$  e  $\sigma_t$  são os primeiros dois momentos da distribuição de  $r$ ,  $Z_\alpha$  refere-se ao percentil  $\alpha$  da distribuição do log dos retornos,  $\tilde{\sigma}$  ao desvio padrão (da sigla inglês, SD) do spread e  $\alpha$  é fator de escala da distribuição não Gaussiana. Em substituição ao *bid-ask spread* introduziu-se o *spread* entre o maior e o menor preço, dividido pelo *spread* do volume  $\tilde{S} = \frac{P_h - P_l}{P_t}$ . O indicador de liquidez é dado por  $V = \frac{\tilde{S}}{tr * V_0}$ , com  $tr$  representando o *turnover ratio* e o  $V_0$  representando o volume de moeda negociada.

O modelo BDSS ainda prevê uma correção para o caso dos retornos dos ativos terem um desvio muito distante da distribuição normal. Bangia *et al* (1999) apresentaram um

fator de correção ( $\theta$ ) para descrever a cauda pesada ou a distribuição leptokurtica, correção mantida por Li (2012):

$$\theta = 1.0 + \phi \ln(k / 3) \quad (14)$$

No qual  $k$  representa a curtose e  $\phi$  refere-se a uma constante cujo valor depende da probabilidade da cauda.

Ainda se faz necessário tratar a não normalidade dos preços e dos COL, já que os spreads e os retornos não seguem uma distribuição Gaussiana. Também a correlação imperfeita entre as formas de risco merece tratamento, para evitar superestimação do VAR. O primeiro é feito através da aproximação Cornish-Fisher:

$$\tilde{z} \approx z + \frac{1}{6}(z^2 - 1) * \gamma + \frac{1}{24}(z^3 - 3z) * k - \frac{1}{36}(2z^3 - 5z) * \gamma^2, \quad (15)$$

No qual  $z$  é o percentil  $\alpha$  da distribuição normal,  $\gamma$  refere-se a assimetria (*skewness*) e  $k$  refere-se a curtose em excesso da variável aleatória.

Para a correlação imperfeita temos:

$$VaR_{Total} = VaR_{market} + VaR_{liquidity} + k * VaR_{liquidity} \quad (16)$$

No qual  $k \leq 0$  mede a correlação da cauda entre o retorno do preço e a intenção de liquidar ativos ( $k=0$  no caso de correlação perfeita).

## 4 ANÁLISE DE RESULTADOS

### 4.1 Estatísticas descritivas dos dados

Ao analisar as estatísticas descritivas (Tabela 2), pode-se observar que a média dos retornos em todos os países analisados foi positiva, sendo o Brasil o maior dentre eles. Os países do bloco “desenvolvidos” tiveram um retorno médio bastante similar (entre 0,015% e 0,027%). Já dentre os emergentes, o Brasil se diferencia com um

retorno médio de 0,21%, valor muito mais elevado que os 0,044% e 0,052% apresentados pela China e Índia respectivamente.

Já no que tange à volatilidade, o Brasil novamente apresenta um valor mais elevado. Seu desvio padrão atingiu o valor de 3,99%; enquanto os países desenvolvidos mantiveram-se distantes com valores por volta de 1,0%. No que tange o valor do retorno máximo atingido, a China se destaca, mas seguida de perto pelo Brasil. Enquanto esses países tiveram valores próximos dos 70%, os outros países tiveram retornos máximos muito mais acanhados, rondando os 10% para os países desenvolvidos. Mesmo a Índia se manteve mais controlada, com um retorno máximo de 16%. Não apenas no máximo, mas o Brasil e China também lideraram os mínimos. Dessa vez, no entanto, foi o Brasil quem apresentou o menor valor de mínimo. Vale destacar que a distância ficou novamente extremamente alta, rondando os 70% negativos, muito acima da segunda colocada a China, a qual apresentou um mínimo de -17%.

Cabe ressaltar a similaridade entre as distâncias entre os máximos e mínimos dos países desenvolvidos. Todos tiveram uma variação de 20 pontos aproximadamente, indo de -9% a 9 ou 10% positivos. Bastante diferente dos países em desenvolvimento os quais apresentaram uma distância de pontos bem diferentes entre si e mais elevadas. A China apresenta próximo dos 90 pontos, o Brasil ronda os 140 pontos enquanto a Índia chega aos 27 pontos.

Os dados estatísticos demonstram a alta volatilidade dos dados históricos dos países emergentes, em especial o Ibovespa. Também fica evidente a maior estabilidade dos índices dos países desenvolvidos. Novamente, merece menção o fato que os países desenvolvidos possuem desempenhos muito similares, com volatilidades, valores de mínimo e máximo, média e outras estatísticas bastante próximas.

A Índia merece menção tendo em vista sua similaridade com os países desenvolvidos em alguns dados. O valor de mínimo e máximo e a distância em pontos entre eles se assemelha muito mais a um país desenvolvido que emergente. Os valores de variância, desvio padrão e curtose são mais baixos que seus pares, o que reflete uma maior estabilidade desse mercado. O país indiano, mesmo pertencente aos BRICs, apresenta dados estatísticos de mercado de países desenvolvidos.

**Tabela 2:** Estatística descritiva dos retornos

|                    | <b>Alemanha</b> | <b>Brasil</b> | <b>Canadá</b> | <b>China</b> | <b>EUA</b> | <b>Índia</b> | <b>Inglaterra</b> |
|--------------------|-----------------|---------------|---------------|--------------|------------|--------------|-------------------|
| <b>Observações</b> | 7294            | 7294          | 7294          | 7294         | 7294       | 7294         | 7294              |
| <b>Mínimo</b>      | -9.8707%        | -69.3147%     | -9.7879%      | -17.9050%    | -9.6596%   | -11.9364%    | -9.2655%          |
| <b>Quartil 1</b>   | -0.6131%        | -0.8656%      | -0.3845%      | -0.6452%     | -0.4325%   | -0.6089%     | -0.5113%          |
| <b>Mediana</b>     | 0.0460%         | 0.0000%       | 0.0322%       | 0.0000%      | 0.0490%    | 0.0000%      | 0.0040%           |
| <b>Média</b>       | 0.0270%         | 0.2173%       | 0.0192%       | 0.0444%      | 0.0275%    | 0.0523%      | 0.0158%           |
| <b>Quartil 3</b>   | 0.7288%         | 1.2251%       | 0.4936%       | 0.7687%      | 0.5403%    | 0.7847%      | 0.5690%           |
| <b>Máximo</b>      | 10.7974%        | 69.3147%      | 9.3702%       | 71.9151%     | 10.957%    | 16.6414%     | 9.3843%           |
| <b>Variância</b>   | 1.95609%        | 15.9987%      | 0.9416%       | 4.8744%      | 1.2271%    | 2.4075%      | 1.1755%           |
| <b>D. Padrão</b>   | 1.39860%        | 3.9998%       | 0.9703%       | 2.2078%      | 1.1077%    | 1.5516%      | 1.0842%           |
| <b>Assimetria</b>  | -0.1622         | 0.9639        | -0.7294       | 5.5972       | -0.2832    | 0.0024       | -0.1273           |
| <b>Curtose</b>     | 8.0340          | 138.0888      | 14.4197       | 173.0883     | 12.7884    | 11.5447      | 9.3520            |

*Fonte: Elaboração própria*

#### 4.2 Análise de desempenho dos modelos VAR

Um primeiro aspecto a se analisar é o índice de violação apresentado por cada modelo, em cada país. Danielsson (2011) explica que um VR contido entre 0,8 e 1,2 são considerados bons preditores, e VR muito baixos (<0,5) e muito altos (>1,5) trazem imprecisão ao modelo. Também há que se avaliar a volatilidade do modelo. Danielsson (2011) deixa claro que dentre dois modelos com mesmos índices de violação se optaria pelo menos volátil.

A análise gráfica também é necessária para analisar o comportamento do modelo frente os retornos de modo a apurar a aderência aos *clusters* de volatilidade. Essa inspeção visual rápida de cada um dos modelos permite averiguar qual possui melhor desempenho (DANIELSSON, 2011).

A seguinte sessão está organizada com a análise de desempenho dos países desenvolvidos. Aplicou-se a amostra completa os *backtests* e a análise gráfica para na análise da volatilidade. Na sequência, a mesma organização e os resultados encontrados aos países emergentes.

## 4.2.1 Desempenho nos países desenvolvidos

### 4.2.1.1 Alemanha

Na Alemanha os modelos MCS-JD, VWHS, HS, EVT-GPD e o DELTA-LINEAR apresentaram índices de violação aceitáveis, enquanto o L-VAR e o EVT-IGARCH ficaram fora do intervalo confiável. Desses dois últimos, o L-VAR ainda obteve um valor extremamente baixo de violação, o que o classifica em método não confiável, enquanto o EVT-IGARCH apresentou um resultado inconclusivo.

