



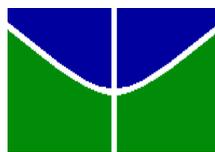
UNIVERSIDADE DE BRASÍLIA (UnB)
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE (FACE)
DEPARTAMENTO DE CIÊNCIAS CONTÁBEIS E ATUARIAIS (CCA)
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CONTÁBEIS (PPGCONT)

Marília Cordeiro Pinheiro

**GESTÃO DE RISCO E MODELOS DE *VaR*: COMPARAÇÃO DO PODER PREDITIVO DE MENSURAÇÃO
DE RISCO PARA DIFERENTES CLASSES DE ATIVOS**

Brasília DF,
2017

BRASÍLIA – DF



2017

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)

Marília Cordeiro Pinheiro

**GESTÃO DE RISCO E MODELOS DE VAR: COMPARAÇÃO DO PODER
PREDITIVO DE MENSURAÇÃO DE RISCO PARA DIFERENTES CLASSES DE
ATIVOS**

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Ciências Contábeis no Programa Multiinstitucional e InterRegional de Pós-Graduação em Ciências Contábeis da Universidade de Brasília

Linha de pesquisa: Contabilidade e Mercado Financeiro

Orientador:
Prof. Dr. Bruno Vinícius Ramos Fernandes.

Brasília DF,
2017

Ficha Catalográfica

Pinheiro, Marília Cordeiro

GESTÃO DE RISCO E MODELOS DE *VaR*: COMPARAÇÃO DO PODER PREDITIVO DE MENSURAÇÃO DE RISCO PARA DIFERENTES CLASSES DE ATIVOS

/ Marília Cordeiro Pinheiro – Brasília, 2017.

94f.

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, 2017.

Bibliografia.

MARÍLIA CORDEIRO PINHEIRO

GESTÃO DE RISCO E MODELOS DE *VaR*: COMPARAÇÃO DO PODER PREDITIVO DE MENSURAÇÃO DE RISCO PARA DIFERENTES CLASSES DE ATIVOS

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. Otávio Ribeiro de Medeiros, Ph.D.
Membro Examinador Interno – PPGCont/UnB

Prof. Dr. José Luiz Barros Fernandes
Membro Examinador Externo – BACEN

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

*A minha mãe, Lilian Cordeiro, pelo apoio,
amor e por ter me criado (**mu**ito³)² bem.*

*A minha avó, Maria Cordeiro,
pela amizade, carinho
e por ter propagado uma genética tão boa.*

AGRADECIMENTOS

Ao Professor Bruno Vinícius Ramos Fernandes pela escolha do tema, confiança depositada e pelo tempo disponibilizado. Aos professores examinadores José Luiz Barros Fernandes e Otávio Ribeiro de Medeiros pela contribuição e atenção concedidas ao trabalho.

Aos professores de finanças do departamento de Administração que tive ao longo da graduação e que muito contribuíram para que seguisse o caminho o qual escolhi. Do PPGCont, um agradecimento especial aos professores José Alves Dantas e Otávio Ribeiro de Medeiros (novamente) por terem me agregado conhecimentos que levarei por toda minha trajetória. Em um país em que a educação é tão pouco valorizada, ser aluna de profissionais como os senhores é algo inspirador.

Aos meus colegas da turma de 2016 que foram muito mais que apenas colegas, sendo amigos e companheiros nesses dois longos anos. Com vocês aprendi que realmente a união faz a força e espero encontra-los após esse período turbulento.

A Inez e Sara, servidoras do PPGCont, por sempre terem me ajudado com paciência, presteza e atenção. Os alunos e o Departamento têm muita sorte de contar com vocês.

Por último e mais importante, a minha mãe Lilian Maria Cordeiro, pelas horas disponibilizadas na revisão de português, referencial teórico, programação, mas, principalmente, pela amizade, fator essencial para finalização do mestrado e para que eu siga em frente.

Resumo

O presente trabalho tem como objetivo testar abordagens distintas do *Value at Risk (VaR)* para diferentes categorias de ativo, de forma a analisar a acurácia dos modelos na estimação do risco de mercado. Para composição da amostra, foram escolhidos ativos pertencentes a diferentes nichos do mercado de capitais; Ibov, dólar, IMA-B, IDA, IFIX, *Commodities* e LP 200. Os modelos de *VaR* testados foram o Delta, *Exponentially Weighted Moving Average (EWMA)*, GARCH, Simulação histórica (HS), Simulação de Monte Carlo (MC) e *Expected Shortfall*, que se distinguem principalmente no aspecto do tratamento da volatilidade dos ativos assim como na inferência sobre sua distribuição. Para apuração de desempenho de estimação do *VaR* foram calculados os índices de violação de cada modelo com o objetivo de verificar se o retorno corrente de um dia específico excede o *VaR* estimado com base na janela de estimação. Em seguida, como forma de validar estatisticamente os resultados encontrados, foram realizados os testes de Kupiec e de Independência. O primeiro foi feito com o objetivo de avaliar a proporção de violações, enquanto que o segundo visando identificar onde essas violações se acumulam. Foram feitas duas análises de resultados, a primeira considerando o período completo da amostra e uma janela de estimação de 1000 dias, enquanto que a segunda considerando triênios e uma janela de estimação de 252 dias. Para a primeira análise, o GARCH apresentou o melhor desempenho, enquanto que o Delta e o MC os piores. Quando comparados aos ativos, o dólar, IFIX e IMA-B apresentaram o maior número de índices, enquanto que o ICB o menor. Para a segunda análise o GARCH, ES e HS apresentaram as melhores performances, o que pode indicar para estes dois últimos a melhoria de estimação com a redução da janela para 252 dias. Os períodos que apresentaram maior número de rejeição foram aqueles abrangidos pela crise de 2008. Quando considerados os ativos, o Ibov foi o que apresentou o maior número de índices apropriados, enquanto que o IDA o menor. Esse resultado vai de encontro a estudos que defendem o uso de uma janela de estimação reduzida para ativos mais voláteis e uma maior para ativos menos voláteis. O melhor desempenho do GARCH pode ser explicado pela característica de agrupamento de volatilidade ao longo de um período.

Abstract

The study is aimed at testing different approaches to Value at Risk (VaR) for a range of asset categories, in order to analyze the accuracy of the models in estimating market risk. For the composition of the sample, assets belonging to different capital market niches were chosen; the VaR models tested were the Delta, Extremely Weighted Moving Average (EWMA), GARCH, Historical Simulation (HS), Monte Carlo Simulation (MC) and Expected Shortfall, which are distinguished based on the treatment of asset volatility as well as inference about its distribution. To assess the VaR estimation performance, the ratios of each model were calculated to verify that the current return of a specific day exceeds the estimated VaR based on the estimation window. Then, as a way to validate statistically the results found, the Kupiec and Independence tests were performed. The first one was done with the purpose of evaluating the proportion of violations, while the second aimed at identifying where these violations accumulate. Two analyzes of results were made, the first considering the complete period of the sample and an estimation window of 1000 days, while the second considering three-year periods and a window of estimation of 252 days. For the first analysis, the GARCH presented the best performance, while the Delta and MC the worst. When compared to assets, the dollar, IFIX and IMA-B had the highest number of indices, while the ICB had the lowest. For the second analysis the GARCH, ES and HS presented the best performances, which can indicate for the latter two the improvement of estimation with the reduction of the window for 252 days. The periods with the highest number of rejections were those covered by the crisis of 2008. With respect to the assets, the Ibov was the one that presented the highest number of appropriate indexes, while the lowest was the IDA. This result matches those of previous studies that advocate the use of a reduced window for more volatile assets and a larger one for less volatile assets. The best GARCH performance can be explained by the volatility pooling characteristic over a period.

Lista de Abreviaturas

APT	<i>Arbitrage Pricing Theory</i>
BACEN	Banco Central do Brasil
CAPM	<i>Capital Asset Pricing Model</i>
COSO	<i>Committee of Sponsoring Organizations of the Treadway Commission</i>
CVM	Comissão de Valores Mobiliários
(EBA)	<i>European Banking Authority</i>
ES	<i>Expected Shortfall</i>
EVT	<i>Extreme Value Theory</i>
EWMA	<i>Exponentially Weighted Moving Average</i>
GARCH	<i>Generalized Autoregressive conditional heteroskedasticity</i>
HS	<i>Historical Simulation</i>
IBOV	Índice Ibovespa
ICB	Índice Commodities Brasil
IDA	Índice de Debêntures ANBIMA
IFIX	Índice de Fundos de Investimentos Imobiliários
IMA-B	Índice de Monte Carlo
VaR	<i>Value at Risk</i>

Lista de Tabelas

Tabela 1: Amostra da pesquisa.....	43
Tabela 2: Estatística descritiva dos ativos.....	58
Tabela 3: Análise de performance do <i>VaR</i> para o período completo.....	62
Tabela 4: Desempenho do <i>VaR</i> por ativos.....	65
Tabela 5: Desempenho dos modelos.....	66

Lista de Figuras

Figura 1: Relação preço e curva de juros do mercado.....	24
Figura 2: <i>VaR</i> da função densidade P/L e cauda esquerda do <i>VaR</i> a q%	34
Figura 3: Janela de estimação.....	45

Sumário

1.0	INTRODUÇÃO	14
1.1	Problema de Pesquisa	16
1.2	Objetivos.....	18
1.3	Relevância.....	18
2.0	REFERENCIAL TEÓRICO	20
2.1	Risco	20
2.1.2	Risco de mercado e risco sistêmico	21
2.2	Riscos inerentes aos ativos	23
2.2.1	Títulos públicos	23
2.2.2	Debêntures.....	25
2.2.3	Ações	26
2.2.4	<i>Commodities</i>	28
2.2.5	Dólar	29
2.2.6	Fundos de investimento imobiliário	31
2.2.7	Fundo de Investimento	32
2.3	<i>Value at Risk</i> e gestão de risco	33
2.3.1	Diferentes formas de cálculo de <i>VaR</i>	34
2.4	Fundamentação teórica das hipóteses de pesquisa	37
2.4.1	Média móvel exponencialmente ponderada (EWMA).....	31
2.4.2	Delta normal.....	31
2.4.3	Simulação histórica.....	32
2.4.4	GARCH.....	33
2.4.5	Expected Shortfall (ES).....	33
2.4.6	Simulação de Monte Carlo.....	34
3.0	METODOLOGIA	42
3.1	Amostra	42
3.2	Formação das janelas para o cálculo do <i>VaR</i>	44
3.3	Estimação do <i>VaR</i>	45
3.3.1	Cálculo de retorno dos ativos	45
3.3.2	<i>VaR</i> paramétrico – Delta normal	46

3.3.3	<i>VaR</i> paramétrico – Média móvel exponencialmente ponderada (EWMA)	47
3.3.4	<i>VaR</i> paramétrico – GARCH	48
3.3.5	<i>VaR</i> não paramétrico - Simulação histórica	49
3.3.6	<i>VaR</i> paramétrico - Simulação de Monte Carlo	50
3.3.7	Expected shortfall	44
3.4	Índice de violação	53
3.5	Teste de significância dos modelos	54
4.0	ANÁLISE DE RESULTADOS	57
4.1	Estatística descritiva dos dados	57
4.2	Análise de desempenho dos modelos de <i>VaR</i>	61
4.2.1	Índices de violação dos modelos de <i>VaR</i> e testes estatísticos	62
5.0	CONSIDERAÇÕES FINAIS	69
6.0	REFERÊNCIAS	72
7.0	APÊNDICES	74
7.1	Gráficos de volatilidade do <i>VaR</i>	74
7.2	Códigos utilizados na programação R	78

1.0 INTRODUÇÃO

A integração dos mercados somada ao desenvolvimento tecnológico acarretou a expansão do mercado de capitais, levando ao surgimento de novos ativos e passivos financeiros, capazes de proporcionar maiores lucros às instituições (MISHKIN; EAKINS, 2012). Ainda que algumas destas inovações financeiras tenham sido criadas com a finalidade de reduzir a exposição do investidor ao risco, grande parte foi elaborada com o objetivo de gerar maiores retornos, porém aumentando o fator do risco (DAMODARAN, 2007).

Nesse contexto, em conjunto as inovações financeiras, surge também à demanda pelo aprimoramento de ferramentas de gerenciamento de risco. Por gestão de risco, entende-se como o processo que envolve a identificação do risco, o estabelecimento adequado de faixas para exposições, mensuração contínua do risco e execução de ajustes toda vez que a exposição extrapolar os limites estabelecidos (MARGINN et. al., 2007).

As razões para investir na gestão de risco podem ser vistas em diferentes dimensões, indo além dos prejuízos financeiros. Como exemplo, pode-se citar a perspectiva social, pois há um interesse coletivo para que os setores econômicos mantenham seu funcionamento estável e seguro, uma vez que a sua ruptura pode levar a crises sistêmicas que resultam em adversidades como desemprego, queda do PIB e estagnação econômica (HOLZMANN; JORGENSEN, 2001). Outro fator preponderante para o gerenciamento de risco é o seu uso como forma de gerar credibilidade para o mercado. Organizações que investem em técnicas que reduzem sua exposição ao risco transmitem uma imagem positiva para os *stakeholders* e conseqüentemente, tendem a captar recursos mais facilmente e à menor custo, o que é favorável ao seu valor de mercado (McNEIL; FREY; EMBRECHTS, 2015).

Os métodos para análise de risco podem ser qualitativos ou quantitativos, sendo o uso conjunto das duas metodologias considerado como a forma moderna do mapeamento de risco (MELKINOV, 2011). A análise qualitativa define o risco em termos dos efeitos de seu impacto e na sua probabilidade de ocorrência utilizando critérios qualitativos (GRAVES, 2000). O Comitê de Supervisão Bancária de Basileia, por exemplo, impôs requerimentos qualitativos para os bancos, como: Uma unidade de controle de risco

independente das operações; *Compliance*; Fluxo de informações entre os gerentes e as áreas de risco (COMITÊ DE BASILÉIA, 2006).

O método quantitativo de gerenciamento de risco constitui-se em uma ciência que faz uso da linguagem da matemática, probabilística e estatística para estimar, controlar, eliminar ou reduzir a exposição ao risco (McNEIL; FREY; EMBRECHTS, 2015). No ambiente do mercado financeiro, esta técnica é essencial para a gestão de investimentos por ser um método objetivo para análise das consequências de oscilações nos preços dos ativos que podem provocar perdas.

A estimação do risco pela forma quantitativa é feita geralmente por modelos de desempenho, alimentados por dados históricos, e preferencialmente complementados por testes de estresse, utilizados como forma de verificar a acurácia do modelo aplicado (CROUHY; GALAI; MARK, 2006). Considerando que os riscos são representados por variáveis aleatórias de eventos futuros incertos, tais modelos baseiam-se principalmente na linguagem da probabilidade (McNEIL; FREY; EMBRECHTS, 2015).

Uma das métricas mais populares utilizadas pelos gestores de risco é o *Value at Risk (VaR)*, que consiste em uma ferramenta estatística que fornece a pior perda esperada dentro de um horizonte de tempo para um determinado intervalo de probabilidade (JORION, 1996). O *VaR* foi criado no final da década de 80 pelo J.P Morgan, sendo difundido pelo Comitê de Basileia em abril de 1995, quando a organização estabeleceu que obrigatoriamente o enquadramento relativo à adequação de capital das instituições financeiras deveria ser baseado no modelo. No final de 1995, a *Securities and Exchange Commission (SEC)*, estabeleceu o *VaR* como um dos três métodos quantitativos que as empresas de capital aberto deveriam utilizar para gestão de risco.