O valor da volatilidade serve como critério de desempate entre os modelos, colocando o MCS-JD como modelo mais adequado e robusto para previsão das oscilações dos índices, seguido pelo modelo controle DELTA-LINEAR e em terceiro pelo modelo VWHS. Na tabela 3 abaixo expõe-se os modelos por ordem de desempenho, do melhor ao pior, baseando-se nesses dois critérios (VR e volatilidade):

**Tabela 3:** Ranking modelos Alemanha e *Backtesting*.

| Ranking | Modelo       | Índice de Violação (VR) | Volatilidade |
|---------|--------------|-------------------------|--------------|
| 1°      | MCS-JD       | 1.0263                  | 0.2752       |
| 2°      | DELTA-LINEAR | 1.1185                  | 0.5400       |
| 3°      | VWHS         | 1.1503                  | 0.9680       |
| 4°      | EVT-GPD      | 0.8802                  | 1.4011       |
| 5°      | HS           | 1.1534                  | 0.5623       |
| 6°      | EVT-IGARCH   | 0.6037                  | 1.9050       |
| 7°      | L-VAR        | 0.2319                  | 2.7527       |

*Ranking ordenado pelo desempenho nos “backtests” VR e Volatilidade, e considerando a amostra como um todo.*

**Fonte:** *Elaboração própria*

Ao se analisar os gráficos é possível averiguar outras diferenças entre os modelos. O HS e o DELTA LINEAR, dotados de VRs aceitáveis, possuem um comportamento não aderente aos *clusters* de volatilidade, mantendo seu nível de VaR basicamente constante ao longo dos anos. Essa característica deixa de fora qualquer grande oscilação da amostra, resultando em estimativas muito distantes dos valores realmente obtidos, com grande diferença entre o previsto e o observado.



O L-VAR apresenta valores extremamente elevados por toda série histórica, o que justifica seu baixo VR e alta volatilidade. O modelo maximiza as estimativas, gerando acertos por superestimação e baixa frequência de erros absolutos.

O modelo MCS-JD cujos resultados de VR e volatilidade foram o elencaram a melhor preditor nos critérios VR e *backtesting*, não repetiu o desempenho quando observado a aderência aos *clusters*. O modelo possui oscilações e mudanças mais constantes que os modelos controle HS e DELTA-LINEAR, mas possui uma linearidade média. Essa constância média acaba por gerar estimativas com valores distantes do observado.

O EVT-IGARCH foi um dos poucos modelos que conseguiu prever as grandes oscilações nos retornos, inclusive apresentando VaRs altos o suficiente para resguardar o país frente volatilidades bastante altas, tais como as ocasionadas pela crise do *subprime*. Embora aderente aos *clusters*, é possível que os valores de VR inconclusivos estejam conectados com a persistência dos valores VaR, valores que permaneceram altos mesmo após o fim dos *clusters* de volatilidade. Essa persistência levou a uma majoração do VaR em momentos de calma e, conseqüentemente, um baixo desempenho do modelo no que tange seu VR e volatilidade.

Outro modelo EVT, o EVT-GPD acabou por apresentar resultados preditivos imprecisos no que tange os *clusters*, sendo incapaz de acompanhar as oscilações mais extremas, além de manter um valor de VaR mais elevado que o necessário, por tempo demais.

Por fim, o VWHS apresentou aderência às oscilações, comprovando achados de Basu (2011). O modelo também apresentou VR adequado e volatilidade baixa. Foi capaz de acompanhar as oscilações do mercado alemão, mantendo o valor de VAR muito próximo do ideal durante todo período. Manteve-se próximo dos valores extremos e seus erros de estimativa apresentaram uma distância curta do valor observado.

A tabela 4 traz os modelos em ordem de desempenho baseado na análise gráfica, a qual considerou a aderência aos *clusters*:

**Tabela 4:** *Ranking* Modelos Alemanha

| <b>Ranking</b> | <b>Modelo</b> |
|----------------|---------------|
| 1°             | VWHS          |
| 2°             | EVT-IGARCH    |

|    |              |
|----|--------------|
| 3° | EVT-GPD      |
| 4° | HS           |
| 5° | DELTA-LINEAR |
| 6° | MCS-JD       |
| 7° | L-VAR        |

*Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.*

**Fonte:** *Elaboração própria*

#### 4.2.1.2 Canadá

Os resultados no Canadá (Tabela 5 e 6) foram bastante similares aos da Alemanha.

Na análise dos testes de violação e volatilidade o modelo com melhor desempenho novamente foi o MCS-JD, seguido do DELTA-LINEAR e do HS. O VWHS, o EVT-GPD, o EVT-IGARCH e o L-VAR completam o ranking, conforme apresentado na Tabela 5 abaixo:

**Tabela 5:** Ranking modelos Canadá e *Backtesting*.

| Ranking | Modelo       | Índice de Violação (VR) | Volatilidade |
|---------|--------------|-------------------------|--------------|
| 1°      | MCS-JD       | 1.0581                  | 0.1909       |
| 2°      | DELTA-LINEAR | 1.1312                  | 0.5685       |
| 3°      | HS           | 1.1312                  | 0.6039       |
| 4°      | VWHS         | 1.1884                  | 0.8111       |
| 5°      | EVT-GPD      | 1.0867                  | 1.2652       |
| 6°      | EVT-IGARCH   | 1.2901                  | 1.6014       |
| 7°      | L-VAR        | 0.5338                  | 2.7930       |

*Ranking ordenado pelo desempenho nos "backtests" VR e Volatilidade, e considerando a amostra como um todo.*

**Fonte:** *Elaboração própria*

Os únicos modelos que não foram aprovados no teste de violação foram o EVT-IGARCH e o L-VAR. Assim como ocorrido no mercado alemão, o EVT-IGARCH ficou fora do intervalo aceitável, mas manteve-se dentro de um intervalo tido como inconclusivo, com a diferença que agora seu índice de violação foi maior do que o permitido (1,290118), enquanto no mercado alemão ele foi abaixo do permitido (0.6037496). A volatilidade permaneceu extremamente alta, sendo um dos modelos mais voláteis ao lado do L-VAR.

O L-VAR apresentou melhoria em seu valor de VR enquadrando-se em um intervalo inconclusivo. Mas, devido seu alto valor de volatilidade, o modelo figurou novamente em último lugar.

O DELTA-LINEAR e o HS apresentaram resultados muito bons, desbancando modelos mais complexos como o VWHS e o EVT-GPD. Esses, embora dentro do intervalo aceitável, foram mais voláteis o que impactou seu desempenho geral.

No que tange os *clusters* de volatilidade, os modelos VWHS e EVT-IGARCH voltaram a apresentar bom desempenho frente aos retornos, prevendo as grandes oscilações e acompanhando seus valores tempestivamente. O EVT-IGARCH manteve seu comportamento persistente, mantendo valores elevados de previsão mesmo após a redução dos picos. Esse comportamento “persistente” teve melhor resultado no Canadá do que na Alemanha. Isso porque nos anos subsequentes foi possível observar “rebotes” da crise, com os valores previstos baixando e voltando a subir, apresentando picos em diversos momentos. A “persistência” foi mais controlada no mercado canadense, apresentando um VaR mais próximo dos retornos. Isso justifica a volatilidade mais baixa do modelo IGARCH, quando comparado ao mesmo modelo na Alemanha.

Os outros modelos falharam em acompanhar as oscilações. Mesmo com valores de VR adequados, o MCS-JD, HS, EVT-GPD e o DELTA-LINEAR não foram capazes de acompanhar as oscilações nos retornos e foram incapazes de prever as grandes oscilações. A tabela 6 abaixo traz os modelos por ordem de desempenho na análise gráfica.

**Tabela 6:** *Ranking Modelos Canadá*

| <b>Ranking</b> | <b>Modelo</b> |
|----------------|---------------|
| 1°             | VWHS          |
| 2°             | EVT-IGARCH    |
| 3°             | EVT-GPD       |
| 4°             | HS            |
| 5°             | DELTA-LINEAR  |
| 6°             | MCS-JD        |
| 7°             | L-VAR         |

*Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.*

**Fonte:** *Elaboração própria*

### 4.2.1.3 Estados Unidos

No mercado americano o *ranking* dos modelos baseado em seus índices de violação e volatilidade mantiveram a mesma ordem da do mercado canadense. No entanto, algumas diferenças são possíveis observar, conforme tabela 7 abaixo:

**Tabela 7:** Ranking modelos Estados Unidos e *Backtesting*.

| Ranking | Modelo       | Índice de Violação (VR) | Volatilidade |
|---------|--------------|-------------------------|--------------|
| 1°      | MCS-JD       | 0.9628                  | 0.2179       |
| 2°      | DELTA-LINEAR | 1.0581                  | 0.5808       |
| 3°      | HS           | 1.0962                  | 0.5839       |
| 4°      | VWHS         | 1.0676                  | 0.8918       |
| 5°      | EVT-GPD      | 0.7689                  | 1.2808       |
| 6°      | EVT-IGARCH   | 0.7562                  | 1.7478       |
| 7°      | L-VAR        | 0.4957                  | 3.6231       |

*Ranking ordenado pelo desempenho nos “backtests” VR e Volatilidade, e considerando a amostra como um todo.*

**Fonte:** *Elaboração própria*

A primeira observação se refere aos modelos cujo resultado VR os qualificam como aceitáveis. O EVT-GPD dessa vez ficou fora do intervalo 0,8-1,2, figurando como um modelo de resultado inconclusivo, assim como o modelo da família EVT, o EVT-IGARCH. Esse teve um resultado similar ao apresentado na Alemanha, mas com um valor de VR mais baixo, resultado possivelmente das majorações dos valores VaR na previsão. Os dois modelos ainda apresentaram valores de volatilidade bastante elevados quando comparados com os outros modelos.

Os quatro primeiros modelos, MCS-JD, DELTA-LINEAR, HS e VWHS, se assemelharam em VR, se diferenciando quanto a volatilidade. O MCS-JD novamente foi o menos volátil, enquanto o DELTA-LINEAR e o HS tiveram valores um pouco mais elevados e praticamente iguais. O VWHS manteve bons resultados VR, mas sua volatilidade acabou por mantê-lo sem grande relevância no *ranking* proposto.