Desde sua criação, diversas abordagens de modelos de *VaR* foram desenvolvidas com o objetivo de aprimoramento de estimação de perdas. Segundo Engle e Managanelli (2004), embora distintos, estes modelos apresentam estruturas semelhantes, sendo resumidas nas seguintes etapas: (1) Obtêm-se os retornos diários, marcados a mercado do portfólio. (2) É feita a estimação da distribuição destes retornos. (3) O *VaR* do portfólio é computado. Os autores acrescentam que a principal diferença entre os modelos encontra-se no estágio 2, pois há uma divergência entre aqueles que assumem que a distribuição dos retornos segue a forma não linear e os que assumem que ela segue uma distribuição linear.

Sendo assim, dificilmente haverá um consenso sobre qual o modelo mais apropriado para a estimação do *VaR*, pois há de se considerar que os instrumentos financeiros formam classes heterogêneas de ativos, com diferentes fundamentações na formação de preços e conseqüentemente, diferentes níveis de exposição ao risco. Por exemplo, o artigo de Duffie e Pan (1997) identifica que a distribuição dos retornos do índice de ações Nasdaq é próxima a normal e desta forma aplica modelos lineares do *VaR*. Entretanto, quando considerada uma carteira de opções, observa-se que o retorno dessas não é distribuído normalmente, o que aumenta a complexidade da estimação de risco, implicando na utilização de modelos não lineares de *VaR* (ALEXANDER, 2009).

Apesar de sua ampla difusão, o *VaR* também possui suas falhas, o que leva a busca de métodos alternativos de mensuração de risco. O mais popular é o *Expected Shortfall* (ES), conhecido também como o *VaR* condicional, que possui como vantagem uma maior sensibilidade em relação a forma da distribuição da cauda esquerda, o que permite o cálculo da perda que excede o *VaR*. Os defensores do modelo afirmam que o ES é mais completo, podendo ser aplicado em qualquer classe de ativo, além de considerar os diferentes tipos de riscos inerentes a um portfólio diversificado (ACERBI; TASCHE, 2002).

1.1 Problema de Pesquisa

Da mesma forma que o aparecimento de novos instrumentos financeiros gerou a demanda para o desenvolvimento de novos métodos de gestão quantitativa de risco, é inegável que esta também impactou positivamente no crescimento não apenas do setor financeiro, como também de outros setores econômicos (McNEIL; FREY; EMBRECHTS, 2015). Desta forma, o gerenciamento de risco evoluiu de ferramentas simplórias para complexos modelos econométricos probabilísticos.

Apesar do *VaR* ser considerado o método estatístico padrão de mensuração de risco de instituições financeiras e empresas de capital aberto, o modelo possui suas fragilidades, gerando um debate sobre a real eficácia de sua adoção (ALEXANDER; SARABIA, 2012). Esta discussão tornou-se ainda mais intensa após a crise de 2008.

Jorion (2003) apresenta algumas das principais limitações: (1) O *VaR* não é capaz de descrever a pior perda; (2) O *VaR* não fornece nenhuma informação sobre a distribuição da perda na cauda esquerda, isto é, o *VaR* não é apropriado para calcular a perda em eventos extremos; (3) O *VaR* é mensurado com erro, isto é, os valores estimados para diferentes escalas de tempo, porém para a mesma amostra, tendem a ser distintos, de forma que seu resultado não é preciso.

Gibson (2010) apresenta a seguinte consideração:

“Qualquer modelo financeiro é uma representação simplória e imperfeita do mundo econômico e da forma como os agentes econômicos gerenciam os investimentos. ”

Considerando as limitações do *VaR*, é conveniente que sejam realizados os *backtesting models*, que têm como finalidade testar a precisão do *VaR* com base em dados históricos (ADAMS; FUSS, 2009). Se o modelo obteve um bom desempenho no passado, tal fator pode ser visto como uma indicação de qualidade. Caso contrário, o *backtesting* pode indicar que o modelo não foi bem especificado, necessitando ser calibrado.

Com base neste contexto, o presente trabalho tem como objetivo testar as diferentes metodologias de cálculo de mensuração de risco para diferentes classes de ativos e analisar a acurácia de estimação para cada modelo, assim como identificar a forma mais adequada para as categorias de ativos da amostra. Desta forma, ressalta-se que a pesquisa tem como foco a mensuração do risco de mercado, que deve ser entendido como o risco sistemático o qual os ativos e passivos financeiros estão sujeitos, decorrente da oscilação das taxas de juros e cambial, preço de ações e *commodities*.

Sendo assim, este trabalho propõe responder a seguinte pergunta de pesquisa:

Quais modelos de mensuração de *VaR* são os mais adequados para as distintas classes de ativos negociados no mercado brasileiro, levando em consideração suas diferentes propriedades estatísticas?

1.2 Objetivos

O trabalho tem como objetivo geral:

Analisar e comparar a capacidade dos modelos de *VaR* paramétricos e não paramétricos na mensuração do risco de diferentes ativos financeiros.

Portanto, como objetivos específicos:

- I. Analisar sob o ponto de vista teórico, os diferentes métodos *VaR*, assim como os modelos alternativos, demonstrando suas formas de cálculo e especificidades;
- II. Realizar o *backtesting* para analisar o nível de acurácia dos modelos;
- III. Efetuar o teste de Kupiec e de independência com o objetivo de validar os resultados obtidos de forma a testar a significância estatística dos resultados encontrados;
- IV. Descrever o desempenho dos modelos para as categorias de ativos.

1.3 Relevância

Os desastres financeiros enfatizam a necessidade do aprimoramento de métodos quantitativos capazes de estimar o risco e a perda de forma mais precisa, tanto para instituições financeiras, como para não financeiras. O *VaR* foi um dos modelos estatísticos que surgiu como resposta a estes distúrbios econômicos, sendo atualmente a métrica mais utilizada no mercado (GAGLIANONE et. al, 2011).

Entretanto a difusão do *VaR* fez com que o modelo fosse amplamente debatido não apenas no mercado, como também no ambiente acadêmico, em especial com a finalidade do desenvolvimento de novas versões de seu cálculo, capazes de estimar o risco com maior acurácia. Neste contexto, os estudos que realizam comparações entre as métricas do *VaR* têm se proliferado (DUFFIE;PAN, 1997; BASAK;SHAPIRO, 2001; BEKIROS;

GEORGOUTSOS,2005; BERKOWITZ;CHRISTOFFERSEN;PELLETIER,2011) Ainda assim, há de se considerar que o *VaR* depende de uma série de características específicas tanto do ativo quanto do mercado ao qual ele pertence, de forma que os testes comparativos entre os modelos estão longe de se esgotar.

McNeil, Frey e Embrechts (2015), afirmam que para a escolha não apenas do modelo de VaR mais adequado, como também de qualquer outro estimador de risco, é necessário levar em consideração fatores como o horizonte de tempo a ser analisado, o nível de liquidez do ativo, as características estatísticas (principalmente a distribuição e volatilidade dos retornos), os tipos e níveis de risco os quais mercado e ativo estão expostos. O mercado financeiro brasileiro é caracterizado por alta volatilidade, desvio da normalidade, sem tendência de termos de dependência estocástica de longo prazo (BERAN;OCKER, 2012). Estas características são típicas de mercados emergentes, que apresentam políticas econômico-financeiras instáveis, estando suscetíveis a crises internas e vulneráveis a crises externas (GENÇAY; SELÇUK, 2004). Desta forma, é conveniente que países emergentes tenham ferramentas robustas de gestão de risco como meio não apenas de prevenirem turbulências em suas economias, como também de ganhar credibilidade e atrair investidores.

Entretanto, diferentemente do contexto dos países desenvolvidos, estudos comparativos dos modelos de estimação de risco em países emergentes ainda são recentes (ZIKOVIC; FILER, 2013). Considerando o contexto brasileiro, ainda são poucos os artigos que realizam comparações da forma mais apropriada de calcular a mensuração de perdas para os diferentes tipos de ativos negociados no mercado financeiro.

Com base nestas considerações, fazendo uso de testes empíricos, o presente trabalho é relevante por contribuir com a identificação do modelo de gestão *de* risco quantitativo mais apropriado para as diferentes classes de ativos, tais como: ações, dólar, título de renda fixa público, título de renda fixa privado, commodities, título imobiliário e fundo de investimento. O trabalho é relevante não apenas para o debate acadêmico, como também como forma de auxiliar a tomada de decisão no contexto da gestão quantitativa de risco no mercado financeiro.

2.0 REFERENCIAL TEÓRICO

2.1 Risco

Garvey (2008) define risco como um evento que, caso ocorra, provoca efeitos adversos no cumprimento dos objetivos estabelecidos de um determinado projeto. Nesta definição, o risco traz dois aspectos importantes. Primeiramente o de probabilidade, decorrente da incerteza de um determinado evento que possa se concretizar. Segundo, o do impacto da ocorrência do evento no projeto. Resumidamente, o risco pode ser entendido como a probabilidade de perda ou dano, em um determinado projeto.

O risco é incorporado no estudo de diferentes ambientes disciplinares, que vão desde o campo de seguros até o de investimentos, o que leva a uma variedade de definições conceituais. Damodaran (2008) apresenta algumas distinções existentes na forma como o risco é tratado:

- Risco *versus* probabilidade: Algumas definições do risco focam apenas na probabilidade de ocorrência de um evento. No entanto, o estudo do risco tornou-se mais abrangente e passou a considerar não apenas a probabilidade como também as consequências do evento.
- Risco *versus* ameaça: Algumas disciplinas traçam uma fronteira entre risco e ameaça. Ameaça consiste em um evento com baixa probabilidade de ocorrência, mas com grande impacto negativo, sendo o cálculo de sua probabilidade de ocorrência inacessível. O risco por outro lado, é definido como um evento com grande possibilidade de ocorrência, em que há informações suficientes para que sejam feitos os cálculos de sua probabilidade e impactos.
- Todos os resultados versus resultados negativos: Algumas definições de risco focam apenas nos cenários de perda, enquanto outros são mais abrangentes. Por exemplo, são englobados também riscos relacionados à perda ou não identificação de oportunidades, utilizados frequentemente nas discussões sobre *trade-off* (custo-benefício).

No contexto do mercado financeiro, o risco é definido em termos da variação dos retornos obtidos em torno dos retornos esperados (DAMODARAN 2008). Marginn et. al. (2007) definem o risco como um fator intrínseco ao investimento, uma vez que sem a sua presença, dificilmente haverá retornos. Desta forma, surge a importância do processo de gestão de riscos, não apenas para investidores, como também para as organizações.

O COSO (2011) define o gerenciamento de riscos como um processo contínuo conduzido pelos profissionais pertencentes a todos os níveis da organização e aplicado à definição de estratégias, sendo formulado para identificar eventos em potencial cuja ocorrência poderá afetar a organização e administrar os riscos, de modo a mantê-los compatível com a aversão ao risco da organização e fornecer garantia razoável do cumprimento de seus objetivos. No contexto do COSO, a gestão de risco se apoia diretamente nos conceitos de controle e *compliance*, tendo como objetivo principal a prevenção de perdas. Sendo assim, para que ocorra a gestão de risco, faz-se necessário, inicialmente, o conhecimento dos riscos aos quais as instituições estão expostas.

2.1.2 Risco de mercado e risco sistêmico

O *European Banking Authority* (EBA) (2001) conceitua o risco de mercado como: “O risco de perdas de posições dentro e fora do balanço decorrentes de movimentos adversos nos preços de mercado.” Collier (2009) define o risco de mercado como o risco derivado de variações nas taxas de juros, no câmbio, no preço de ativos e *commodities*. Jorion (2003) resume o risco de mercado como o risco de flutuações no valor de portfólios devido ao movimento da volatilidade dos preços de mercado. O risco de mercado pode se ramificar em outros tipos de riscos. O Comitê de Basileia (2016) apresenta de forma exemplificativa alguns dos tipos de riscos que podem derivar do risco de mercado:

- i. Risco de *default*, risco de juros, risco do mercado de ações, risco de negociações de *commodities*, risco de câmbio em carteiras de negociação;
- ii. Risco cambial e risco de *commodities* para carteiras de negociação bancárias.

Os efeitos do risco de mercado levaram ao desenvolvimento de diferentes formas de mensuração. De acordo com Saunders e Cornett (2008), as três formas mais utilizadas

para cálculo de risco de mercado são: (1) *RiskMetrics* (ou a abordagem da variância/covariância) (2) Simulações históricas (3) Simulação de Monte Carlo.

O risco de mercado não deve ser confundido com o risco sistêmico, uma vez que o primeiro corresponde a um risco não sistemático, enquanto que o segundo é um risco sistemático, ou seja, um risco não diversificável, que atinge o sistema econômico como um todo. No que tange o risco sistêmico, esse é definido pelo G10 (2001) como:

“O risco sistêmico financeiro é o risco de um evento desencadear em uma perda do valor econômico ou da confiança e consequentemente provocar o aumento de incertezas sobre o sistema financeiro, tendo efeitos significativos sobre a economia real.”

O risco sistêmico é o de maior preocupação dos reguladores devido ao seu efeito dominó: A falência de um banco pode levar à falência de outros bancos, afetando outros nichos econômicos e levando a uma crise sistêmica (CROUHY; GALAI; MARK, 2006). Tal fator ocorre devido à conexão existente entre os agentes econômicos. O balanço patrimonial de cada agente inclui ativos que simultaneamente são passivos de outros agentes. Desta forma se um agente tiver seus ativos desvalorizados, o valor do seu capital também será reduzido. Este fator irá inibir os gastos deste agente o que irá interferir no lucro dos outros integrantes do mercado. Se a perda do valor do ativo for suficientemente grande, pode ainda interferir na capacidade de cumprimento das obrigações do agente, levando ao *default* e reduzindo o valor dos ativos de outros agentes (KAUFMAN, 1996).

No modelo do *CAPM* o risco sistêmico é tido como não diversificável, por atingir não apenas uma ação, mas sim o mercado de ações como um todo, independente do setor econômico (DAMODARAN 2008). A preocupação do risco sistêmico é decorrente justamente do seu potencial de gerar crises sistêmicas, o que fez ambos os conceitos serem tidos como sinônimos nas décadas de 80 e 90 (OET; DOOLEY; ONG, 2015). O risco sistêmico é tido como a representação da propensão de ruptura do sistema financeiro.

2.2 Riscos inerentes aos ativos

As subseções seguintes fazem uma breve descrição dos fatores que compõem a precificação dos ativos estudados no presente trabalho e dos principais riscos aos quais estão sujeitos.

2.2.1 Títulos públicos

Os títulos de dívida pública são instrumentos financeiros de renda fixa emitidos pelo Governo Federal para a captação de recursos junto à sociedade, tendo como finalidades principais o financiamento do déficit orçamentário e a realização de operações para fins específicos (Tesouro Nacional, acesso 2016). São tidos como ativos livres de risco no mercado, uma vez que a sua contraparte é o governo, sendo comumente utilizados para o cálculo do prêmio de um investimento.

Os títulos públicos podem ser emitidos pelo valor descontado ou com pagamentos de cupom. Os títulos descontados (*zero cupom*) recebem este nome por realizarem um único pagamento na data de vencimento, sendo emitidos com deságio em relação ao seu valor nominal, de forma que o retorno do investidor é igual ao valor de face menos o preço da emissão. Os títulos com cupom são aqueles que efetuam pagamentos periódicos até a data de vencimento, sendo estas amortizações o retorno do ativo para o investidor (FABOZZI; FLEMING, 2000).