O L-VAR novamente teve desempenho baixo, apresentando uma volatilidade que se destaca por seu alto valor. Ficou bastante próximo de figurar como um resultado inconclusivo no que tange a VR, mas por fim foi rejeitado com um valor final de 0,4957102. Nos *clusters* de volatilidade, a análise gráfica permite a formação do seguinte *ranking*:

**Tabela 8:** *Ranking Modelos Estados Unidos*

| <b>Ranking</b> | <b>Modelo</b> |
|----------------|---------------|
| 1°             | VWHS          |
| 2°             | EVT-IGARCH    |
| 3°             | EVT-GPD       |
| 4°             | HS            |
| 5°             | DELTA-LINEAR  |
| 6°             | MCS-JD        |
| 7°             | L-VAR         |

*Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.*

**Fonte:** *Elaboração própria*

A posição do ranking manteve-se inalterada, com o VWHS e o EVT-IGARCH se destacando devido sua rápida resposta as oscilações extremas além da aderência às oscilações dos resultados observados.

Os modelos HS, DELTA-LINEAR, MCS-JD foram desqualificados devido sua incapacidade de acompanhar grandes pulos, enquanto o L-VAR teve resultados muito majorados, longe do observado. O modelo EVT-GPD teve sinais de aumentos abruptos, mas não foi capaz de aderir-se as curvas.

#### 4.2.1.4 Inglaterra

O último país dos mercados desenvolvidos analisado, a Inglaterra, se manteve aderente aos resultados já observados em outros países desse grupo. A ordem dos desempenho dos modelos foi igual ao observado nos Estados Unidos e Canadá, conforme Tabela 9 abaixo:

**Tabela 9:** *Ranking modelos Inglaterra e Backtesting.*

| <b>Ranking</b> | <b>Modelo</b>       | <b>Índice de Violação (VR)</b> | <b>Volatilidade</b> |
|----------------|---------------------|--------------------------------|---------------------|
| 1°             | <b>MCS-JD</b>       | 0.9882                         | 0.2133              |
| 2°             | <b>DELTA-LINEAR</b> | 1.0772                         | 0.4665              |
| 3°             | <b>HS</b>           | 1.1407                         | 0.4556              |
| 4°             | <b>VWHS</b>         | 1.1121                         | 0.8087              |
| 5°             | <b>EVT-GPD</b>      | 0.9088                         | 1.1858              |
| 6°             | <b>EVT-IGARCH</b>   | 0.8420                         | 1.5245              |

|    |       |        |        |
|----|-------|--------|--------|
| 7° | L-VAR | 0.2160 | 2.8111 |
|----|-------|--------|--------|

*Ranking ordenado pelo desempenho nos “backtests” VR e Volatilidade, e considerando a amostra como um todo.*

**Fonte:** *Elaboração própria*

Diferente do que se viu nos EUA e no Canadá, dos 7 modelos apenas 1 não foi aprovado de acordo com o critério VR. Os modelos EVT que ficaram fora do intervalo 0,8-1,2 nos EUA, figuraram dentro do intervalo no mercado inglês. A ordem do ranking terminou por não se alterar devido aos índices de volatilidade que permaneceram altos nesses modelos.

O MCS-JD manteve sua regularidade, apresentando um VR e uma volatilidade diferenciadas. Esse modelo, inclusive, se mostrou bastante estável em termos de resultados já que seu VR e sua volatilidade nos quatro mercados foram praticamente os mesmos. Esses resultados podem ser explicados devido a característica do modelo, o qual se baseia em uma simulação de Monte Carlo com a inserção de “pulos”, simulação esta baseada em uma distribuição normal com variância igual a variância observada nos retornos dos ativos.

Na análise gráfica o VWHS e o IGARCH continuaram aderentes as curvas, enquanto modelos como o DELTA-LINEAR, HS e o MCS-JD continuaram com média linear, o que os colocaram com baixo desempenho no que tange a previsão de crises. O L-VAR apresentou valores muito majorados, sem relação com os valores observados.

**Tabela 10:** *Ranking Modelos Inglaterra*

| Ranking | Modelo       |
|---------|--------------|
| 1°      | VWHS         |
| 2°      | EVT-IGARCH   |
| 3°      | EVT-GPD      |
| 4°      | HS           |
| 5°      | DELTA-LINEAR |
| 6°      | MCS-JD       |
| 7°      | L-VAR        |

*Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.*

**Fonte:** *Elaboração própria*

## 4.2.2 Desempenho nos países emergentes

### 4.2.2.1 Brasil

No Brasil, os modelos com melhor resultado no VR e na Volatilidade foram o HS, seguido do VWHS e em terceiro o DELTA-LINEAR. Em quarto lugar, se encontra o EVT-GPD, fechando a lista dos modelos que conseguiram manter-se dentro do intervalo VR.

O modelo L-VAR obteve resultado inconclusivo (0,7149666), mas seu alto valor de volatilidade (62,34834), muito superior ao dos outros modelos, evidencia sua falta de confiabilidade. Na sequência, pode-se observar os modelos EVT-IGARCH e MCS-JD, os quais apresentaram valores baixos de VR e terminando classificados como inadequados.

Aqui já se evidencia uma diferença entre os mercados emergentes e desenvolvidos. Enquanto nos mercados desenvolvidos o resultado do *ranking* praticamente se manteve constante, com um top 3 formado pelo MCS-JD, DELTA-LINEAR e HS (VWHS no caso alemão), no Brasil o MCS-JD foi o modelo pior ranqueado pelo *backtest*. Essa baixa performance pode ser explicada pela característica do modelo que baseia-se em simulações decorrentes da distribuição normal, o que aparentemente não comporta mercados com oscilações tão elevadas.

Outro aspecto interessante a se observar é a alta volatilidade apresentada em cada um dos modelos. Mesmo o HS, o qual foi o menos volátil (1.031535), ainda assim teve volatilidade bem maior que os apresentados pelos países desenvolvidos. Já os modelos L-VAR e os modelos EVT tiveram valores bastante altos, evidenciando a falta de confiabilidade destes.

**Tabela 11:** Ranking modelos Brasil e *Backtesting*.

| Ranking | Modelo       | Índice de Violação (VR) | Volatilidade |
|---------|--------------|-------------------------|--------------|
| 1°      | HS           | 0.8643                  | 1.0315       |
| 2°      | VWHS         | 1.1598                  | 1.7057       |
| 3°      | DELTA-LINEAR | 0.9374                  | 2.0945       |
| 4°      | EVT-GPD      | 0.8579                  | 13.576       |
| 5°      | L-VAR        | 0.7149                  | 62.348       |
| 6°      | EVT-IGARCH   | 0.4289                  | 28.060       |
| 7°      | MCS-JD       | 0.1525                  | 0.7870       |

Ranking ordenado pelo desempenho nos “backtests” VR e Volatilidade, e considerando a amostra como um todo.

**Fonte:** Elaboração própria

Na análise gráfica:

**Tabela 12:** Ranking Modelos Brasil

| Ranking | Modelo       |
|---------|--------------|
| 1°      | VWHS         |
| 2°      | EVT-IGARCH   |
| 3°      | EVT-GPD      |
| 4°      | HS           |
| 5°      | DELTA-LINEAR |
| 6°      | MCS-JD       |
| 7°      | L-VAR        |

Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.

**Fonte:** Elaboração própria

O VWHS continuou como modelo mais aderente às curvas de oscilação extremas. Seu desempenho se assemelhou aos observados nos países desenvolvidos, com respostas rápidas a picos de alta. O EVT-IGARCH também teve bom desempenho geral, falhando com previsões muito altas no início da série, mesmo problema observado no EVT-GPD e no L-VAR. Essa previsão exagerada e inconsistente pode estar conectada com a grande dificuldade e instabilidade econômica e política em que se encontrava o Brasil, com altos valores inflacionários, mudanças de moedas, troca de presidente.

O modelo L-VAR, se mostrou inconstante e com previsões majoradas, enquanto modelos como o HS, DELTA-LINEAR e MCS-JD novamente apresentaram a linearidade média habitual, sem aderir aos eventos extremos.

#### 4.2.2.2 China

Pode-se observar os *backtests* dos modelos no segundo país emergente da amostra, a China, na tabela 13 a seguir:



**Tabela 13:** Ranking modelos China e *Backtesting*.

| Ranking | Modelo       | Índice de Violação (VR) | Volatilidade |
|---------|--------------|-------------------------|--------------|
| 1°      | HS           | 0.9437                  | 1.1583       |
| 2°      | DELTA-LINEAR | 0.8166                  | 1.5324       |
| 3°      | VWHS         | 0.8992                  | 2.4771       |
| 4°      | MCS-JD       | 0.6196                  | 0.4344       |
| 5°      | EVT-GPD      | 0.4416                  | 5.4713       |
| 6°      | L-VAR        | 0.3781                  | 9.3456       |
| 7°      | EVT-IGARCH   | 0.2637                  | 11.5727      |

Ranking ordenado pelo desempenho nos “backtests” VR e Volatilidade, e considerando a amostra como um todo.