Títulos com o mesmo vencimento, porém com pagamentos de cupom distintos possuem rendimentos diferentes, enquanto que títulos zero cupom, com vencimentos iguais, possuem o mesmo rendimento. Tal fator se deve a relação existente entre os preços dos títulos e a taxa de juros do mercado (ALEXANDER, 2008). O preço justo de um título é dado pelo somatório do valor presente de todos os seus fluxos de caixa, incluindo os pagamentos do cupom e o resgate (CHOUDHRY, 2006). Com base nesta premissa, infere-se que o preço do título e taxa de juros seguem direções opostas, uma vez que os fluxos são descontados a valor presente.

Considerando a relação inversa existente entre taxa de juros e a precificação, o principal risco a que os títulos estão expostos é o da variação da taxa de juros, uma vez que o seu aumento impacta negativamente no valor do título (MISHKIN; EAKINS, 2012). Uma consideração a ser feita é que títulos de vencimento mais longo são mais sensíveis à variação da taxa de juros, pois seus retornos são mais voláteis do que títulos de curto prazo (CHOUDHRY, 2006).

O gráfico abaixo ilustra a relação existente entre o preço de um título e a taxa de juros:

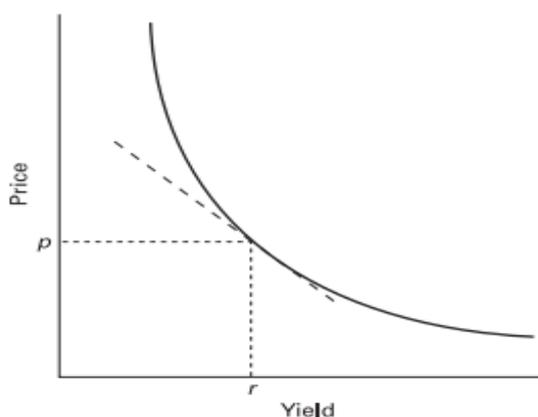


Figura 1: Relação preço e curva de juros do mercado

Fonte: CHOUDHRY, 2006

Títulos com pagamentos de cupom estão menos expostos ao risco da oscilação da taxa de juros do que os títulos de zero cupom, pois as amortizações feitas anteriormente ao vencimento fazem com que o investidor recupere o capital aplicado mais rapidamente (SAUNDERS; CORNETT, 2008). Portanto, quanto maior o cupom do título, mais rápida será a recuperação do investimento e conseqüentemente, menor a sensibilidade do preço do título à variação da taxa de juros.

2.2.2 Debêntures

As debêntures são uma categoria de títulos privados que tem por objetivo a captação de recursos em troca do pagamento do principal somado aos juros incidentes. As debêntures podem ser pré-fixadas ou pós-fixadas; A primeira categoria consiste em títulos que já possuem sua rentabilidade definida até o momento de seu vencimento. A segunda categoria são títulos que estão atrelados a um indexador e por isso tem sua remuneração periodicamente ajustada. Quanto a sua emissão, assim como os títulos públicos, os títulos privados podem ser emitidos com o valor descontado ou com pagamento de *cupom*.

Por ser um título de dívida, o preço da debênture se move de forma inversa a oscilação da taxa de juros, de forma que, mantido o vencimento constante, um decréscimo nos juros eleva o valor da debênture, enquanto que um acréscimo acarreta em sua desvalorização. Outro parâmetro importante na precificação é o seu vencimento, uma vez que quanto maior o prazo de vencimento maior tende a ser a volatilidade, haja vista que maior é sua sensibilidade às taxas de juros. Esses fatores compõem o risco da oscilação da taxa de juros (MARTELLINI; PRIAULET; PRIAULET, 2003). Embora o processo descrito seja semelhante ao dos títulos públicos, as debêntures apresentam um risco maior por estarem expostas também ao risco de crédito.

O risco de crédito corresponde ao risco do emissor da debênture não cumprir as obrigações estabelecidas. O risco de crédito também pode ser visto sob o aspecto de deterioração da qualidade do crédito, o que impacta nos resultados do fluxo de caixa (SAUNDERS; CORNETT, 2008). Como forma de auxílio e divulgação de informações sobre o risco de crédito, surgiram as agências de rating, que tem por objetivo a análise da capacidade do emissor de dívida em pagar o principal e o rendimento prometido ao investidor. O *rating* de crédito também é um fator fundamental no prêmio-risco exigido pelo mercado (HUANG, 2003).

2.2.3 Ações

As ações constituem-se em títulos de renda variável que representam parte do patrimônio de uma organização. A principal diferença entre as ações e os títulos privados é a responsabilidade limitada, que implica que os acionistas podem perder o capital aplicado em caso de falência da empresa. Por isso, as ações são consideradas investimentos que proporcionam maior risco do que os títulos (JORION, 2000).

Assim como outros ativos, o valor da ação é determinado pelo valor presente dos fluxos de caixa, representados pelo somatório do pagamento de dividendos e o preço pelo qual a ação é vendida (ROSS; WESTERFIELD; JAFFE, 2009). Entretanto o seu *valuation* é mais complexo devido à dificuldade de estimação precisa da taxa de desconto, uma vez que essa não se comporta de forma estável como, por exemplo, a de títulos públicos (JORION, 2000).

Os fluxos de caixa futuros são dependentes não apenas de variáveis internas, como também variáveis externas, o que interfere no cálculo da taxa de desconto, pois essa não é capaz de captar todas as incertezas as quais a empresa está exposta. Este fator ocorre porque eventos imprevistos alteram a taxa de desconto empregada e com isso influenciam também o valor estimado dos fluxos de caixa futuro, o que é refletido na precificação das ações e no prêmio-risco exigido pelos investidores (CHEN; ROLL; ROSS, 1986).

Diversos estudos já foram realizados objetivando encontrar os principais fatores que influenciam a precificação das ações. Bhandari (1988), por exemplo, analisou a influência dos tipos de alavancagem no retorno esperado. O autor identificou uma associação positiva entre retorno e alavancagem da empresa a valor de mercado (dívida/valor das ações), porém uma relação inversa quando considerada a empresa a valor contábil (dívida/valor contábil).

Após a teoria dos portfólios, as variáveis econômicas externas passaram a receber atenção especial, uma vez que essas representam o risco sistemático da ação, ou seja, o risco que não pode ser diversificado (CHEN; ROLL; ROSS, 1986). Com isso, surgiram novos modelos de estimativa de custo de capital e avaliação de carteiras de investimento,

sendo o *capital asset pricing model* (CAPM) o mais utilizado por fornecer previsões sobre a medida de risco e a relação entre risco e retorno.

O CAPM introduz o conceito do beta de mercado, que pode ser interpretado como uma variável que mede a sensibilidade do retorno do ativo à variação do retorno da carteira de mercado. O modelo coloca que o retorno esperado de uma ação é igual à taxa livre de risco mais o beta de mercado da ação multiplicado pelo prêmio por unidade de risco beta (FAMA;FRENCH, 2007). Apesar do CAPM ser o modelo predominante nas finanças, o modelo é alvo de diversas críticas, devido a sua simplicidade em assumir que o retorno do ativo comporta-se de forma linear em relação ao seu beta de mercado e de não levar em consideração outros fatores de risco, os quais foram posteriormente introduzidos.

A teoria da formação de preços por arbitragem (APT) desenvolvida por Ross (1977) oferece uma forma alternativa ao CAPM para a precificação de ativos. O APT assume que os retornos esperados dos ativos são definidos em função linear a uma série de variáveis estruturais econômicas e não apenas ao fator risco da carteira de mercado, conforme o CAPM (ROLL, ROSS, 1980). Logo, a principal diferença é que o APT assume que existe mais de um fator relevante na precificação do ativo.

Outro método alternativo ao CAPM é o de três fatores de Fama-French (1993). O modelo assume que o retorno esperado de um portfólio depende de três variáveis: (1) Fator mercado: O prêmio risco da carteira de mercado (diferença entre o retorno da carteira de mercado e do ativo livre de risco) (2) Fator tamanho: Diferença entre o retorno de uma carteira de ações de empresas pequenas menos o retorno de uma carteira de ações de empresas grandes (*small minus big*) (3) Fator patrimônio-mercado: Diferença entre o retorno de empresas de alta capitalização menos o retorno de empresas de baixa capitalização (*high minus low*) (FAMA;FRENCH, 1996). Posteriormente, os autores expandiram o modelo para o modelo de cinco fatores, com o acréscimo das variáveis de rentabilidade e investimentos, entretanto, apesar da melhoria, o modelo falha em capturar o preço médio de ações de pequenas empresas, com lucros baixos, porém com grandes investimentos (FAMA;FRENCH, 2014).

Ainda assim, os modelos criados por Fama e French são criticados por não conseguirem captar as anomalias presentes no mercado. Como resposta a esse *gap*, Hou, Xue e Zhang (2015) criaram *q factor model* composto pelas seguintes variáveis: O excesso

de retorno do mercado, a diferença entre os retornos de um portfólio composto por ações de empresas de pequeno porte e de grande porte, a diferença entre os retornos de ações de baixo investimento e de alto investimento e por fim a diferença entre os retornos de ações de alta lucratividade e baixa lucratividade. O modelo apresenta uma melhor performance do que o de Fama- French e Carhart em capturar o momento das anomalias. Tal fator ocorre porque os autores realizam uma associação direta entre os retornos das ações e as características específicas das firmas o que gera um modelo dinâmico na captura dos choques dos retornos.

2.2.4 *Commodities*

As *commodities* consistem em classes heterogêneas de ativos, de forma que cada espécie possui seu preço conduzido por uma variedade de fatores específicos (Adam, Fuss, & Kaiser, 2008). Apesar de serem matérias primas, as *commodities* passaram a ser vistas como investimento devido aos componentes econômicos que contribuem para a formação de seu preço, fazendo com que estas se tornassem *hedge* de oscilações de índices econômicos que afetam o mercado, principalmente a inflação (STEPHENSON, 2010).

A volatilidade dessa categoria de ativos ainda é algo não compreensível, uma vez que as oscilações dos preços das *commodities* ainda é controversa. O risco das *commodities* é comumente associado aos choques de demanda e oferta no mercado agrícola, além das políticas macroeconômicas que também possuem um papel essencial em seu retorno. Entretanto há de se considerar que existem outros fatores que são imprevisíveis para o mercado, mas que influenciam os preços das *commodities*. As *commodities* agrícolas, por exemplo, dependem das condições climáticas, de forma que pouco pode ser feito para prevenir grandes perdas decorrentes desse fator. Outro ponto é que devido ao seu processo de “financiarização” as *commodities* também passaram a sofrer com as especulações no mercado financeiro (RAPSOMANIKIS; SARRIS, 2010).

Uma variedade de modelos foi criada com o objetivo de lidar com a volatilidade sistêmica de séries financeiras, sendo que a maioria foi elaborada com foco em ativos em que o comportamento dos retornos passados não pode ser utilizado como fator de previsão

dos retornos futuros. A volatilidade das *commodities* se diferencia das séries financeiras comuns por ser decomposta em dois componentes: o cíclico e o aleatório (BALCOMBE, 2010).

O comportamento cíclico é explicado pela sazonalidade de comercialização desses produtos, podendo ser utilizado para estimação de retornos futuros. Tal fator se deve aos choques de oferta e demanda das *commodities* agrícolas, uma vez que, em decorrência da sazonalidade, os investidores esperam que esses ativos voltem ao seu preço de equilíbrio (FRANKEL, 2014). Já o aleatório é o correspondente aos fatores imprevisíveis que são os responsáveis pela instabilidade da volatilidade das *commodities*. Esse fator aleatório é ainda mais notável quando considerados os retornos dos índices de commodities uma vez que os fatores intrínsecos ao mercado financeiro passam a influenciar no retorno da categoria desses ativos, de forma que a oscilação do valor do índice é transmitida para as categorias individuais de *commodities* (BASAK; PAVLOVA, 2016).

2.2.5 Dólar

A hegemonia monetária do dólar começou no período pós 2ª guerra mundial, com o sistema de Bretton Woods. Os países europeus ocidentais possuíam uma grande dívida frente aos Estados Unidos e esse era detentor de grande parte das reservas de ouro mundial. Além disso, o país também era detentor central dos bens de mercado e capital. Com a preocupação de reconstrução da política monetária internacional, o sistema de Bretton Woods buscava somar as vantagens da política padrão ouro (estabilidade cambial) às vantagens de um sistema de flutuação de taxas (independência monetária) (BORDO; EICHENGREEN, 2007).

Com a Inglaterra enfraquecida e endividada, os acordos de Bretton Woods substituíram o padrão libra-ouro pelo padrão dólar-ouro: os países tinham sua taxa de câmbio atrelada ao preço do ouro, e o dólar americano assumia o papel de moeda-reserva, tendo seu valor ancorado ao valor do ouro. Trinta e dois países adotaram o regime cambial, que durou por 25 anos, tendo seu fim em 15 de agosto de 1971 (BORDO; EICHENGREEN, 2007). Ainda que tenha acabado, os efeitos da Conferência de Bretton

Woods perduram até hoje, sendo que o dólar ainda continua sendo a moeda de referência mundial.

A utilização do dólar como referência monetária também atraiu a atenção de especuladores, pois no final do acordo de Bretton Woods, os Estados Unidos passaram por diversas instabilidades econômicas, enquanto que países da Europa ocidental começavam a recuperar a força de suas respectivas moedas. Isto fez com que os especuladores começassem a apostar contra o dólar. Neste cenário, começou a ocorrer a popularização do dólar como forma de investimento. Entre o período de 1981-1985, ocorreu um *boom* na demanda de investidores por dólares o que resultou na sua valorização, criando uma bolha especulativa em relação aos retornos esperados. O interesse do dólar como forma de investimento segue a premissa dos outros ativos, por considerar que o valor da moeda responde as informações contidas no mercado, e considerando que os investidores são racionais, esses irão enxergar oportunidades de ganhos decorrentes da oscilação de seu preço (FRANKEL;FROOT, 1991).

A formação do preço do dólar é complexa porque a taxa cambial de um país depende de políticas internas e externas. No contexto interno, o poder da moeda doméstica frente ao dólar depende de fatores relacionados ao balanço de pagamentos, nível de reservas internacionais, níveis de importação e exportação, por exemplo, que são variáveis que influenciam diretamente na demanda e oferta (ARNDT, 2013). Quando considerado o contexto externo, o valor do dólar depende principalmente das diretrizes econômicas dos Estados Unidos, como sua posição de investimento em bens estrangeiros, sua taxa de inflação, taxa de juros estabelecida pelo FED, PIB americano, entre outros fatores (BLACHARD; GIAVAZZI;SA,2005; WANG,2009).

Cabe destacar ainda que o interesse do dólar no mercado financeiro é derivado também de seu uso como *hedge* ao risco das oscilações cambiais. Com a adoção do sistema de câmbio flutuante nas economias desenvolvidas, o risco de variação cambial passou a fazer parte do cotidiano de grandes instituições, levando-as a investirem em instrumentos financeiros de gestão que consigam mitigar esse risco (JORION,2001).