**Fonte:** Elaboração própria

Observa-se inicialmente a quantidade de países aceitos como métodos preditivos, contra a quantidade de modelos inconclusivos ou rejeitados. Enquanto no Brasil quatro modelos foram aprovados (HS, VWHS, DELTA-LINEAR e o EVT-GPD), na China apenas três modelos figuraram entre os aceitos (HS, DELTA-LINEAR e VWHS). No grupo dos inconclusivos apenas um, assim como no Brasil. No entanto, enquanto no Brasil MCS-JD apresentou um desempenho bastante fraco figurando em último no *ranking*, na China o MCS-JD apresentou baixíssima volatilidade e um VR melhor, o permitindo terminar em 4° lugar no *ranking* de modelos chinês.

Os outros modelos, L-VAR e os EVTs, novamente foram rejeitados como preditores. Não apenas pelos VRs elevados, mas também seus níveis de volatilidade foram extremamente altos.

O baixo desempenho do L-VAR surpreende já que o modelo foi criado por Li (2012) para se adaptar as características desse mercado. Li (2012) utilizou um índice diferente (o CSI300 *index*) enquanto esse estudo optou pelo Shanghai Composite. Essa baixa resposta do modelo, mesmo aplicado ao mercado chinês, deflagra a possibilidade do modelo ter sido adaptado ao índice, deixando a aplicação a outros mercados e índices como temerária.

No que tange as previsões e aderências aos *clusters* de volatilidade:

**Tabela 14:** *Ranking* Modelos China

| Ranking | Modelo     |
|---------|------------|
| 1°      | VWHS       |
| 2°      | EVT-IGARCH |

|    |              |
|----|--------------|
| 3° | EVT-GPD      |
| 4° | HS           |
| 5° | DELTA-LINEAR |
| 6° | MCS-JD       |
| 7° | L-VAR        |

*Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.*

**Fonte:** *Elaboração própria*

O modelo VWHS manteve sua característica de rápida resposta a choques e adaptação rápida choques. Se manteve aderente, e no que tange os *clusters*, esse modelo pode ser apontado como único modelo adequado para a previsão.

Os outros modelos, embora tenham sido elencados em um *ranking*, não podem ser utilizados como bons preditores para as oscilações mais extremas. Isso porque modelos como o MCS-JD, DELTA-LINEAR e o HS não oscilam com intensidade suficiente para se adequar a grandes picos, mantendo uma média linear. Já os modelos EVT e o L-VAR apresentam sensibilidade a eventos extremos. Não obstante, tendo em vista a grande volatilidade do mercado chinês, os resultados das previsões desses modelos refletem estimativas altas demais.

#### 4.2.2.2 Índia

Por fim, temos a tabela de resultados da Índia:

**Tabela 15:** Ranking modelos Índia e *Backtesting*.

| Ranking | Modelo       | Índice de Violação (VR) | Volatilidade |
|---------|--------------|-------------------------|--------------|
| 1°      | MCS-JD       | 0.8516                  | 0.3053       |
| 2°      | DELTA-LINEAR | 0.9151                  | 0.5910       |
| 3°      | HS           | 0.9119                  | 0.6512       |
| 4°      | VWHS         | 1.0009                  | 0.9874       |
| 5°      | EVT-GPD      | 0.6831                  | 1.5439       |
| 6°      | EVT-IGARCH   | 0.4893                  | 1.9815       |
| 7°      | L-VAR        | 0.2129                  | 4.6092       |

*Ranking ordenado pelo desempenho nos "backtests" VR e Volatilidade, e considerando a amostra como um todo.*

**Fonte:** *Elaboração própria*

O que chama atenção nos resultados indianos é a proximidade com resultados dos países desenvolvidos, mais do que aos dos países emergentes. Similar aos resultados encontrados nos países desenvolvidos, o *ranking* de modelos da Índia apresentou mesma composição para os 7 primeiros lugares quando comparado ao Canadá, Estados Unidos e Inglaterra. Essa semelhança pode ser explicada em parte pela menor volatilidade existente no índice indiano, com variância, desvio padrão e distância entre máximo e mínimo mais baixo dentre todos os países emergentes.

O MCS-JD, DELTA-LINEAR, HS e VWHS não apenas foram aprovados no VR, como mantiveram uma volatilidade bastante similar à encontrada nos países desenvolvidos. Os modelos EVT tiveram também resultados próximos dos apresentados nos países desenvolvidos, com o EVT-GPD apresentado como inconclusivo e o EVT-IGARCH como reprovado. O L-VAR, assim como os países do G7, também foi rejeitado pelo VR baixo e volatilidade elevada.

Na análise dos *clusters* de volatilidade, temos:

**Tabela 16:** *Ranking* Modelos Índia

| <b>Ranking</b> | <b>Modelo</b> |
|----------------|---------------|
| 1°             | VWHS          |
| 2°             | EVT-IGARCH    |
| 3°             | L-VAR         |
| 4°             | EVT-GPD       |
| 5°             | HS            |
| 6°             | DELTA-LINEAR  |
| 7°             | MCS-JD        |

*Ranking ordenado pelo desempenho na análise gráfica e baseado no desempenho dos modelos relacionado a previsão de crises financeiras.*

**Fonte:** *Elaboração própria*

O L-VAR foi capaz não apenas de prever os choques e pulos com tempo hábil para tomada de decisões, mas retornar a valores mais baixos em sequência, evitando a majoração do VaR.

O VWHS manteve seu desempenho, seguido do EVT-IGARCH, ambos com aderência a curva. O EVT-IGARCH apresentou a mesma dificuldade de baixar suas estimativas após a passagem da oscilação extrema, majorando as estimativas e mantendo o VaR alto por tempo demais.

Os outros modelos não preveram o *clusters*, devido a suas linearidades médias (HS, DELTA-LINEAR e MCS-JD) ou suas incapacidades de acompanhar a intensidade do choque (EVT-GPD).

#### 4.2.3 Desempenho geral dos modelos

Os resultados demonstraram a força de cada um dos modelos, muitos sendo aprovados nos *backtests* propostos. O VWHS foi robusto o suficiente para se amoldar a mercados distintos (desenvolvido e emergente), além de responder bem em momentos diversos (picos positivos e calmaria). Foi o modelo que mais consistência teve como preditor de *clusters* de volatilidade e apresentou VR e volatilidade aceitáveis. Esse desempenho do VWHS corrobora com os achados de Basu (2011), o qual explica que a cauda no VWHS e a ponderação permite um preditor com melhor desempenho.

Outro modelo também estudado por Basu (2011), o MCS-JD, teve resultados bastante robustos. Foi o modelo que figurou no topo de quase todos os *rankings*, seja por seu VR aceitável como por seu nível baixo de volatilidade. No entanto, sua falta de aderência às oscilações extremas o coloca como um preditor de picos e oscilações extremas não confiável.

A falta de aderência aos picos pode estar conectada a presunção de que os retornos do ativos seguem uma distribuição normal, informação aplicada nas simulações. Mesmo com a inclusão de “pulos” ao modelo, os resultados se mantiveram inferiores a outros modelos nesse quesito. Não obstante, a combinação VR e volatilidade foram as mais consistentes dentre os modelos.

Os modelos baseados em EVT foram interessantes na medida que esboçavam mudanças na direção da predição das grandes oscilações. O modelo EVT-IGARCH foi bem sucedido nessa predição, possivelmente por ser um modelo não paramétrico e não presumir uma distribuição normal dos retornos. A presunção de distribuição seguida pelo EVT-GPD, pode ter impactado em seus resultados.

Outro motivo que pode ter contribuído para a imprecisão dos modelos EVT pode ser o tamanho da janela de análise. Analisou-se janelas de 1000 observações e por tratar-se de modelo que enfatiza a cauda, a quantidade de observações é fundamental para garantir resultados coerentes. Não obstante, o número de

observações não aparenta ser motivo do baixo desempenho dos modelos EVT tendo em vista que o EVT-IGARCH foi capaz de prever os *clusters* de volatilidade, falhando apenas na duração/persistência delas. Portanto, conclui-se que o número de observações foi suficiente para se obter um resultado adequado, repousando sobre o modelo em si a falta de melhores resultados.

O modelo L-VAR foi o modelo mais instável dentre os analisados. Tal modelo, baseado em BDSS, mas adaptado por Li (2012) para o mercado chinês, apresentou valores muito acima dos retornos observados, mantendo-se sempre bastante instável e impreciso.

Os modelos controle HS e DELTA-LINEAR ganham por sua simplicidade e adequação a índices como VR e volatilidade. Apresentaram uma dificuldade similar ao MCS-JD de manterem-se aderentes aos *clusters* observados, no entanto.

Os resultados permitem confrontar as hipóteses elencadas. As primeiras hipóteses versavam sobre a constância de resultado dos modelos dentro dos países do mesmo grupo. Esperava-se observar para os países desenvolvidos (Alemanha, Canadá, EUA e Inglaterra) um preditor ranqueado em primeiro igual para todos. Para essa hipótese apenas o valor de VR e a volatilidade eram relevantes. A hipótese H1 reza confirmada, tendo em vista que para todos os países desenvolvidos, o MCS-JD foi o melhor ranqueado.

Já a hipótese H2, a qual pressupunha que os países emergentes teriam como melhor preditor o mesmo entre eles, terminou rejeitada. Enquanto que para o Brasil e para a China o melhor preditor foi o HS, a Índia teve o MCS-JD como preditor mais acurado. Na situação de desconsiderar os modelos controle (HS e DELTA LINEAR), a hipótese permaneceria rejeitada já que o Brasil e a China tiveram o VWHS como melhor modelo dentre os cinco testados, o qual é diferente do encontrado na Índia.