2.2.6 Fundos de investimento imobiliário

A instrução 472 da CVM define fundos de investimentos imobiliários como uma comunhão de recursos captados e destinados à aplicação em empreendimentos imobiliários. Esses empreendimentos caracterizam-se pela geração de retorno, atrelada a performance da operação, que será obtido com base no imóvel, seja decorrente de aluguel com valor fixo ou para exploração de determinada atividade (ROCHA LIMA, 2001). A ABNT (2002) divide os investimentos de base imobiliária em sete categorias: [i] Imobiliários, ou com parcelamento do solo, ou com benfeitorias; [ii] com fins de exploração comercial e/ou de serviços; [iii] base industrial; [iv] base rural; [v] base comercial e serviços [vi] base mineral; [vii] base em concessões de serviços públicos.

Apesar das propriedades específicas de cada uma das categorias de ativos imobiliários, existem alguns fatores de riscos que são comuns ao setor como um todo. O primeiro risco a ser destacado é o de negócio, pois o preço relacionado ao retorno imobiliário é facilmente afetado por flutuações na atividade econômica, haja vista que tanto imóveis utilizados para aluguel como fins comerciais dependem do fator oferta e demanda do mercado. Outro risco comum é o da taxa de juros, haja vista que investimentos imobiliários costumam ter um elevado grau de alavancagem, o que afeta diretamente os ganhos dos investidores. O risco de liquidez também é típico do setor imobiliário, pois por depender do nível econômico, em épocas de recessão, o investidor perde poder de barganha (BRUGGEMAN; FISCHER, 2008).

A volatilidade de investimentos imobiliários é caracterizada pela existência de choques persistentes, agrupados e previsíveis. A variância condicional dos investimentos imobiliários é melhor explicada por variáveis macroeconômicas (inflação, PIB, prêmio risco, por exemplo) do que propriamente pelo comportamento de seus retornos, o que auxilia na explicação do porquê das características descritas (DEVANEY, 2001; COTTER & STEVENSON, 2006; JIRASAKULDECH; CAMPBELL; EMEKTER, 2007). Além da fundamentação econômica na formação dos preços imobiliários, também há o fator especulação, que recebeu maior atenção na crise de 2008. Em épocas de *booms*

econômicos, os preços dos imóveis estão expostos ao fator especulativo, dando origem a bolhas imobiliárias, evento derivado principalmente do amplo acesso ao crédito concedido pelos bancos (CROWE, 2013).

2.2.7 Fundo de Investimento

Fundo de investimento é um conjunto de recursos pertencentes a vários investidores utilizado para adquirir investimentos coletivos de forma que cada investidor retém uma cota do fundo proporcional a sua participação de capital (ARNOLD, 2012). A principal vantagem dos fundos consiste na oportunidade de diversificação, pois por ser um investimento coletivo permite que os investidores adquiram uma variedade de ativos, reduzindo sua exposição ao risco (BROWN; WILLIAM, 2003). Normalmente a performance de investimento dos fundos é atrelada a um *benchmark*, o que faz com que as restrições legais aplicadas ao fundo, como aquelas relacionadas as suas transações, alavancagem, risco e outros fatores dependam da estratégia de gerenciamento acordada (JANSEN, 1998).

Existem várias categorias de fundos, como por exemplo, os de renda variável, que investem somente em ações, renda fixa, que investem somente em títulos públicos ou privados e multimercado, que transacionam em diversos tipos de ativos financeiros. Sendo assim, o risco inerente ao fundo de investimento depende da categoria de ativos ao qual ele é direcionado. Basicamente, os fundos são classificados em três tipos de estratégias: Os de alto grau de risco, em que o objetivo é obter retorno acima do mercado, através de investimentos alavancados e de alto risco. Os de risco moderado, que geralmente têm suas aplicações concentradas em ativos de longo prazo. E por fim os de baixo risco, que são caracterizam-se por baixos retornos devido a estratégias conservadoras (SAUNDERS; CORNETT, 2003).

Entretanto um risco comum aos fundos de investimento que independe de sua estratégia corresponde ao risco de gerenciamento derivado do risco de falha humana nas operações e pelo conflito de interesses entre gestores de fundos. Como os fundos cobram taxa de performance, que é uma remuneração vinculada a rentabilidade do fundo, os

agentes internos tendem a agir em benefício próprio na efetuação das transações, o que pode aumentar o nível de risco além do estabelecido (MISHKIN; EAKINS, 2012). O risco de mercado também é característico desse tipo de investimento, haja vista que corresponde a um risco não diversificável. Entretanto, a exposição ao risco de mercado também depende da gestão, uma vez que é necessária a *expertise* da gestão para ajuste da posição da carteira para diferentes condições de mercado, seja em época de crise ou expansão (FABOZZI;FRANCIS, 1979). Um estudo realizado por Huang, Sialm e Zhang (2003), para os fundos de investimento americano, mostra que estes tendem a mudar sua volatilidade anual em uma média superior a 6%, justamente devido a resposta de ajuste da posição dos fundos por parte dos gestores.

2.3 Value at Risk e gestão de risco

A volatilidade dos mercados financeiros tem induzido reguladores, gestores e acadêmicos a desenvolverem ferramentas sofisticadas de mensuração de risco. Com a teoria da diversificação do portfólio, a volatilidade (desvio padrão) e a correlação tornaram-se métodos tradicionais de mensuração de risco, entretanto tais conceitos estatísticos são considerados limitados uma vez que só conseguem captar o risco com maior precisão para retornos que apresentam uma distribuição normal multivariada (ALEXANDER, 2009).

Como resposta às crises financeiras ocorridas anteriormente a década de 1990, surgiu o *Value at Risk (VaR)*, que possui um modelo matemático subjacente a teoria da diversificação de risco, porém criado com foco no risco de mercado e nos efeitos dos movimentos adversos em uma carteira de investimentos (DAMODARAN, 2008). O *VaR* se distingue de outras métricas por ter como objetivo descrever probabilisticamente as possíveis mudanças futuras no valor de um portfólio. É considerado como um mensurador de risco de queda, por medir a cauda esquerda de uma série financeira. Desta forma, o *VaR* é definido como a pior perda à um determinado nível de confiança dentro de um horizonte de tempo (CROUHY;GALAI;MARK, 2006).

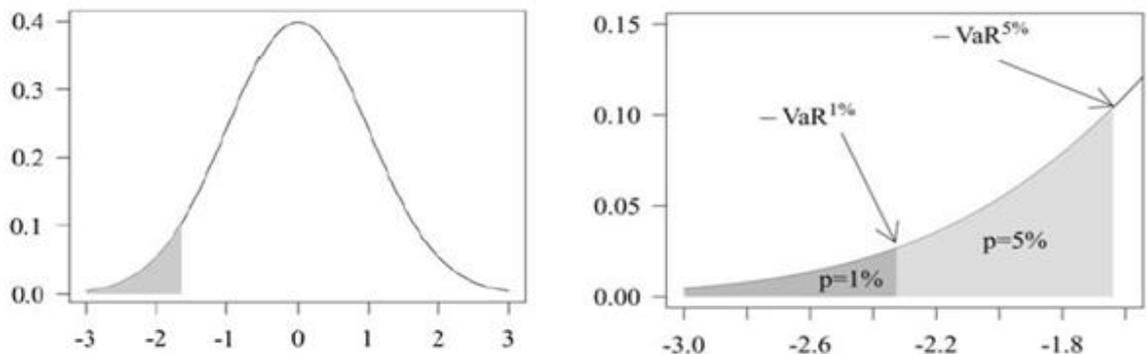
Matematicamente, Artzner et. Al. (1999) define o *VaR* como:

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

Em que α corresponde ao nível de confiança estabelecido e X o processo de retornos, admitindo $F(x) = \Pr(X_i \leq x_i)$.

O *VaR* apresenta três elementos cruciais em sua aplicação; O nível específico do valor da perda, o período fixo o qual o risco é mensurado e o intervalo de confiança. O *VaR* pode ser aplicado tanto individualmente para ativos como para portfólios (DAMADORAN, 2008). Embora inicialmente criado para mensurar o risco de mercado, o *VaR* ganhou expansões, tornando-se uma métrica universal, aplicada para uma variedade de setores e diversos tipos de risco (ALEXANDER, 2008) O *VaR* é utilizado por diferentes instituições que encontram-se expostas ao risco, seja financeiras ou não. A sua vantagem reside principalmente na criação de um denominador comum que permite a comparação de diferentes atividades de risco nos mais diversos tipos de mercados (JORION, 2007)

Figura 2: VaR da função densidade P/L e cauda esquerda do VaR a q%



Fonte: Danielsson (2001)

2.3.1 Diferentes formas de cálculo de *VaR*

A avaliação do *VaR* é mais complexa do que as formas tradicionais de avaliação de risco por depender da distribuição multivariada do fator risco dos retornos e de sua

dinâmica, assim como ocorre no mapeamento do risco de um portfólio (ALEXANDER, 2009). Considerando que o *VaR* depende de características estatísticas específicas tanto dos ativos quanto do mercado ao qual estão sendo negociados, foram desenvolvidas extensões da forma de seu cálculo, buscando melhorar a sua capacidade preditiva.

No contexto de alocação de investimentos, o desenvolvimento de diferentes formas de cálculo do *VaR* faz-se importante porque seu modelo tradicional não é subaditivo, o que pode resultar em uma diversificação ineficiente e dificultar a implementação de algoritmos de otimização de portfólio (MALEVERGNE; SORNETTE, 2004). A ausência de subaditividade é uma característica indesejável e incoerente por acarretar o seguinte fator: O *VaR* de uma combinação de dois portfólios pode ser maior do que a soma do *VaR* individual de cada portfólio (ROCKAFELLAR; URYASEV, 2000).

Duffie e Pan (1997) acrescentam que ainda que o *VaR* possa ser medido de forma precisa, ele está limitado ao horizonte específico e também ao intervalo de probabilidade estabelecido, não sendo apropriado que a empresa utilize o *VaR* como o nível oficial de capital necessário para a sustentação da exposição ao risco. Neste contexto, o *VaR* é tido como um *benchmark*, utilizado para realizar comparações entre risco de portfólios ou ativos isolados. Como resposta a esses tipos de fragilidade encontrados no *VaR* padrão, foram desenvolvidos novos métodos de seu cálculo, com o intuito de aprimorar a acurácia de estimação de perda máxima.

A principal diferença existente entre as métricas de *VaR* consiste na premissa utilizada acerca da distribuição dos retornos dos portfólios, uma vez que, para séries financeiras, é predominante a característica de não linearidade, de forma que a premissa usual de distribuição normal dos modelos paramétricos não é sustentada. Esse fator coloca em questionamento a capacidade preditiva do *VaR* normal, uma vez que o modelo não seria capaz de se ajustar aos choques dos retornos (FUSS; ADAMS; KAISER, 2009). Sendo assim, surgiram as categorias não paramétricas de *VaR*, em que não é feita nenhuma inferência sobre a distribuição dos retornos dos ativos. Essa métrica de *VaR* é representada pela abordagem da simulação histórica, em que são feitas simulações de cenários a partir da distribuição empírica dos retornos. Apesar de suas vantagens, assim como os modelos paramétricos do *VaR*, a abordagem da simulação histórica falha em prever perdas que

ocorrem em eventos catastróficos, que ultrapassam o horizonte de 99% de confiança (BARONE-ADESI; GIANNOPOULOS, 2001).

Considerando as particularidades das distintas linhas de abordagem de mensuração de perdas, diversos trabalhos têm sido elaborados com o objetivo de analisar a acurácia de modelos de cálculos de *VaR* para categorias de ativos diferentes. Daniélsson et. al. (2005), por exemplo, realizou um estudo com a finalidade de identificar para quais classes de ativos o *VaR* viola a subaditividade. Os autores encontraram evidências de que para a maioria dos ativos não há violação da subaditividade, havendo exceção para aqueles que apresentam distribuição com caudas grossas pesadas (elevado grau de assimetria ou curtose).

Posteriormente, Daniélsson et. al. (2013) realizam uma releitura de seu trabalho, incluindo o cálculo do *VaR* pelo método de simulação histórica de Monte Carlo. Pelo cálculo paramétrico, novamente foi encontrado que o *VaR* não viola a subaditividade para ativos com retornos multivariados. Entretanto, quando calculado pela simulação de Monte Carlo, houve indícios de que este método pode levar a violação de subaditividade dos ativos.

Além da subaditividade, outro questionamento refere-se à característica a distribuição assimétrica, com picos em torno da moda e das caudas, dos retornos dos ativos financeiros. Esse fator implica que a ocorrência de eventos extremos é mais usual do que a distribuição normal sugere. Desta forma, uma das críticas usuais as métricas tradicionais de *VaR* é que essas são insuficientes na estimação de perda máxima frente a períodos catastróficos (GUPTA et.al., 2016). A preocupação com os quantis da cauda e sua probabilidade é de interesse comum no âmbito do mercado financeiro devido as informações que permitem a gestão de riscos extremos associados a rupturas econômicas, *crashes* e *default* de títulos de renda fixa, por exemplo (DIEBOLD, SCHUERMANN, 2000).

A partir dessa preocupação, o modelo *Expected Shortfall* (ES), conhecido também como *VaR* condicional, tem sido preferido ao *VaR* por muitos gestores de risco, tendo em vista que ele se baseia nas informações concentradas na cauda e não na distribuição inteira. (McNEIL, FREY, EMBRECHTS, 2015). O ES considera a perda que excede o *VaR*, além de demonstrar ser um método sub-aditivo, uma vez que permite facilmente a

decomposição dos fatores de risco (YAMAI; YOSHIBA, 2002). Outro método alternativo são os modelos de *VaR* baseados na teoria dos valores extremos (EVT), e que também consideram as informações contidas na cauda esquerda para estimação da perda máxima.

Desta forma, a escolha do modelo apropriado do *VaR* depende de propriedades específicas dos dados financeiros a serem analisados. Há de se considerar também que estes ativos possuem variáveis diferentes para a formação de seus respectivos preços, além de responderem de forma distinta às oscilações que ocorrem no mercado financeiro. Sendo assim, faz-se necessário o conhecimento das particularidades das diferentes categorias de instrumentos financeiros.

2.4 Fundamentação teórica das hipóteses de pesquisa

O presente trabalho tem como objetivo testar a acurácia de diferentes modelos de estimação de perdas para classes de ativos distintas. Para atender ao objetivo, foram escolhidos modelos que abordam diferentes premissas e perspectivas teóricas em relação à forma de distribuição de *VaR*. Sendo assim, foram construídas seis hipóteses de pesquisa que servirão de referência para a realização de testes empíricos, destacando as características e fundamentações específicas dos modelos de pesquisa.

2.4.1 Média móvel exponencialmente ponderada (EWMA)

O modelo EWMA representa uma técnica clássica de cálculo do *VaR*, haja vista que consiste em uma das formas mais simples de se modelar a variância dos ativos. Resumidamente, o método consiste em dar um peso maior as últimas observações referentes ao histórico do ativo, uma vez que essas irão carregar as informações mais importantes relacionadas ao risco. Este modelo apresenta duas vantagens principais: primeiramente, a volatilidade reage de forma mais rápida aos choques ocorridos no mercado, considerando que os dados recentes têm maior peso do que aqueles que estão em um passado mais distante. Segundo fator é que após o choque no retorno, a volatilidade cai

de forma exponencial à medida que a observação correspondente ao choque se afasta do presente (LONGERSTAEY, 1996).

Por essa razão, a estimação pelo método EWMA não é afetada pelos “fantasmas do passado” que se encontram nos modelos de média igualmente ponderada. O modelo EWMA permite que o contexto atual do mercado seja incorporado na modelagem do risco do ativo (ALEXANDER, 2008). Com base nessas considerações é formulada a seguinte hipótese de pesquisa:

H₁: Com base no teste de Kupiec e no teste de independência, o modelo EWMA é capaz de estimar com acurácia o VaR do ativo.

2.4.2 Delta normal

O modelo linear, chamado de delta normal, baseia-se na distribuição paramétrica dos retornos, assumindo que o valor de um portfólio é uma função linear dos fatores de risco inerentes a ele. A essência do modelo consiste em assumir a premissa de que os retornos de um portfólio são independentes e identicamente distribuídos. As dependências existentes entre os fatores de risco são representadas pela correlação, que são agrupadas com a variância de cada fator de risco durante um horizonte futuro de risco, formando a matriz de covariância diária. É esta matriz que conduz o modelo paramétrico e de onde se obtém a probabilidade de distribuição dos valores do portfólio (ALEXANDER, 2008).

O método linear é uma das formas mais simples de cálculo, tendo como vantagem a possibilidade de estimação do *VaR* ainda quando se têm restrições de programação computacional. Além disso, o modelo serve como ponto de partida para o desenvolvimento de outros métodos de estimação, haja vista que se faz necessário entender as vantagens e desvantagens do delta linear para compreender esses mesmos fatores em modelos mais complexos (CHOUDHRY, 2013). Com base nesse contexto, é elaborada a seguinte hipótese de pesquisa:

H₂: Com base no teste de Kupiec e no teste de independência, o modelo Delta normal é capaz de estimar com acurácia o VaR do ativo.

2.4.3 Simulação histórica

A simulação histórica é um dos métodos de *VaR* mais utilizados devido a vantagem de não realizar nenhuma suposição sobre a forma paramétrica da distribuição do retorno dos ativos, pois seus respectivos comportamentos e fatores de risco são inferidos diretamente das observações históricas. Considerando esta característica, percebe-se que o maior benefício deste modelo é a abrangência de sua aplicação por não restringir-se apenas a portfólios lineares (ALEXANDER, 2009).

O modelo tem como vantagem a sua fácil implementação, além disso, reduz a mensuração de estimação do risco a um problema unidimensional; nenhuma estimação estatística da distribuição multivariada X é necessária, não sendo feita nenhuma premissa acerca da estrutura de dependência das mudanças dos fatores de risco. Entretanto por utilizar informações contidas nos quantis da amostra, é necessário que essa possua um número suficiente de observações como forma de melhorar a acurácia de cálculo do modelo (MCNEIL, FREY, EMBRECHTS, 2015). Desta forma, é elaborada a seguinte hipótese de pesquisa:

H₃: Com base no teste de Kupiec e no teste de independência, o modelo de simulação histórica é capaz de estimar com acurácia o VaR do ativo.

2.4.4 GARCH

As series temporais financeiras podem exibir o fenômeno de aglomeração de volatilidade, isto é, períodos em que seus preços apresentam grandes oscilações por um longo horizonte de tempo. O modelo de heterocedasticidade condicional autor-regressiva (ARCH), desenvolvido por Engle (1982), surgiu desta necessidade de considerar as oscilações ocorridas na volatilidade. Como o próprio nome sugere, a heterocedasticidade observada ao longo de diferentes períodos pode ser autocorrelacionada (GUJARATI; PORTER, 2011).

Desde o nascimento do ARCH, sua modelagem passou por diversas transformações em relação a sua forma original, sendo a mais conhecida o modelo de heterocedasticidade condicional auto-regressiva generalizada (GARCH), proposto por Bollerslev (1986). O modelo GARCH é capaz de capturar diversas propriedades de séries financeiras ao levar em consideração suas três principais características: caudas grossas, agrupamento de volatilidade e dependência não linear. O modelo é visto como um aprimoramento do EWMA ao levar em consideração mais de um parâmetro na composição da volatilidade, o que permite especificações mais completas e dinâmicas que outros métodos paramétricos (DANIELSSON, 2011). Com base nessas considerações, a quarta hipótese de pesquisa assume que:

H₄: Com base no teste de Kupiec e no teste de independência, o modelo de simulação histórica é capaz de estimar com acurácia o VaR do ativo.

2.4.5 Expected Shortfall (ES)

O *Expected Shortfall* (ES), surgiu para fornecer mais informações acerca do formato da cauda com o intuito de mensurar qual a perda esperada que excede o *VaR*. Atualmente o método é defendido por suprir a fragilidade de subaditividade dos modelos tradicionais de *VaR*. Por subaditividade entende-se que o *VaR* de uma combinação de variáveis aleatórias pode ser superior a soma do *VaR* de cada uma delas. Desta forma, uma carteira de ativos é mensurada com um risco inferior do que a soma dos riscos desses ativos individuais, o que levanta o questionamento de eficácia do *VaR* (ACERBI; NORDIO; SITORI, 2001; DANIELSSON, 2011).

O objetivo do ES é responder a pergunta: Qual a perda esperada quando essa perda excede o *VaR*? Assumindo-se que a distribuição de um portfólio é contínua, a resposta a essa pergunta é dada pelo valor esperado condicional que se encontra abaixo ao quantil associado à probabilidade *p*. Conseqüentemente o ES consegue diferenciar os níveis de risco inerentes a um ativo, por levar em consideração a forma da cauda da distribuição,

diferentemente dos *VaR* tradicionais (DANIELSSON, 2011). Com base nessas considerações, é formulada a seguinte hipótese de pesquisa:

H₅: Com base no teste de Kupiec e no teste de independência, o modelo expected shortfall é capaz de estimar com acurácia a perda do ativo.

2.4.6 Simulação de Monte Carlo

O método de Monte Carlo (MC) é um nome generalizado para qualquer abordagem de mensuração de risco que envolve a simulação de um modelo paramétrico explícito para oscilações nos fatores de risco. No que se refere ao uso da simulação para estimação do *VaR*, o modelo de Monte Carlo é similar a simulação histórica, se diferenciando pelos movimentos das variáveis de risco que são gerados pelo esboço de alguma distribuição de probabilidade (JORION,2003).

É feita uma simulação das perdas, com o intuito de se obter a sua distribuição e, a partir dela, se mensurar o risco estimado. O método é mais flexível que a simulação histórica por permitir a escolha do número de replicações necessárias, sendo comum que este número seja superior ao da amostra o que permite o cálculo do *VaR* com maior precisão (McNEIL; FREY; EMBRECHTS, 2015). A ideia por trás das simulações é de replicar os resultados do mercado em programações computacionais, com base em algum modelo da evolução de mercado. Ao se realizar essas simulações, obtém-se uma grande amostra que permite calcular com maior robustez a perda do ativo. Dessa forma, ao se observar uma amostra suficientemente grande do processo estatístico, é possível chegar a um número que é aproximadamente igual à expectativa matemática do risco (DANIELSSON, 2011).

A fragilidade desse método é que os resultados são limitados a qualidade do modelo de *VaR* aplicado. É demandado que os usuários façam suposições sobre o processo estocástico e compreendam a sensibilidade dos resultados a estas suposições (JORION, 2013). Com base nessas premissas, é feita a seguinte hipótese:

H₆: Com base no teste de Kupiec e no teste de independência, o modelo de Monte Carlo é capaz de estimar com acurácia a perda do ativo.

3.0 METODOLOGIA

A metodologia de pesquisa a ser utilizada no presente trabalho pode ser esquematicamente representada da seguinte forma:

1. Identificar o problema de pesquisa
2. Definir os objetivos de pesquisa
3. Formular as hipóteses
4. Definir a seleção de amostra
5. Aplicar as metodologias do modelo de *VaR*
6. Testar o desempenho dos métodos de cálculo utilizando os índices de violação
7. Testar a significância estatística dos resultados encontrados pelo teste de Kupiec e de Independência de violações.
8. Descrever os resultados encontrados

3.1 Amostra

O período amostral da pesquisa tem início em janeiro de 1997 e final em janeiro de 2017, total de 20 anos. Para ativos com início de negociação posterior a 1997, o primeiro dia de negociação foi tido como o início do período amostral. Os ativos selecionados para a amostra representam as seguintes categorias: Ações, debêntures, títulos públicos, câmbio, *commodities*, *fundo* imobiliário e fundo de investimento. O critério de seleção dos representantes dessas classes foi o de liquidez e representatividade no mercado de capitais. A tabela abaixo apresenta uma breve descrição dos ativos da pesquisa:

Tabela 1: Amostra da pesquisa

Ativo	Período	Descrição	Fonte
Índice de Ações Ibovespa	1997-2016 (frequência diária)	Carteira teórica utilizada como indicador de desempenho médio das ações de maior negociabilidade no mercado brasileiro.	Economática
Dólar	1997-2016 (frequência diária)	Cotação dólar / real	Economática
Índice de Debêntures (ANBIMA) (IDA)	2009-2016 (frequência diária)	Carteira teórica de debêntures a preços de mercado utilizado como parâmetro no segmento.	Economática
IMA-B	1997-2016 (frequência diária)	Carteira teórica de títulos públicos, dividida em quatro subíndices: Prefixados, indexados a IPCA e IGP-M e pós-fixados indexados a SELIC	Economática
Índice de <i>Commodities</i> Brasil (ICB)	1997-2016 (frequência diária)	Carteira teórica de <i>commodities</i> com preço a vista.	Reuters
Índice de fundos de investimento imobiliário (IFIX)	(2011-2016) (frequência diária)	Carteira teórica composta pelos fundos imobiliários negociados na bolsa e mercado de balcão.	Economática
LP 200	1997-2016 (frequência diária)	Fundo multimercado com aplicações em cotas de fundo de investimentos.	Economática

Fonte: Elaboração própria

O Ibovespa foi escolhido como *proxy* do mercado acionário por ser o indicador de performance dos ativos de maior negociabilidade do mercado de ações brasileiro. O Índice de Mercado ANBIMA (IMA) foi selecionado como *proxy* do desempenho dos títulos de renda fixa. O IDA representa uma carteira teórica dos títulos de renda fixa privados que têm como indexadores o DI e o IPCA. As debêntures indexadas a IPCA são divididas em dois segmentos: investimentos destinados a infraestrutura e ex-infraestrutura, que são as demais classes de investimentos. O IMA-B corresponde a uma família de índices de renda fixa que representam a dívida pública por meio de preços a mercado de uma carteira de títulos públicos federais. O dólar foi escolhido como *proxy* da categoria câmbio por ser a moeda estrangeira de maior negociabilidade e representatividade.

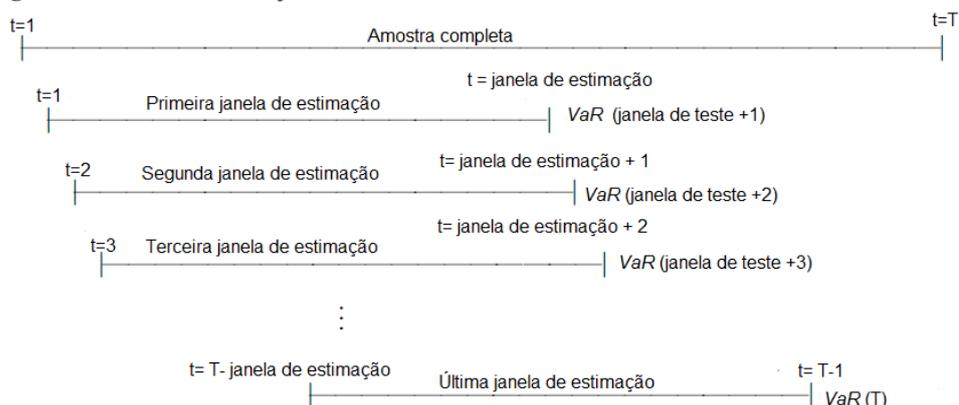
O Índice de Commodities Brasil (ICB) representa a *proxy* da categoria *commodities*. O ICB corresponde a uma carteira teórica de *commodities*, com preço a vista, baseada no ajuste diário dos contratos futuros da BM&FBOVESPA. Possui como critério de participação a liquidez da *commodity* dentro do total de *commodities* negociadas na bolsa. O Índice de Fundos Imobiliários (IFIX) foi escolhido como representante da categoria de ativos do setor imobiliário, por ser tido como o indicador de desempenho médio dos fundos imobiliários com negociações diárias listados na BOVESPA e mercado de balcão.

O fundo LP 200 foi escolhido como uma *proxy* dos fundos de investimentos, uma vez que consiste em um fundo multimercado com aplicações em cotas de outros fundos compostos por títulos públicos federais, títulos privados, operações compromissadas, contratos de câmbio, investimentos imobiliários, derivativos e ações de empresas brasileiras. O fundo é classificado como um investimento de risco moderado. Há de ressaltar que o ativo de maior peso no fundo corresponde a fundos aplicados em LFT, seguidos por fundos aplicados em operações compromissadas, ambos com mais de 30% de participação.

3.2 Formação das janelas para o cálculo do *VaR*

Para analisar a acurácia de um modelo de *VaR* é feito o *backtesting*, que consiste em um procedimento comumente utilizado para monitorar a performance de um método de previsão de *VaR* e posteriormente compará-lo com outras metodologias de cálculo (MCNEIL, FREY, EMBRECHTS, 2015). Para execução do *backtesting* faz-se necessária à criação de duas janelas: Janela de estimação e Janela de teste. A janela de estimação corresponde ao número de observações utilizado para prever a perda, enquanto que a janela de teste consiste na amostra posterior a previsão da perda, ou seja, o dia o qual o *VaR* é calculado (DANIELSSON, 2011). A figura abaixo apresenta o processo de montagem das janelas:

Figura 3: Janela de estimação



Adaptação: Danielsson (2011)

A escolha do tamanho da janela de estimação é um fator crucial para a robustez do *backtesting*, uma vez que é necessário que seja um período suficientemente longo para acomodar as particularidades e exigências dos métodos de *VaR*. Para atender aos critérios dos modelos utilizados no presente trabalho, foi determinada uma janela de estimação com um período de 1000 dias, correspondente a aproximadamente 4 anos. A janela de teste se move a cada um dia, acrescentando $t+1$ e retirando $t-1000$. Desta forma, caso a perda do dia corrente da janela de teste exceder a perda prevista pelo modelo de *VaR*, então é constatado que o limite do *VaR* foi violado.

3.3 Estimação do *VaR*

3.3.1 Cálculo de retorno dos ativos

Devido a um conjunto de fatores estatísticos e as particularidades de precificação das diferentes classes de ativos da amostra, o retorno diário será utilizado como a variável de estimação dos modelos de *VaR*. Dessa forma, o *VaR* irá estimar o pior retorno que se pode obter na janela de teste a uma probabilidade de 1%.

Assumindo que os retornos são contínuos, seu cálculo é realizado da seguinte forma:

$$Y_t = \ln\left(\frac{p_t}{p_{t-1}}\right) \quad (2)$$

Em que p_t corresponde ao valor do ativo p em t e p_{t-1} ao valor do ativo p em $t - 1$.