Esse resultado no mercado indiano destaca-se já que o país atualmente é enquadrado como do bloco emergente. Isso porque seus resultados econômicos apresentados nessa pesquisa refletem uma proximidade maior com os países do bloco desenvolvido. O *ranking* dos modelos testados foi igual aos do Canadá, Inglaterra e EUA, o que demonstra tal proximidade.

No que tange os *clusters* de volatilidade, a hipótese H3 previa que o modelo mais acurado no mercado desenvolvido seria diferente ao do mercado emergente. A hipótese terminou rejeitada.

O modelo mais aderente aos *clusters* foi o VWHS. Em todos os países, o modelo foi o mais robusto, respondendo rapidamente às oscilações e baixando seus valores de VaR sempre que a volatilidade baixasse. Países com alta volatilidade (como Brasil e China) e países mais estáveis tiveram o mesmo resultado e o modelo foi o mais aderente em todos.

Sendo assim, a presunção de que a baixa volatilidade da série histórica na amostra dos países desenvolvidos e a baixa frequência de eventos extremos, tais como crises financeiras, colocaria em risco a acurácia do modelo, não se confirma nesse estudo.

## 5 CONSIDERAÇÕES FINAIS

O estudo comparativo do VaR é pertinente na medida que se volta a garantir que os valores obtidos são confiáveis para se evitar erros de estimação. Zicovic e Filler (2013), Basu (2011) e Vee *et al* (2014) destacaram alguns dos modelos que aparentemente despontam como mais robustos, a exemplo dos baseados na Teoria dos Valores Extremos e outros tantos existentes.

No presente estudo analisou-se 5 modelos VAR, cada qual já analisado em algum outro momento pela bibliografia, mas não testados entre si. Também se destaca que cada um dos modelos se submeteu a um cenário distinto entre si, tornando a comparação entre eles importante para definir os mais confiáveis.

As hipóteses previam comparar os diferentes mercados, desenvolvidos e emergentes. Buscou-se averiguar se os modelos teria comportamentos diferentes entre mercados, e se a série histórica volátil em países emergentes poderia impactar no desempenho dos modelos quando comparados com o mercado desenvolvido.

No caso alemão, no caso canadense, no caso inglês, no caso estadunidense e no caso indiano, os modelos com melhor resultado foram o MCS-JD e o VWHS. O primeiro modelo, MCS-JD, apresentou grande estabilidade e bons índices de violação, gerando resultados bastante confiáveis. No entanto o modelo não conseguiu repetir seu desempenho no que tange a aderência aos *clusters* de volatilidade, já que não conseguiu acompanhar as oscilações dos retornos. Essa característica já havia sido apontada por Basu (2011), o qual esclareceu que a força do modelo MCS-JD estaria em apontar a quebra de correlação, característica desejável para análise de portfólios de investimento.

O VWHS se destacou fortemente como preditor da volatilidade, tanto nos países desenvolvidos como nos países emergentes, além de obter resultados confiáveis também na apuração de momentos de baixa. O modelo obteve o mesmo resultado para todos os mercados, além de figurar com valores de VR aceitáveis (entre 0,8-1,2). O valor da volatilidade ficou em patamares médios, elencando esse modelo a galgar as primeiras colocações nos *rankings* relacionados a amostra completa: 2º lugar Brasil, 3º lugar Alemanha e China, 4º lugar Canadá, EUA, Inglaterra e Índia.

Esse resultado corrobora os encontrados por Basu (2011), que argumenta que tal modelo combina caudas pesadas com a presença de picos de volatilidade em ambientes voláteis (estressados) nessas caudas. No VWHS, presume-se que choques históricos ou simulados podem ocorrer no futuro, sendo assim, a ponderação da cauda torna esse modelo mais robusto.

Outro modelo que merece destaque é o EVT-IGARCH. Embora tenha obtido resultados bastante baixos no VR e na volatilidade, figurando em posições bastante baixas no *ranking* baseado em *backtesting*, o modelo apresentou uma boa análise gráfica em todos os mercados, o elencando sempre como segundo lugar nesse quesito. O modelo foi capaz de prever todas oscilações extremas, falhando apenas na duração do *cluster*, mantendo valores de VaR majorados.

O resultado desse modelo contrasta com o EVT-GPD testado, o qual obteve resultados inferiores. Essa diferença nos resultados pode ser justificado pela característica dos retornos financeiros, os quais são voláteis e com caudas pesadas. Essas característica coloca a confiança no modelo EVT-GPD em dúvida, já que este presume que os retornos são *i.i.d.*

O uso do GARCH Integrado em substituição ao GARCH também explica a força do modelo, já que dá grande ênfase aos choques passados, elevando a raiz unitária ao quadrado e tornando com que eventos extremos tenham maior relevância (TSAY, 2005).

Os modelos de controle HS e DELTA-LINEAR foram bons preditores quando avaliado seu valor de VR e volatilidade. Sua característica de cálculo leva a uma linearidade do VaR, já que não trabalha com ponderações de eventos ou mesmo com inserção de choques em sua amostra, o que não permite que os modelos tenham bom resultado quando as oscilações são extremas.

Já o L-VAR foi o modelos pior avaliado diante dos parâmetros de teste adotados. O único caso em que não figurou como pior preditor, seja para as hipóteses de análise das crises financeiras como para as hipóteses da amostra completa, foi no Brasil. Nesse caso, seu VR o enquadrou como inconclusivo. Não obstante, seu valor de volatilidade foi tão alto (acima de 60%) que o modelo não pode ser cogitado como um preditor qualificado. Esse baixo resultado pode ser proveniente da construção do modelo. Li (2012) criou o modelo com a intenção de adaptá-lo aos dados disponíveis na China, e utilizou um índice diverso do utilizado nesse estudo (CSI300).

No que tange as hipóteses, H2 foi rejeitado diante dos resultados encontrados na Índia. Diferente do esperado, a Índia se assemelhou mais dos países desenvolvidos que dos países emergentes. Nos países desenvolvidos, a hipótese H1 foi aceita já que todos países nesse mercado tiveram o mesmo preditor elencado em primeiro lugar, o MCS-JD.

E a hipótese H3 também foi rejeitada já que existia a expectativa de que o melhor preditor de *clusters* de volatilidade no país desenvolvido seria diferente do melhor preditor no mercado emergente. Os resultados deflagraram o VWHS como unânime, rejeitando a hipótese em questão.

Pode-se apontar algumas limitações do presente estudo, e sugestões para futuras pesquisas. A utilização de apenas um índice limita a apuração dos modelos, sendo pertinente a aplicação dos mesmos a carteiras de ativos. Pode-se também trabalhar outras opções dentro dos modelos, como utilização de janelas diferentes ou de *backtesting* diversos. Como explica Danielsson (2011), cada modelo pode apresentar uma sensibilidade diferente a janelas de tamanho diferentes.

## 6 REFERÊNCIAS

ACHARYA, V.; ENGLE, R.; PIERRET, D. (2014). *Testing macroprudential stress tests: The risk of regulatory risk weights*. Journal of Monetary Economics, 65, pp. 36-53.

AEBI, V; SABATO, G; SCHMID, M (2012). *Risk management, corporate governance, and bank performance in the financial crisis*. Journal of Banking & Finance 36, pp. 3213–3226.

ALEXANDER, Carol. *Market Risk Analysis Volume III, Pricing, Hedging and Trading Financial Instruments*. England. Editora: John Wiley & Sons, 2008.

ALEXANDER, Carol. *Market Risk Analysis Volume IV, Value-at-risk Models*. England. Editora: John Wiley & Sons, 2008.



- ALEXANDER, C.; SHEEDY, E. (2008). *Developing a stress testing framework based on market risk models*. Journal of Banking & Finance, 32, pp. 2220-2236.
- ALMEIDA, A. T. C; FRASCAROLI, B. F; CUNHA, D. R. *Medidas de Risco e Matriz de Contagio: Uma aplicação do CoVaR para o Mercado Financeiro Brasileiro*. Rev. Bras. Finanças, RJ, Vol. 10, No. 4, dezembro 2012, pp. 551–584.
- AMARAL, L. Crises financeiras: história e actualidade. Relações Internacionais. 2009, n.23, pp.119-138. ISSN 1645-9199.
- BALI, T. (2007). *A Generalized Extreme Value Approach to Financial Risk Measurement*. Journal of Money, Credit and Banking, Vol. 39, n 7.
- BANERJEE, S.; MURALI, D. (2015). *Stress Test of Banks in India Across Ownerships: A VAR approach*. Working paper.
- BANGIA, A.; DIEBOLD, F.; SCHUERMAN, T.; STROUGHAIR, J. (1999). *Modeling Liquidity Risk, With Implications for Traditional Market Risk Measurement and Management*. Working paper.
- BARRIEU, P.; SCANDOLO, P (2015). *Assessing financial model risk*. European Journal of Operational Research 242, pp. 546–556.
- BASEL COMMITTEE ON BANKING SUPERVISION. *An Internal Model-Based Approach to Market Risk Capital Requirements*, Basel, Bank for International Settlements, 1995.
- BASEL COMMITTEE ON BANKING SUPERVISION. *Amendment to the Capital Accord to Incorporate Market Risks*, Basle Report, No. 24, Bank for International Settlements, 1996.
- BASEL COMMITTEE ON BANKING SUPERVISION – BCBS. *Principles for the Management of Credit Risk*, 2000.
- BASEL COMMITTEE ON BANKING SUPERVISION – BCBS. *Principles for the Management of Credit Risk*, 2008.
- BASEL COMMITTEE ON BANKING SUPERVISION – BCBS. *Basel III: The Liquidity Coverage Ratio and liquidity risk monitoring tools*, 2013.
- BASU, S. (2011). *Comparing simulation models for market risk stress testing*. European Journal of Operational Research 213, pp. 329-339.
- BELLINI, T. (2013). *Integrated bank risk modeling: A bottom-up statistical framework*. European Journal of Operational Research 230, 385–398.
- BOLLERSLEV, T. (1986). *Generalized autoregressive conditional heteroskedasticity*. Journal of Econometrics 31, pp. 307–327.

- BONTI, G.; KALKBRENER, M.; LOTZ, C.; STAHL, G; (2006). *Credit risk concentrations under stress*. Journal of Credit Risk, 3.
- BORIO, C. (2014). *The financial cycle and macroeconomics: What have we learnt?* Journal of Banking & Finance 45, 182–198.
- BOUCHER, C.; DANIELSSON, J.; KOUONTCHOU, P.S.; MAILLET, B.B. (2014). *Risk models-at-risk*. Journal of Banking & Finance 44, pp. 72–92.
- BRECHMANN, E.; HENDRICH, K.; CZADO, C. (2013). *Conditional copula simulation for systemic risk stress testing*. Insurance: Mathematics and Economics 53, pp. 722–732.
- BRIGO, D.; NORDIO, C. (2010). A Random Holding Period Approach for Liquidity-Inclusive Risk Management. In: GLAU, K.; SCHERER, M.; ZAGST, R. (2013). *Innovations in Quantitative Risk Management*. Springer Proceedings in Mathematics & Statistics, V. 99,
- CALVO, G. (2012). *Financial crises and liquidity shocks a bank-run perspective*. European Economic Review 56, pp. 317–326.
- CAPRIO, G.; KLINGEBIEL, D. (1996) *Bank Insolvencies: Cross Country Experiences*. World Bank Policy Research Working Paper No. 1620.
- CAPELETTO, L. (2006) *Mensuração do risco sistêmico no setor bancário com utilização de variáveis contábeis e econômicas*. Tese, São Paulo.
- CHANG, K. L. (2012). The time-varying and asymmetric dependence between crude oil spot and futures markets. *Economic Modelling*, v. 29, pp. 2298–2309.
- CHEN (2013) - *Modelling Value-at-Risk for international portfolios in diferent jump-diffusion processes*. Journal of Risk Model Validation, V. 7, n.2, pp. 93-117.
- CHRISTOFFERSEN, P.; HAHN, J.; INOUE, A. (2001). *Testing and comparing Value-at-Risk measures*. Journal of Empirical Finance 8, pp. 325–342.
- COHEN, L.; CORNETT, M.; MARCUS, A.; TEHRANIAN, H (2014). *Bank Earnings Management and Tail Risk during the Financial Crisis*. Journal of Money, Credit and Banking, Vol. 46, No. 1.
- CORNETT, M.; MCNUTT, J.; STRAHAN, P.; TEHRANIAN, H. (2011). *Liquidity risk management and credit supply in the financial crisis*. Journal of Financial Economics 101, pp. 297–312.
- COTTER, J. (2001). *Varying the VaR for Unconditional and Conditional Environments*. University College Dublin.
- COUSIN, A.; Di BERNARDINO, E. (2014). *On multivariate extensions of Conditional-Tail-Expectation*. Insurance: Mathematics and Economics 55, pp. 272–282.

DANIELSSON, J. .Financial risk forecasting: the theory and practice of forecasting market risk with implementation in R and Matlab (Vol. 588). John Wiley & Sons, 2011.

DANIELSSON, J.; MACRAE, R (2011): *The appropriate use of risk models*. voxeu.org.

DE BANDT, O.; HARTMANN, P. (2000) *Systemic risk: A Survey*. European Central Bank Working Paper No. 35, Frankfurt, Germany.

DEMIRGÜÇ-KUNT, A.; DETRAGIACHE, E. (1998) *The determinants of banking crises in developing and developed countries*. IMF Staff Pap., 45, pp. 81–109.

DEYOUNG, R.; FLANNERY, M.J.; LANG, W.W.; SORESCU, S.M. (2001). *The information content of bank exam ratings and subordinated debt prices*. J. Money Credit Bank. 33, pp. 900–925.

Di BERNARDINO, E.; FERNÁNDEZ-PONCE, J.M.; PALACIOS-RODRÍGUEZ, F.; RODRÍGUEZ-GRIÑOLO, M.R. (2015). *On multivariate extensions of the conditional Value-at-Risk measure*. Insurance: Mathematics and Economics 61, pp 1–16.

DIAS, A (2013). *Market capitalization and Value-at-Risk*. Journal of Banking & Finance 37, pp. 5248–5260.

DUBECQ, S. (2013). *Stress-Test Exercises and the Pricing of Very Long-Term Bonds*. General Mathematics, Université Paris Dauphine - Paris IX.

DUCA, M.; PELTONEN, T. (2013). *Assessing systemic risks and predicting systemic events*. Journal of Banking & Finance 37, pp. 2183–2195.

DUFFIE, D.; PAN, J. (1997). *An Overview of Value-at-Risk*. Working paper.

DULLMAN, K.; KICK, T (2014). *Stress testing German banks against a global credit crunch*. Financ Mark Portf Manag, 28, pp. 337–361.

EBER, J.-M., P. ARTZNER, F. DELBAEN and D. HEATH (1999). *Axiomatic structure of coherent measures of risk*. Risk Management Conference, Geneva, November.

FERNANDES, B. V. (2012) - Modelos de valores extremos e convencionais de VaR. Nível de acurácia na previsão de risco de mercado. Universidade de Brasília, Tese.

FERREIRA, C. A. (2013). *Avaliação de Modelos de Risco através de Backtesting*. Instituto Nacional de Matemática Pura e Aplicada, RJ.

GERSL, A.; JAKUBÍK, P.; KONEČNÝ, T.; SEIDLER, J. (2013). *Dynamic Stress Testing: The Framework for Assessing the Resilience of the Banking Sector Used by the Czech National Bank*. Czech Journal of Economics and Finance, 63, no. 6.

GIRARDI, G.; ERGUN, A.T. (2013). *Systemic risk measurement: Multivariate GARCH estimation of CoVaR*. Journal of Banking & Finance 37, pp. 3169–3180.

GORTON, G. B; HAYASHI, F; ROUWENHORST, K. G. (2012). The Fundamentals of Commodity Futures Returns. *Review of Finance* v. 17, pp. 35–105.

GREENE, W. H. (2002). *Econometric Analysis*. 5<sup>o</sup> edição, Uper Saddle River, New York University, Prentice Hall.

GRUNDKE , P. (2010). *Top-down approaches for integrated risk management: How accurate are they?* *European Journal of Operational Research* 203, pp. 662–672.

GRUNDKE, P.; PLISZKA, K (2015). *A macroeconomic reverse stress test*. Discussion paper, Deutsche Bundesbank, n. 30/2015.

HAKWA, B.; JAGER-AMBROZEWICZ, M.; RUDIGER, B. (2012). *Measuring and Analysing Marginal Systemic Risk Contribution using CoV aR: A Copula Approach*. Cornell University Library, Risk Management.

HALBLEIB, R.; POHLMEIER, W. (2012). *Improving the value at risk forecasts: Theory and evidence from the financial crisis*. *Journal of Economic Dynamics & Control* 36, pp. 1212–1228.

HEUDE, A.F.; WYNENDAELE, P. (2001). *Integrating Liquidity Risk in a Parametric Intraday VaR Framework*. Working Paper, Université de Perpignan.

HO, L.; BURRIDGE, P.; CADLE, J.; THEOBALD, M. (2000). *Value-at-risk: Applying the extreme value approach to Asian markets in the recent financial turmoil*. *Pacific-Basin Finance Journal* 8, pp. 249–275.

HOANG, K; FAFF, R.; HAQ, M. (2014). *Market discipline and bank risk taking*. *Australian Journal of Management*, Vol. 39(3), pp. 327–350

HUANG, X.; ZHOU, H.; ZHU, H. (2012). *Systemic Risk Contributions*. *J Financ Serv Res*, 42, pp. 55–83.

HULL, J.; WHITE, A. (1998). *Incorporating volatility updating into the historical simulation method for value at risk*. *Journal of Risk*, University of Toronto.

JORION, P. (2003). *Financial Risk Manager Handbook*. John Wiley & Sons, Inc. Second ed.

KABUNDI, A.; MUTEBA, J. (2011). *Extreme Value At Risk: A Scenario For Risk Management*. *South African Journal of Economics*, Vol. 79:2.

KICK, T.; KOETTER, M. (2007). *Slippery slopes of stress: Ordered failure events in German banking*. *Journal of Financial Stability* 3 (2007) pp. 132–148.

LI, L. (2012). *Integrating Liquidity risk into a VaR Model - An application to the Chinese stock market*. University of Amsterdam, Amsterdam Business School, Master in International Finance.

LIBANIO, G. (2005). *Unit Roots in Macroeconomic Time Series: theory, implications, and evidence*. Belo Horizonte, Nova Economia, 15 (3), pp. 145-176.

LONGIN, F. (2000). *From value at risk to stress testing: The extreme value approach*. Journal of Banking & Finance 24, pp. 1097-1130.

LUCAS, G. A. S. (2009). Risco de Base e Demanda por Derivativos Agropecuários no Brasil. PUC-RJ, Dissertação.

MCNEIL, A.J. (1997) Estimating the Tails of Loss Severity Distributions Using Extreme Value Theory. *Astin Bulletin* 27(2), pp.117–37.