3.3.2 VaR paramétrico – Delta normal

O modelo Delta normal assume que os retornos diários de um ativo são normalmente distribuídos. Sendo assim, a distribuição do retorno do ativo Y apresenta a seguinte forma (JORION,2007):

$$Y^{i.i.d.} \sim N(\mu, \sigma^2)$$

Ao derivar a fórmula, y_α corresponde ao quantil do retorno α tal que $P(Y < y_\alpha) = \alpha$. Usando a transformação normal padrão, tem-se:

$$P(Y < y_\alpha) = P\left(\frac{Y - \mu}{\sigma} < \frac{y_\alpha - \mu}{\sigma}\right) = P\left(Z < \frac{y_\alpha - \mu}{\sigma}\right) \quad (3)$$

Onde $Z \sim N(0,1)$. Se $P(Y < y_\alpha) = \alpha$, então:

$$P\left(Z < \frac{y_\alpha - \mu}{\sigma}\right) = \alpha \quad (4)$$

Por definição $P(Z < \phi^{-1}(\alpha)) = \alpha$, logo:

$$\frac{y_\alpha - \mu}{\sigma} = \phi^{-1}(\alpha) \quad (5)$$

Em que ϕ é a função da distribuição normal. O *VaR* nada mais é do que $-y_\alpha$ e pela definição de uma distribuição simétrica $\phi^{-1}(\alpha) = \phi^{-1}(1-\alpha)$. Substituindo essa definição na equação 5, é obtida uma fórmula analítica do *VaR* de um ativo com distribuição normal:

$$VaR = \phi^{-1}(1-\alpha)\sigma - \mu \quad (6)$$

Em que o ativo possui retorno médio igual a μ e desvio padrão igual a σ . Como o *drift* μ é utilizado para o ajuste de cálculo de *VaR* para longos horizontes de tempo, a fórmula do *VaR* diário é reduzida à:

$$VaR = \phi^{-1}(1-\alpha)\sigma \quad (7)$$

3.3.3 *VaR* paramétrico – Média móvel exponencialmente ponderada (EWMA)

O EWMA coloca maior peso nas observações recentes para a estimação da volatilidade. Desta forma, os retornos extremos se movem para o passado, tornando-se cada vez menos importantes à medida que a janela de observação se movimenta para o futuro. Supondo que na data t os dados são registrados no período $t - 1$. O modelo EWMA desta observação pode ser definido por (DANIELSSON, 2011):

$$EWMA(x_{t-1}, \dots, x_1 | \lambda) = \frac{x_{t-1} + \lambda x_{t-2} + \lambda^2 x_{t-3} + \lambda^3 x_{t-4} + \dots + \lambda^{t-1} x_1}{1 + \lambda + \lambda^2 + \dots + \lambda^{t-1}} \quad (8)$$

Em que λ é uma constante $0 < \lambda < 1$ denominada de parâmetro de decaimento. Uma vez que $\lambda^n \rightarrow 0$ como $n \rightarrow \infty$, o modelo EMWA atribui pesos insignificantes as observações mais afastadas. Sendo assim:

$$1 + \lambda + \lambda^2 + \dots = (1 - \lambda)^{-1} \quad (9)$$

Para amostras grandes, tem-se:

$$EWMA(x_{t-1}, \dots, x_1 | \lambda) \approx \frac{x_{t-1} + \lambda x_{t-2} + \lambda^2 x_{t-2} + \lambda^2 x_{t-3} + \lambda^2 x_{t-3} + \dots + \lambda^{t-2} x_1}{1 + \lambda + \lambda^2 + \dots + \lambda^{t-2}} =$$

$$(1 - \lambda) \sum_{i=1}^{\infty} \lambda^{i-1} x_{t-i} \quad (10)$$

Essa fórmula pode ser utilizada para o cálculo de estimação EWMA da variância, em que x representa o retorno ao quadrado:

$$\sigma^2 = (1 - \lambda) \sum_{i=1}^{\infty} \lambda^{i-1} r_{t-i}^2 \quad (11)$$

A partir da variância estimada pelo EWMA, o VaR é calculado com o uso da seguinte fórmula:

$$VaR = \phi^{-1}(1 - \alpha) \sigma \sqrt{h} \quad (12)$$

Em que h corresponde ao horizonte de estimação de interesse, e $\phi^{-1}(1 - \alpha)$ é a função da distribuição normal padrão do quantil $1 - \alpha$.

3.3.4 VaR paramétrico – GARCH

A família de modelos GARCH permite especificações robustas em relação às propriedades das volatilidades dos ativos, o que simultaneamente enriquece a estimação dos parâmetros dos modelos de risco (DANIELSSON, 2011). O modelo GARCH (L_1, L_2) é dado por:

$$\sigma_t^2 = \omega + \sum_{i=1}^{L_1} \alpha_i Y_{t-i}^2 + \sum_{j=1}^{L_2} \beta_j \sigma_{t-j}^2 \quad (13)$$

Em que L representa o número de *lags*, Y o retorno do ativo, σ a volatilidade e $\omega, \alpha_i, \beta_j$ correspondem aos parâmetros da equação, estimados pelo modelo de máxima verossimilhança. Dado o objetivo do trabalho de prever as propriedades estatísticas dos retornos com base nas informações previstas em $t - 1$, foi utilizado o GARCH (1,1):

$$\sigma_t^2 = \omega + \alpha Y_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (14)$$

A distribuição mais comum no modelo GARCH é a normal em que os choques de Z_t seguem a distribuição:

$$Z_t \sim N(0,1) \quad (15)$$

Então os retornos do ativo são dados por $Y_t \sim N(0, \sigma_t^2)$. Este modelo é denominado de GARCH normal. Feita a estimação da volatilidade pelo GARCH (1,1), o *VaR* é calculado com o uso da seguinte função:

$$VaR = Z_p \times \sigma_t \quad (16)$$

3.3.5 *VaR* não paramétrico - Simulação histórica

O cálculo do *VaR* pela simulação histórica pode ser feito da seguinte forma: O tempo corrente é definido como t , observando o intervalo de dados de 1 para t . O valor do portfólio corrente é P_t , em que a função dos fatores de risco em t é dada por:

$$P_t = P[f_1, f_{2,t}, \dots, f_{N,t}] \quad (17)$$

Os movimentos da amostra da distribuição histórica, sem substituição são dados por:

$$\Delta f_i^k = \{\Delta f_{i,1}, \Delta f_{i,2} \dots \Delta f_{i,t}\} \quad (18)$$

A partir deste ponto, podem ser construídos valores hipotéticos, começando por um dado atual:

$$f_i^k = f_{i,t} + \Delta f_i^k \quad (19)$$

Os valores hipotéticos podem ser usados para a construção de um valor hipotético do portfólio, considerando o novo cenário, utilizando a equação:

$$P^k = P[f_1^k, f_2^k \dots, f_N^k] \quad (20)$$

Agora podem ser calculadas as mudanças nos valores do portfólio de uma posição atual $R^k = (P^k - P_t)/P_t$. Os retornos t são ordenados e é escolhido aquele que corresponde ao *quantil* c^{th} , $R_p(c)$. O VAR é obtido pela diferença entre a média e o *quantil*:

$$VAR = AVE[R_p] - R_p(c) \quad (21)$$

3.3.6 VaR paramétrico - Simulação de Monte Carlo

A abordagem da simulação de Monte Carlo é um método paramétrico que gera movimentos aleatórios nos fatores de risco a partir da estimação de distribuições paramétricas. A etapa mais importante da simulação consiste em escolher um modelo estocástico adequado para o comportamento dos preços. Comumente utiliza-se o movimento geométrico browniano por assumir que as inovações relacionadas aos preços dos ativos são não correlacionadas ao longo do tempo e que pequenas oscilações podem ser expressas por:

$$dS_t = \mu_t S_t dt + \sigma_t S_t dz \quad (22)$$

Em que dz é uma variável aleatória com distribuição normal, média zero e variância dt . É browniano no aspecto de que a variância reduz continuamente com o horizonte de tempo $V(dz) = dt$. O processo também é geométrico uma vez que os parâmetros são escalados pelo preço corrente S_t . Os parâmetros μ_t e σ_t representam respectivamente o *drift* e a volatilidade no tempo t (JORION, 2007).

Na prática, um processo com incrementos de dt mínimos pode ser aproximados de movimentos discretos de tamanho Δt . Define-se t como o tempo presente, T como o tempo alvo e $\tau = T - t$ como o horizonte. Para gerar a série de variáveis aleatórias S_{t+1} durante o intervalo τ , inicialmente corta-se τ em n incrementos, com $\Delta t = \frac{\tau}{n}$ (JORION, 2007).

Integrando dS/S sobre um intervalo finito de tempo, tem-se aproximadamente:

$$\Delta S_t = S_{t-1}(\mu\Delta t + \sigma\epsilon\sqrt{\Delta t}) \quad (23)$$

Em que ϵ corresponde a uma variável aleatória normal com média zero e variância unitária. Para simular o direcionamento do preço de S , inicia-se de S_t , gerando uma sequência de ϵ 's para $i = 1, 2, \dots, n$. Então S_{t+1} é definido em $S_{t+1} = S_t + S_t(\mu\Delta t + \sigma\epsilon_1\sqrt{\Delta t})$. Este processo é repetido até que o horizonte visado seja atingido, no ponto em que $S_{t+n} = S_T$.

Para estimação do *VaR*, calcula-se o valor do portfólio $F_{t+n} = F_T$ sob a sequência de preços S_t no horizonte visado. Esse processo dá origem a distribuição F_T^1, \dots, F_T^n . As observações são ordenadas e tabuladas, de forma a obter o valor esperado $E(F_T)$ e os quantis $Q(F_T, c)$, que corresponde ao valor excedente em c vezes para n replicações. O *VaR* então é obtido por:

$$VaR(c, T) = E(F_t) - Q(F_t, c) \quad (24)$$

3.3.7 Expected shortfall

Assumindo que a distribuição de um ativo é contínua, o *ES* estima o valor excedente abaixo do quantil associado a probabilidade p (DANIELSSON, 2011). A função matemática da perda esperada do ativo Y é dada por:

$$E(Y) = \int_{-\infty}^{\infty} yf(y)dy \quad (25)$$

Entretanto para o cálculo do *VaR*, a função deve ser adaptada, uma vez que a expectativa não varia de $-\infty$ a ∞ , mas sim de $-\infty$ a $-VaR(p)$. A área abaixo de $f_q(\cdot)$ no intervalo de $[-\infty, -VaR(p)]$ é menor do que um, o que implica que $f_q(\cdot)$ não é função adequada da densidade para este caso. Sendo assim, define-se uma nova densidade $f_{VaR}(\cdot)$ pelo ajuste positivo de $f_q(\cdot)$, de forma que a área acima deste valor se torna unitária (DANIELSSON, 2011). Para identificar a distribuição densidade correta, aplica-se:

$$p = \int_{-\infty}^{-VaR(p)} yf(y)dy \quad (26)$$

Então a função densidade da cauda de $f_{VaR}(\cdot)$ é dada por:

$$1 = \int_{-\infty}^{-VaR(p)} f_{VaR}(y)dy = \frac{1}{p} \int_{-\infty}^{-VaR(p)} f_q(y)dy \quad (27)$$

O *CVaR* é dado pelo valor negativo da razão entre o lucro e a perda sobre a densidade da cauda de $f_{VaR}(\cdot)$

$$CVaR = \int_{-\infty}^{-VaR(p)} f_{VaR}(y)dy \quad (28)$$

3.4 Índice de violação

O índice de violação (VR) é uma forma usual de verificar a adequação e realizar a comparação de métodos de estimação de risco distintos. Simplificadamente, o VR mensura se o retorno corrente de um dia específico excede o *VaR* estimado com base na janela de estimação. As violações são representadas por n_t , que assume o valor igual a 1 quando a violação ocorre e igual a 0 caso contrário. O número de dias com violações é coletado na variável v_1 , enquanto que v_0 corresponde ao número de dias sem violações.

$$n_t = \begin{cases} 1 & \text{se } y_t \leq -VaR \\ 0 & \text{se } y_t > -VaR \end{cases} \quad (29)$$

$$v_1 = \sum n_t \quad (30)$$

$$v_0 = \text{janela de teste} - v_1 \quad (31)$$

Dessa forma, o VR é obtido pela seguinte expressão:

$$VR = \frac{\text{número de violações observadas}}{\text{número esperado de violações}} = \frac{v_1}{p \times \text{janela de teste}} \quad (32)$$

Como regra geral, tem-se que um *VaR* com $VR \in [0.8, 1.2]$ possui uma boa estimação, enquanto que para $VR < 0.5$ ou $VR > 1.5$ indica um modelo impreciso, uma vez que o primeiro superestima em excesso o risco, enquanto que o segundo o subestima (DANIELSSON, 2011).

3.5 Teste de significância dos modelos

Para complementação e formalização estatística do desempenho dos modelos de *VaR* é feito o *backtest*, um procedimento utilizado com a finalidade de averiguar a eficácia de estimação das perdas máximas. Grande parte dos *backtests* de *VaR* assume que os retornos diários de um ativo são gerados por um processo de *Bernoulli*. Resumidamente, quando uma violação ocorre, η assume o valor 1, que indica uma “fracasso” na estimação. Caso contrário, η assume o valor igual a 0, que indica “sucesso” (ALEXANDER, 2009).

O teste de Kupiec é aplicado para analisar a proporção de violações. A hipótese nula para as violações do *VaR* é:

$$H_0: \eta \sim B(p) \quad (33)$$

Em que B representa a distribuição Bernoulli. A densidade Bernoulli é dada por:

$$(1 - p)^{1-\eta_t} (p)^{\eta_t}, \eta_t = 0, 1 \quad (34)$$

A probabilidade p pode ser estimada pela razão entre os dias de violação e o tamanho total da janela, representada por:

$$\hat{p} = \frac{v_1}{W_t} \quad (35)$$

A função de máxima verossimilhança é dada por:

$$l_U(\hat{p}) = \prod_{t=W_e}^T (1 - \hat{p})^{1-\eta_t} (\hat{p})^{\eta_t} = (1 - \hat{p})^{v_0} (\hat{p})^{v_1} \quad (36)$$

Essa expressão é tida como função irrestrita de máxima verossimilhança por utilizar o estimador de probabilidade \hat{p} . Sob H_0 , $\hat{p} = p$, então a função restrita é representada por:

$$l_R(\hat{p}) = \prod_{t=W_e}^T (1-p)^{1-\eta_t} (p)^{\eta_t} = (1-p)^{v_0} (p)^{v_1} \quad (37)$$

O teste de máxima verossimilhança é aplicado então para identificar onde $l_U = l_R$. Por ser não paramétrico, o *Bernoulli coverage test* fornece um bom *benchmark* para testar a precisão do *VaR*, entretanto, conforme estabelecido pelo Comitê de Basileia, o teste não pode ser aplicado para amostras pequenas, como de um ano, por exemplo. É comum utilizar para o teste de Kupiec o nível de significância de 5%, de forma que, para $LR > 3.84$, a hipótese nula é rejeitada. Entretanto, para uma análise mais completa, neste trabalho o *p-value* foi calculado diretamente.

Adicionalmente, também é feito o teste de independência das violações, elaborado por Christoffersen (1998). Esse teste possui a vantagem de identificar onde as violações se acumulam, indicando uma sequência de perdas, uma vez que as violações deveriam se espalhar ao longo do tempo. A essência do teste consiste em assumir que a violação observada em um determinado dia não contém informações da violação que pode ser observada no dia posterior (DANIELSSON, 2011).

Para realização do teste, inicialmente, calcula-se a probabilidade de duas violações consecutivas e a probabilidade de violação caso não tenha ocorrido violação no dia anterior. De forma geral, a probabilidade é dada por:

$$p_{ij} = \Pr(\eta_t = i | \eta_{t-1} = j) \quad (38)$$

Em que i e j corresponde a 0 ou 1. A matriz de probabilidade de transição é definida por:

$$\Pi = \begin{pmatrix} 1 - p_{01} & p_{01} \\ 1 - p_{11} & p_{11} \end{pmatrix} \quad (39)$$

A função de máxima verossimilhança restrita é dada por:

$$l_R(\Pi_1) = (1 - p_{01})^{v_{00}} p_{01}^{v_{01}} (1 - p_{11})^{v_{10}} p_{11}^{v_{11}} \quad (40)$$

Em que v_{ij} é o número de observações em que j segue i . A função de máxima verossimilhança é estimada maximizando-se $l_R(\Pi_0)$:

$$\Pi = \begin{pmatrix} \frac{v_{00}}{v_{00} + v_{11}} & \frac{v_{01}}{v_{00} + v_{11}} \\ \frac{v_{10}}{v_{10} + v_{11}} & \frac{v_{11}}{v_{10} + v_{11}} \end{pmatrix} \quad (41)$$

Sob a hipótese nula de não agrupamento, a probabilidade da violação do dia posterior não depende da do dia corrente, então $p_{01} = p_{11} = p$ e a matriz de transição estimada é:

$$\Pi_1 = \begin{pmatrix} 1 - \hat{p} & \hat{p} \\ 1 - \hat{p} & \hat{p} \end{pmatrix} \quad (42)$$

Onde

$$\hat{p} = \frac{v_{01} + v_{11}}{v_{00} + v_{10} + v_{01} + v_{11}} \quad (43)$$

De acordo com H_0 a função de máxima verossimilhança irrestrita utiliza a matriz de restrição e é igual a:

$$l_U(\Pi_0) = (1 - \hat{p})^{v_{00} + v_{10}} \hat{p}^{v_{01} + v_{11}} \quad (44)$$

O teste de relação de verossimilhança é então implementado com:

$$LR = 2(\log l_U(\Pi_0) - \log l_R(\Pi_1)) \sim \chi^2 \quad (45)$$

O índice de violação para o *CVaR* possui uma modificação em relação aos outros modelos no aspecto de que o que está sendo testado é um quantil específico. De forma análoga aos demais modelos, o índice de violação para caudas é dado por:

$$NS_t = \frac{y_t}{ES_t} \quad (46)$$

Em que *ES* corresponde ao excedente observado no dia *t*. Pela definição do *ES*, o valor esperado de y_t , dado que o *VaR* foi violado, é de:

$$\frac{E[Y_t | Y_t < -VaR_t]}{ES_t} = 1 \quad (47)$$

A média de *NS* denotada por \overline{NS} deveria ser igual a um, dando forma à H_0 :

$$H_0: \overline{NS} = 1 \quad (48)$$

4.0 ANÁLISE DE RESULTADOS

4.1 Estatística descritiva dos dados

Conforme descrito no referencial teórico, um dos fatores determinantes de acurácia do modelo de estimação do *VaR* é o comportamento estatístico das séries financeiras. Dessa forma, como suporte para interpretação da análise de resultados, faz-se necessário, inicialmente, compreender a dinâmica dos retornos dos ativos da pesquisa, o que será feito nessa seção. Ressalta-se que os períodos dos ativos, embora tenham inícios distintos, englobam tanto expansões como retrações vivenciadas pela economia brasileira.

Além do cálculo das principais medidas estatísticas, também foi executado o teste de normalidade das séries, uma vez que o divisor principal de metodologia dos modelos de *VaR* paramétricos e não paramétricos é a presunção de distribuição normal. Com a

finalidade de testar essa premissa, foram calculados os coeficientes de curtose, assimetria e por fim aplicado o teste de Jarque-Bera, um dos métodos mais utilizados para se testar à normalidade de uma variável. A distribuição normal é caracterizada por ser simétrica e possuir o coeficiente de curtose igual a três, de forma que o excesso de curtose de uma amostra pode ser definido como o coeficiente de curtose menos três. O teste Jarque-Bera formaliza essas premissas testando onde o coeficiente de assimetria e o de excesso de curtose são estatisticamente iguais a zero, conforme equação mostrada abaixo:

$$W = T \left[\frac{b_1^2}{6} + \frac{(b_2 - 3)^2}{24} \right] \quad (50)$$

Em que T é o tamanho da amostra. O teste segue uma distribuição χ^2 com dois graus de liberdade. A hipótese nula assume que a distribuição da série é simétrica e mesocúrtica. Uma segunda forma de se averiguar a normalidade consiste em uma ferramenta comparativa de distribuições de probabilidade conhecida como *quantile-quantile plot (Q-Q plot)*. O *Q-Q plot* compara duas distribuições de probabilidade graficamente ao plotar dois conjuntos de quantis um contra o outro. Se as duas distribuições se sobrepõem após uma transformação linear, os pontos do *Q-Q plot* formam uma linha reta.

A tabela 2 apresenta a estatística descritiva da série e o resultado do teste JB:

Tabela 2: Estatística descritiva dos ativos

	Ibov (1997- 2017)	Dólar (1997- 2017)	IDA (2009- 2017)	IMA-B (2006- 2017)	ICB (2004- 2017)	IFIX (2011- 2017)	LP 200 (1998- 2017)
Observações	4970	5039	2175	2915	3237	1505	4786
Mínimo	-17.21%	-9.36%	-1.35%	-3%	-7%	-4.98%	-1.87%
Quartil 1	-1.02%	0.42%	0.03%	-0.2%	0.13%	-0.15%	-0.94%
Mediana	0.09%	0.02%	0.05%	0.05%	0%	0.04%	0.05%
Média	0.04%	0.02%	0.05%	0.05%	0.03%	0.04%	0.04%
Aritmética							

Quartil 3	1.17%	0.41%	0.07%	0.13%	0.52%	0.26%	0.10%
Máximo	28.83%	10.53%	0.84%	0.14%	8.65%	1.77%	1.78%
Variância	0.04%	0.01%	0	0	0.01%	0	0%
Desvio-padrão	2.08%	0.97%	0.10%	0.18%	0.94%	0.42%	0.17%
Assimetria	0.33	0.34	-1.72	-1.51	0.46	-1.28	-1.10
Curtose	12.93	14.76	28.32	27.41	7.44	15.89	21.30
JB p-value	0.00	0.00	0.00	0.00	0.00	0.00	0.00

Fonte: Elaboração própria

Inicialmente observa-se que todos os ativos obtiveram retorno médio positivo, dentro de seus respectivos períodos, sendo os maiores o IDA e o IMA-B, que possuem aproximadamente o mesmo valor (0.05%), enquanto que o menor foi o dólar (0.02%), o que pode ter sido ocasionado pela forte desvalorização do ativo durante os anos de 2008 e 2009. Em relação à volatilidade, representada pelo desvio-padrão, o Ibov foi o mais volátil do período, seguido pelo dólar. Os ativos menos voláteis foram o IDA (0.10%) seguido pelo LP 200 (0.17%).

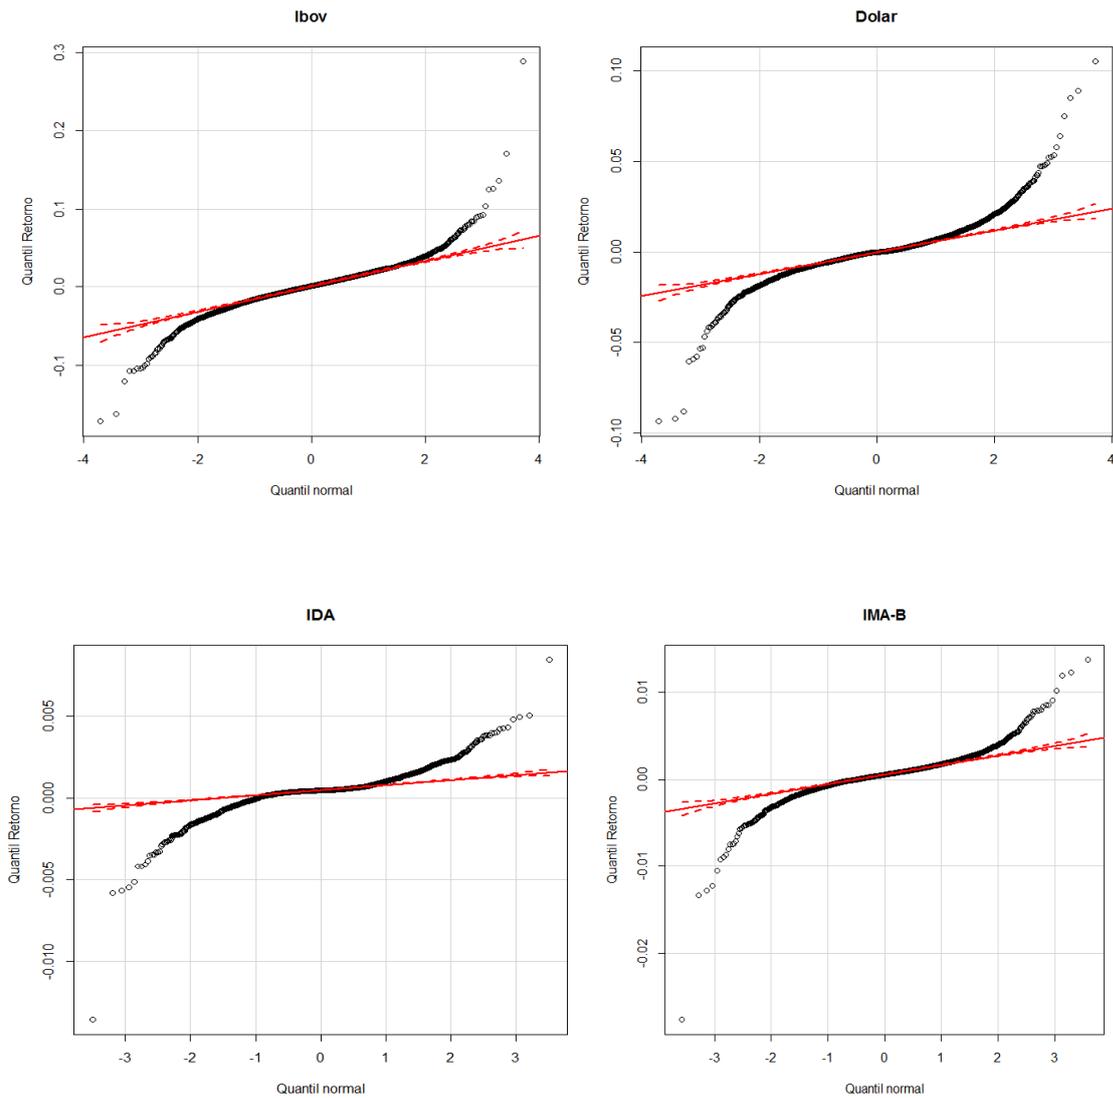
Quando analisados os valores máximos das séries dos ativos, um fator que merece destaque é que tanto o Ibov quanto o dólar atingiram seu ápice no mesmo dia, 15/01/1999. Na verdade, este fator não ocorreu devido a um *boom* econômico e sim por uma queda brusca do preço dos dois ativos no dia anterior gerada pela política cambial do BACEN em que foi estabelecido o preço máximo do dólar, levando à fuga de capital estrangeiro do país. O LP 200 e o IDA apresentaram os menores valores máximos, entretanto por terem apresentado uma menor volatilidade, é condizente com o esperado. Quando analisados os pontos mínimos, o Ibov obteve o menor valor, no segundo semestre de 1999, seguido pelo dólar, no segundo semestre de 2002.

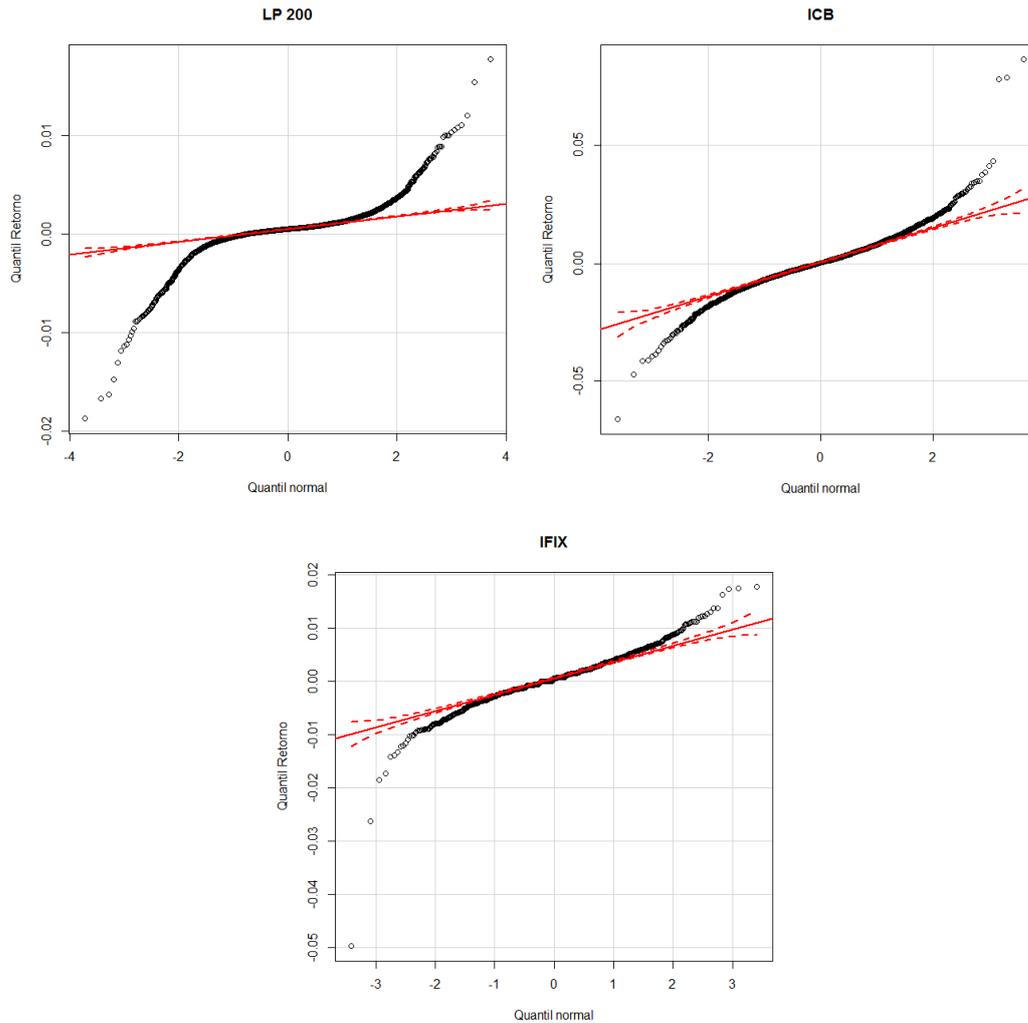
Com base nos *p-values* do teste JB apresentados na tabela 02, à hipótese nula de que os resíduos da série financeira são normalmente distribuídos foi rejeitada para todos os ativos da amostra, o que gera um questionamento em relação aos modelos de *VaR* paramétricos que assumem a premissa de normalidade. O menor índice de curtose foi do ICB, entretanto como ainda é superior a três, a série indica distribuição leptocúrtica como as outras. O Ibov, dólar e ICB apresentaram assimetria à direita, diferentemente dos outros ativos que obtiveram assimetria negativa. A comparação nesse aspecto é limitada devido à diferença entre os períodos dos ativos, mas pode-se concluir que as distribuições da

amostra são não simétricas em relação à média e possuem caudas mais pesadas do que as de uma distribuição normal.