MCNEIL, A. J.; FREY, R. (2000). *Estimation of tail-related risk measures for heteroscedastic financial time series: an extreme value approach*. Journal of Empirical Finance 7, pp. 271–300.

NEGRILA, A. (2010). *The Role of Stress-test Scenarios in Risk Management Activities and in the Avoidance of a New Crisis*. Theoretical and Applied Economics, Volume XVII, n. 2(543), pp. 5-24.

OET, M.; DOOLEY, J.; ONG, S. (2015). *The Financial Stress Index: Identification of Systemic Risk Conditions*. Risks 2015, 3, pp. 420-444.

ONG, L.; PAZARBASIOGLU, C. (2014). *Credibility and Crisis Stress Testing*. Int. J. Financial Stud, 2, pp.15–81.

OSHINSKY, R., OLIN, V. (2006). *Troubled banks: Why don't they all fail?* FDIC Bank. Rev., 18, pp. 23–44.

OURA, H.; SCHUMACHER, L. (2014). *Macrofinancial stress testing: Incorporating systemic risk perspectives into a stress testing framework*. Journal of Risk Management in Financial Institutions Vol. 7, 1, pp. 26-37.

PERIGNON, C.; SMITH, D. (2010). *Diversification and Value-at-Risk*. Journal of Banking & Finance 34, pp. 55-66.

PINHEIRO, M. C (2017). Gestão de risco e modelos de VAR: Comparação do poder preditivo de mensuração de risco para diferentes classes de ativos. Dissertação.

RODRIGUEZ-MORENO, M.; PENA, J.I. (2013). *Systemic risk measures: The simpler the better?*. Journal of Banking & Finance 37, pp. 1817–1831.

SALADO, A.; HUERTA, H.; GUZMÁN, M.E.R.; LAZALDE, J.R.V.; SALADO, C.A.A. (2010). *Estimación del valor en riesgo en la Bolsa Mexicana de valores usando modelos de heteroscedasticidad condicional y teoría de valores extremos*. Economía Mexicana Nueva Época, vol. xxII, n 1, pp. 177-205.

SCHUMPETER, JOSEPH A. - *The Theory of Economic Development*. Cambridge Ma: Harvard University Press, 1968.

TOTIC, S.; BULAJIĆ, M.;VLASTELICA, T. (2011). *Empirical comparison of conventional methods and extreme value theory approach in value-at-risk assessment*. African Journal of Business Management Vol. 5(33), pp. 12810-12818.

TSAY, R. S. (2002). *Analysis of Financial Time Series*. Financial Econometrics, John Wiley & Sons, Inc.

VEE, D.; GONPOT, P.; SOOKIA, N. (2014). *Forecasting value-at-risk for frontier stock market indexes using GARCH-type models and extreme value theory: model validation for dynamic models*. Journal of Risk Model Validation 8(4), pp. 47-67.

WEISS, G.; SUPPER, H. (2013). *Forecasting liquidity-adjusted intraday Value-at-Risk with vine copulas*. Journal of Banking & Finance 37, pp. 3334–3350.

ZAYERNYUK, V.; Chernikova, L.; Leonova, V.; Mukhomorova, I.; Belokhvostova, N. (2015). *Stress Testing as a Tool for Assessing Systemic Risk of Organizations of the Russian Banking Sector*. Mediterranean Journal of Social Sciences, Vol 6 No 3 S3.

ZICOVIC, S.; FILLER, R. (2013). *Ranking of VaR and ES Models: Performance in Developed and Emerging Markets*. Czech Journal of Economics and Finance, 63, no. 4.

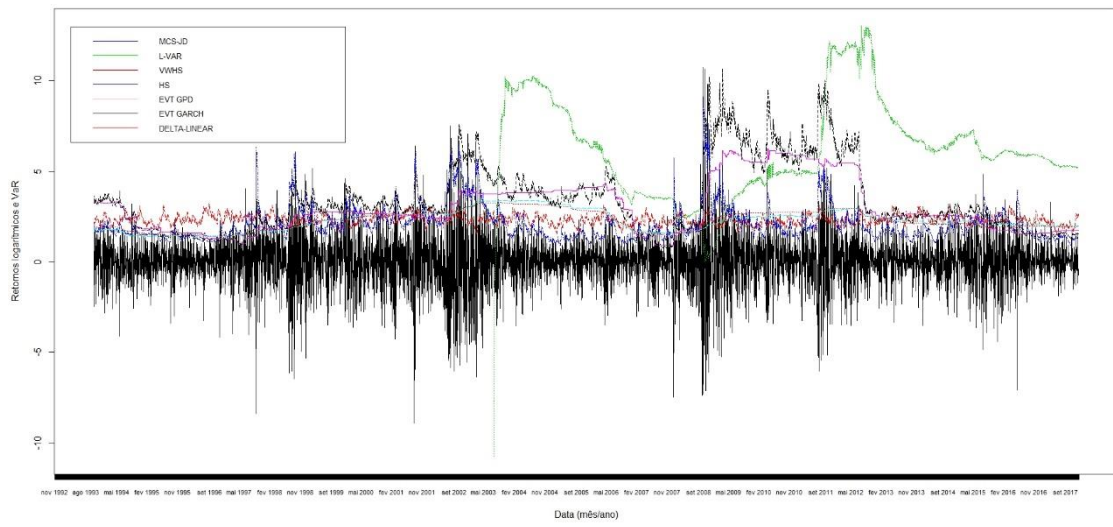
## 7 APÊNDICES

### 7.1 Gráficos de volatilidade do VAR


Apresentação dos gráficos de volatilidade por país;

#### 7.1.1 Alemanha

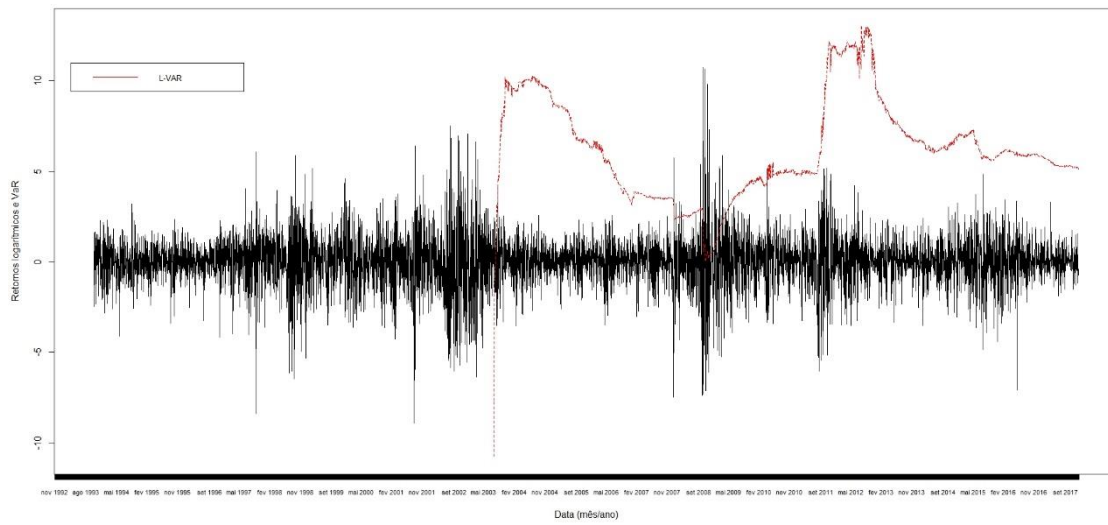
Volatilidade de previsibilidade do VaR




### MCS-JD




### L-VAR



## VWHS




## HS







## EVT-GPD



## EVT-IGARCH




## DELTA-LINEAR




## 7.1.2 Brasil


### Volatilidade de previsibilidade do VaR




### MCS-JD




## L-VAR




## VVHS




## HS




## EVT-GPD



## EVT-IGARCH




## DELTA LINEAR




### 7.1.3 Canadá


Volatilidade de previsibilidade do VaR




### MCS-JD




### L-VAR




## VWHS




## HS




## EVT-GPD



## EVT-IGARCH




## DELTA LINEAR






## 7.1.4 China

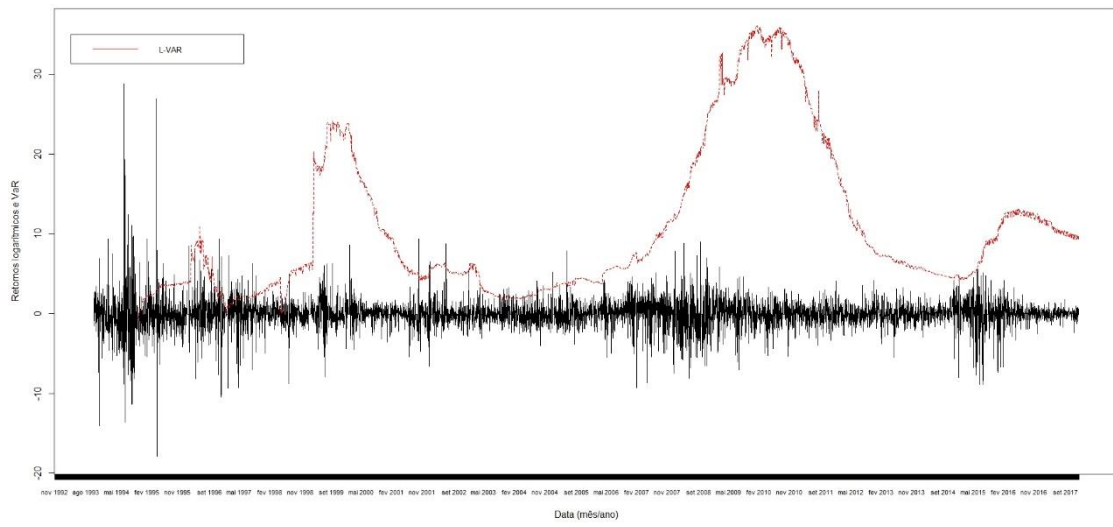
### Volatilidade de previsibilidade do VaR




### MCS-JD




### L-VAR




## VWHS




## HS




## EVT-GPD



## EVT-IGARCH




## DELTA LINEAR




### 7.1.5 Estados Unidos


#### Volatilidade de previsibilidade do VaR




#### MCS-JD




## L-VAR




## VWHS




## HS




## EVT-GPD



## EVT-IGARCH




## DELTA-LINEAR




### 7.1.6 Índia


Volatilidade de previsibilidade do VaR



### MCS-JD




### L-VAR







## VWHS




## HS




## EVT-GPD



## EVT-IGARCH




## DELTA LINEAR




## 7.1.7 Inglaterra


### Volatilidade de previsibilidade do VaR




### MCS-JD




### L-VAR




## VWHS




## HS




## EVT-GPD



## EVT-IGARCH



## DELTA LINEAR



## 7.2 Códigos utilizados na programação R

##### Códigos utilizados para o “Brasil” e replicados para outros países.

#Carregar arquivo R:

```
c <- read.csv("E:/Documents/1 - Arquivos pessoais/Estudo/Contabilidade/3 -
Mestrado/Dissertação/Qualificação/Dados por país/Brasil/Brasil - indice
bolsa.csv",header=T,sep=";")
```

#Transformar coluna da matriz em lista (vetor)

```
prices <- c [,2]
```

#Retirar a vírgula dos números:

```
prices <- gsub(",",".",prices)
```

#Transformar a classe da variável 'prices'

```
prices <- as.numeric(prices)
```

#Calcular log dos retornos / get returns and multiply them by 100 (so they are expressed in returns)

```
log_returns <- diff(log(prices), lag=1)*100
```

```

# de-mean (set mean to zero)
log_returns <-log_returns-mean(log_returns)

#Carregar biblioteca GARCH

library(fGarch)

#Inicialização de variáveis para cálculo VaR
# number of observations for return (log_returns)
T = length(log_returns)

# estimation window length
WE = 1000

# probability
p = 0.95

# HS observation
l1 = WE * p

# portfolio
value = 1;

# matrix to hold VaR forecasts for 4 models
VaR = matrix(nrow=T,ncol=7)

#####MCS-JD
# 1° passo: simular dados. Assume-se Média 0 e variância histórica.

set.seed(1)

# number of simulations
NumSim = 50000

```

```

# daily variance
s2 = var(log_returns)

# simulated returns
retornos_sim = rnorm(NumSim,0, sqrt(s2))

# EWMA (JUMPS) setup
lambda = 0.94;
s11 = var(retornos_sim[1:1000]);
for(t in 2:WE) s11 = lambda * s11 + (1 - lambda) * retornos_sim[t - 1]^2

#####Liquid-VAR
#Carregar arquivo R:
e <- read.csv("E:/Documents/1 - Arquivos pessoais/Estudo/Contabilidade/3 -
Mestrado/Dissertação/Qualificação/Dados por país/Brasil/Brasil - PH PL
PO.csv",header=T,sep=";")
d <- read.csv("E:/Documents/1 - Arquivos pessoais/Estudo/Contabilidade/3 -
Mestrado/Dissertação/Qualificação/Dados por país/Brasil/Brasil - Turnover
Volume.csv",header=T,sep=";")

#Atribuição dos dados PH PL PO e Vo*tr.
PO = e[,4]
PH = e[,2]
PL = e[,3]
Vo = d[,2]

#Retirar a vírgula dos números:
PO = gsub(",",".",PO)
PH = gsub(",",".",PH)
PL = gsub(",",".",PL)
Vo = gsub(",",".",Vo)

```



```

#Transformar a classe da variável 'prices'
PO <- as.numeric(PO)
PH <- as.numeric(PH)
PL <- as.numeric(PL)
Vo <- as.numeric(Vo)

#Calcular Pt, S e V
Pt = (PO + PH + PL + prices)/4
S = (PH + PL)/Pt
V = S/(Vo*Vo)

#####GARCH (1,1)
# saves output to res
#Normal distribution

library(moments)
library (fExtremes)

for (t in (WE + 1):T){

# start of the data window
t1 = t - WE

# end of the data window
t2 = t - 1

# data for estimation
window = log_returns[t1:t2]
print(paste(t))

#MCS-JD
s11 = lambda * s11 + (1 - lambda) * retornos_sim[t - 1]^2
VaR[t,1] = -qnorm(p) * sqrt(s11) * value

```

```
#EVT-GPD
```

```
gpd_fit = gpdFit(window,na.rm=TRUE)
```

```
xi = gpd_fit@fit$fit$par[1]
```

```
beta = gpd_fit@fit$fit$par[2]
```

```
VaR[t,5] = qgpd((1-p), xi = xi, beta = beta)*value
```

```
#GARCH(1,1)
```

```
g <- garchFit(~ garch(1,1), data = window,trace=FALSE,include.mean=FALSE)
```

```
par=g@fit$matcoef
```

```
s4=par[1]+par[2]* window[WE]^2+par[3]* g@h.t[WE]
```

```
VaR[t,3] = -sqrt(s4) * qnorm(p) * value
```

```
#EVT-GARCH
```

```
VaR[t,6] = sqrt(sqrt(s4)) * qgpd((1-p), xi = xi, beta = beta)* value
```

```
#Historic Simulation (Simple)
```

```
ys = sort(window)
```

```
op = WE*p
```

```
VaR[t,4] = -ys[op] * value
```

```
#Delta-Normal
```

```
VaR[t,7] = -value*qnorm(p,0,1)*sd(window, na.rm=TRUE)*sqrt(1)
```

```
#Liquid-VaR
```

```
#quantile, simetria (skewness), curtose da variável aleatória
```

```
z = qnorm((1-p)*2)
```

```
y = skewness(window,na.rm=TRUE)
```

```
k = kurtosis(window,na.rm=TRUE)
```

```
k1 = k
```

```
PT = window
```

```
#-abs(log_returns[t2]-log_returns[t1])
```

```
z_aprox = z + (1/6)*((z^2)-1)*y + (1/24)*((z^3)-(3*z))*k - (1/36)*((2*(z^3))-(5*z))*(y^2)
```

```
#Var_Market
```

```
VaR_Market = PT*(1-(exp(-z_aprox*sd(window,na.rm=TRUE))))
```

```
# data for estimation
```

```
window = V[t1:t2]
```

```
PT = window
```

```
y = skewness(window,na.rm=TRUE)
```

```
k = kurtosis(window,na.rm=TRUE)
```

```
z_aprox = z + (1/6)*((z^2)-1)*y + (1/24)*((z^3)-(3*z))*k - (1/36)*((2*(z^3))-(5*z))*(y^2)
```

```
#VaR_Liquid
```

```
VaR_Liquid = (1/2)* PT*(V + (z_aprox * sd(window, na.rm=TRUE)))
```

```
VaR_Total = VaR_Market + (k1*VaR_Liquid) + VaR_Liquid
```

```
VaR_Total_ordenado = sort(VaR_Total)
```

```
VaR[t,2] = -VaR_Total_ordenado[WE*p] * value
```

```
}
```

```
#Backtesting: Calcular violações e volatilidade (VR = Violations Ratio)
```

```
W1 = WE+1
```

```
for (i in 1:7){
```

```
VR = sum(log_returns[W1:T] < -VaR[W1:T,i], na.rm=TRUE)/(p*(T - WE))
```

```
s = sd(VaR[W1:T,i], na.rm=TRUE) # VaR volatility
```

```
cat(i,"VR",VR,"VaR vol",s,"\n") # print results
```

```
}
```

```
data = c[,1]
```

```
data = as.Date(data, format = "%d/%m/%Y")
```

```
matplot(data[W1:T],cbind(log_returns[W1:T],VaR[W1:T,]),ylab = "Retornos
```

```
logarítmicos e VaR", xlab = "Data (mês/ano)", type='l', xaxt = 'n')
```

```
axis(1, data, format(data, "%b %Y"), cex.axis = .7)
```

```
legend(15000, 30, legend=c("MCS-JD", "L-VAR","VWHS","HS", "EVT GPD", "EVT  
GARCH", "DELTA-LINEAR" ),col=c("blue", "green","red","blue", "pink", "black", "red"),  
lty=1, cex=0.8)
```

```
#Montar gráfico HIT
```

```
ones <- rep(1, NROW(VaR))
```

```
i <- 1
```

```
retorno_over_VAR <- rep("white",NROW(VaR))
```

```
while(i < (NROW(VaR)+1)){
```

```
  ifelse(log_returns[i] > VaR[i,1],retorno_over_VAR[i] <- 4, retorno_over_VAR[i] <-  
  "white")
```

```
  i <- i + 1
```

```
}
```

```
plot(data[W1:T], ones[W1:T], type="h", col=retorno_over_VAR,ylim=c(0,1))
```

```
legend(8500, 1, legend=c("MCS-JD"),col=c("red"), lty=1, cex=0.8)
```