Os gráficos *QQ-Plot* das séries financeiras, apresentados abaixo, também indicam a não normalidade, uma vez que nenhuma distribuição se adequou em torno da reta da distribuição normal.

Gráfico 1: QQ-plot dos ativos das amostras





4.2 Análise de desempenho dos modelos de *VaR*

O presente tópico apresentará a descrição dos resultados obtidos para as classes de ativos, com o objetivo de se realizar uma comparação conjunta tanto entre os modelos de *VaR*, quanto sua robustez entre os ativos. O R versão 3.4.1 foi o *software* utilizado para realização dos cálculos computacionais. Os *packs* e códigos utilizados encontram-se no anexo do trabalho. Inicialmente é feita uma análise do índice de violação, e em seguida, para fins de auxílio na interpretação dos resultados, é feita a análise gráfica da volatilidade do *VaR* (contida no anexo). Por fim, são feitos os testes de significância do índice de

violação, que tem por objetivo identificar se os excessos de perda em relação ao *VaR* estimado estão no nível de erro esperado.

4.2.1 Índices de violação dos modelos de *VaR* e testes estatísticos

A tabela abaixo apresenta o resultado do cálculo do índice de violação dos modelos e suas respectivas volatilidades com nível de confiança de 99%. Conforme descrito anteriormente, para análise dos índices de violação será utilizado o padrão de que um índice com valor entre 0.8 e 1.2 é apropriado, enquanto que inferior a 0.5 e superior a 1.5 é impreciso (DANIELSSON, 2011).

Tabela 3: Análise de performance do *VaR* para o período completo

	Número de Índices adequados	Melhor modelo	Número de rejeições (Kupiec)	Número de rejeições (Independência)
Ibov	1	HS	2	3
Dolar	2	EWMA	2	3
IDA	1	GARCH	4	2
IMA-B	2	EWMA, HS E GARCH	2	4
ICB	0	-	3	3
IFIX	3	EWMA, GARCH, ES	3	2
LP 200	1	ES	4	3

Fonte: elaboração própria

Ao fazer uma análise geral dos resultados da tabela 3, o número de índices de violação apropriado dos modelos de *VaR* foi igual a 11 (26%), enquanto que o número de valores imprecisos foi de 31 (74%). As classes de ativos que obtiveram os melhores resultados de estimação foram o dólar, IMA-B e IFIX, enquanto que o ICB não apresentou nenhum modelo de *VaR* com índice apropriado. O GARCH foi o modelo que apresentou o maior número de índices precisos (4), enquanto que o Delta normal e o MC tiveram o pior desempenho, não retornando nenhum índice apropriado.

Para o Ibov, o melhor desempenho foi do HS. Esse resultado pode ser explicado pela alta volatilidade da carteira de ações, haja vista que o modelo de simulação histórica ao não realizar nenhuma inferência em relação à distribuição, é capaz de incorporar a não linearidade do ativo, de forma que, para uma volatilidade inconstante (heterocedástica), ele é capaz de estimar valores mais elevados de *VaR*.

O EWMA, GARCH tiveram os melhores índices para o dólar, sendo que quando comparada a volatilidade entre os modelos, o EWMA apresentou a melhor performance. Ambos os modelos correspondem a metodologias de cálculo que consideram o agrupamento de volatilidade no tempo, de forma a utilizar esse fator para estimação do risco. Sendo assim, é provável que o dólar apresente a característica de aglomeração de volatilidade em períodos seguidos.

O IMA-B obteve três índices de violação apropriados: EWMA, HS, GARCH, sendo que quando considerada a volatilidade, o segundo apresentou o melhor desempenho. O IMA-B é uma carteira de títulos públicos, apresentando menor volatilidade do que os outros dois anteriores, o que auxilia na explicação da baixa performance do ES. Por depender principalmente do fator taxa de juros, é de se esperar que sua volatilidade apresente agrupamentos, o que corrobora com a performance do GARCH e EWMA.

Para o IDA, apenas o GARCH obteve um índice adequado, enquanto que todos os outros foram imprecisos. Uma explicação possível é que a exposição ao risco de crédito de uma debênture é superior ao risco de mercado, de forma que os modelos deste trabalho não conseguiram estimar a perda referente ao primeiro risco. Os modelos também se mostraram não satisfatórios para o ICB, que não obteve nenhum índice de violação adequado. Este fator também pode ter sido ocasionado pelas características particulares e distintas que as *commodities* possuem quando comparadas a outros ativos tradicionais. Os preços das *commodities* são influenciados por fatores como choques de demanda e oferta, assim como desastres naturais, de forma que os modelos de estimação de risco, utilizados neste trabalho não sejam os mais adequados para capturar essas perdas.

Tiveram índice adequado para o IFIX o EWMA, GARCH e o ES, sendo que, com base na volatilidade, o último obteve o melhor desempenho. Este resultado pode ser decorrente da ocorrência de perdas superiores ao *VaR* estimado, um diferencial que o ES é capaz de prever em relação aos outros modelos. Como dito anteriormente, o desempenho

do EWMA e do GARCH pode ser explicado pela existência de *clusters* na volatilidade do IFIX.

Por fim, o LP 200 teve apenas o índice do ES apropriado, que é um modelo mais conservador do que os outros métodos de cálculo de *VaR*, uma vez que ambos se concentram nas informações contidas nas caudas. A estatística descritiva do LP 200 indica que o ativo é leptocúrtico, o que justificaria o resultado. Entretanto, há de se destacar que o IMA-B e o IDA apresentaram um valor superior de curtose e ainda assim, esse modelo não foi satisfatório para estes ativos. Outra explicação poderia ser que, por ser um fundo multimercado, o LP 200 inclui classes de ativos de maior risco, como os derivativos, por exemplo, o que pode ter gerado perdas superiores às previstas pelos outros modelos.

Não foi encontrado nenhum padrão em relação às características estatísticas dos ativos e os modelos, não sendo possível concluir que, um determinado método é melhor para ativos com assimetria positiva ou negativa, por exemplo. Os resultados obtidos foram heterogêneos, o que era esperado, haja vista que conforme dito no referencial teórico, cada ativo possui riscos específicos que influenciam em seus respectivos retornos.

Para formalizar os resultados encontrados e validar as hipóteses de pesquisa, foram feitos os testes de Kupiec e de independência, considerando o nível de confiança de 95%, com foco na significância de precisão de estimação de perda e de independência das violações. O número total de rejeições do teste de Kupiec foi igual a 19, o que indica que, para a amostra, 40% dos modelos não estimaram com precisão o *VaR*. Os modelos com menor número de rejeições e consequentemente com melhor capacidade preditiva foram o GARCH e o ES, o que corrobora com os resultados encontrados no índice de violação. O Monte Carlo e o Delta obtiveram o maior número de rejeições (6), o que também vai de encontro ao resultado do índice de violação. Quando realizada a análise do teste de Kupiec considerando a perspectiva dos ativos, o IDA foi o que apresentou maior número de rejeições (5), o que sugere que os modelos deste trabalho não são adequados para mensuração de seu *VaR*. O IFIX não obteve nenhuma rejeição, sendo o ativo em que os modelos apresentaram o melhor desempenho para o cálculo das perdas.

Para o teste independência, o número de rejeições também foi 19, o que indica que 40% dos modelos testados apresentaram agrupamento de violações de estimação para algum dos ativos da amostra, indicando demora desses modelos no ajuste a volatilidade

dos ativos. O HS foi o que apresentou o maior número de violações (6), enquanto que GARCH não apresentou nenhuma. Realizando a análise sob a perspectiva dos ativos, o IMA-B e dólar foram os que apresentaram maior número de violações de independência (4). Este fator pode ser um indicativo da ocorrência de perdas sequenciais não estimadas para essas categorias de ativos, o que indica uma necessidade de melhoria em incorporar essas informações na estimação do *VaR*. O IFIX não apresentou nenhuma rejeição para o teste de independência, não havendo evidências de agrupamento de violações.

Adicionalmente foi feito o teste dos modelos de risco segregando as amostras em grupos de três anos, com início em 2005 e final em 2016. Para essa nova análise foi utilizada uma janela de estimação de 252 dias, o que corresponde a aproximadamente um ano de negociação de ativos. Este teste foi feito com o intuito de analisar o poder preditivo do *VaR* frente a diferentes ciclos econômicos, além de permitir a comparação do horizonte de estimação. Devido ao início de negociação, o IFIX e o IDA tiveram apenas dois períodos de análise, enquanto que o IMA-B teve o início da amostra o ano de 2006.

As tabelas abaixo apresentam os resultados: A tabela 4 contém os resultados sob a perspectiva dos ativos, enquanto que a tabela 5, sob a perspectiva dos modelos:

Tabela 4: Desempenho do VaR por ativos

	Percentual de índices adequados	Percentual de rejeições (Kupiec)	Percentual de rejeições (Independência)	Período com maior nº de rejeições (Kupiec)	Período com maior número de rejeições (Independência)
Ibov	37,5%	20,8%	0,0%	2005-2007	-
Dolar	25,0%	12,5%	8,3%	2005-2007	2005-2007
IDA	25,0%	50,0%	25,0%	2011-2013	2011-2013
IMA-B	33,3%	20,8%	8,3%	2009-2011	2006-2008
ICB	20,8%	12,5%	4,2%	2008-2010	2008-2010
IFIX	16,7%	4,2%	8,3%	2011-2013	2011-2013
LP 200	12,5%	16,7%	12,5%	2005-2007	2011-2013

Fonte: Elaboração própria

Tabela 5: Desempenho dos modelos

	Número de índices adequados	Número de rejeições (Kupiec)	Número de rejeições (Independência)	Período com maior nº de rejeições (Kupiec)	Período com maior número de rejeições (Independência)
EWMA	5	4	2	2005-2007/2011-2013	2005-2007/2011-2013
Delta	3	6	1	2005-2007	2011-2013
HS	5	3	1	2008-2010/2011-2013	2008-2010
GARCH	6	2	1	2011-2013/2014-2016	2011-2013
ES	15	1	2	2011-2013	2005-2007
MC	4	5	1	2005-2007/2011-2012	2011-2013

Fonte: Elaboração própria

Os resultados gerais obtidos dessa segunda análise referentes ao índice de violação foram semelhantes aos da primeira. No total, foram estimados 144 índices, dos quais 26% foram precisos e 74% imprecisos. O Ibov apresentou o maior percentual de índices adequados (32%), enquanto que o IDA o menor percentual (21%). Esses resultados vão de encontro aos de estudos anteriores, em que janelas de estimação de menor horizonte tendem a ser melhores para ativos voláteis e negociados frequentemente, enquanto que as de maior horizonte são apropriadas para ativos de baixa liquidez e estáveis (HARMANTZIS; MIAO; CHIEN, 2006).

O modelo com maior número de índices adequados foi o ES (15), seguido pelo GARCH (6). Entretanto, apesar do bom desempenho do ES, há de se ressaltar que o método, embora seja relacionado com o *VaR*, se distingue dos outros modelos por se concentrar na informação abaixo do quantil p da distribuição, de forma que sempre terá um valor superior ao *VaR*, o que consequentemente influencia no índice de violação (ALEXANDER et. al., 2005). O Delta apresentou o menor número de índices apropriados (3), seguido pelo MC (4). Apesar disso, para esses dois últimos modelos e o ES, a redução da janela de estimação foi positiva, enquanto que para os demais modelos, o percentual de

índices adequados foi reduzido, indicando que uma janela mais extensa pode ser mais apropriada para a estimação.

Para o Ibov, o período com maior número de índices precisos foi de 2011-2013, enquanto que os períodos restantes apresentaram o mesmo total (2). O ES obteve o melhor desempenho, seguido pelo Delta. O EWMA apresentou a pior performance, não retornando nenhum índice adequado de estimação de VaR . Esse resultado pode ser o inverso do que ocorre com o ES e Delta, de forma que um maior número de observações pode melhorar a capacidade de estimação para o EWMA. Considerando o teste de Kupiec, os intervalos com maiores números de rejeições de H_0 foi 2005-2007, seguido por 2008-2010, mostrando a incapacidade de estimação dos modelos EWMA, Delta, GARCH e MC para o primeiro período e HS e MC para o segundo. Tal fator pode ser decorrente da crise do *subprime* que teve seu início em 2007, perdurando até 2008, o que gerou perdas acima do previsto. Quando considerado o teste de independência, nenhum modelo apresentou agrupamento de violações.

O período com maior número de índices adequados para o dólar foi de 2014-2016 (4), enquanto que o período de 2011-2013 não apresentou nenhum índice com valor preciso. Os modelos EWMA e GARCH apresentaram o melhor desempenho, enquanto que o Delta e MC não tiveram nenhum índice de estimação preciso. Observa-se que o ES, assim como ocorreu no Ibov, retornou um índice adequado para o período de início da crise (2005-2007), o que era esperado, haja vista que é o modelo mais conservador por se concentrar na cauda esquerda. Quando considerado o teste de Kupiec, o período com maior número de rejeições foi 2005-2007, o que também pode ter sido gerado pela crise, em especial para este ativo. O teste de independência foi rejeitado para o EWMA e ES no primeiro período, apesar de terem retornado um índice de violação adequado, sendo um indicativo de falha desses dois modelos a se adequarem rapidamente à mudança de volatilidade gerando uma sequência de violações.

O IDA foi o ativo com menor número de índices precisos, entretanto também ocorreu a piora de dois modelos decorrente da redução da janela de estimação. O Delta e o GARCH não retornaram o cálculo do índice de violação, o pode ser decorrente da baixa volatilidade do ativo quando dividida a amostra, pois, considerando que o GARCH é um modelo de previsibilidade de variância, o número de observações necessárias para

estimação do *VaR* do IDA pode não ter sido suficiente para o cálculo de estimação. O MC retornou um índice adequado para o período de 2011-2013, enquanto que HS e ES no período de 2014-2016. O teste de Kupiec teve duas rejeições, para o ES e EWMA, no primeiro período, enquanto que o teste de independência de violação foi rejeitado para o MC no mesmo intervalo.

O IMA-B teve seis índices precisos, distribuídos igualmente entre o EWMA, HS, e GARCH, os mesmos modelos da análise do período completo. O intervalo de 2015-2016 apresentou o melhor desempenho, enquanto o de 2006-2008 não retornou nenhum índice adequado. A hipótese nula do teste de Kupiec foi rejeitada cinco vezes: três em 2009-2011 para o Delta, HS e MC e duas vezes em 2012-2014, para o Delta e MC. A hipótese nula do teste de independência foi rejeitada para o MC e ES para o primeiro intervalo de análise.

O período de 2014-2016, para o ICB, foi o que apresentou o maior número de índices adequados, enquanto que os de 2005-2007 e 2011-2013 obtiveram apenas um índice preciso. O ES apresentou o melhor desempenho. O EWMA, Delta e HS não retornaram nenhum valor adequado. Para este ativo, nota-se uma melhoria para a análise segregada por períodos, que pode ser decorrente do uso da janela de estimação de 252 dias, haja vista que no primeiro teste realizado para o período todo, o ICB não obteve nenhum índice de violação adequado. O teste de Kupiec não rejeitou a hipótese nula para nenhum dos ativos, assim como a hipótese nula de independência de violações também não foi rejeitada.

Para o IFIX, o período com maior número de índices adequados foi de 2011-2013. O HS teve o melhor desempenho, seguido pelo GARCH, EWMA e ES, enquanto que os outros modelos não retornaram nenhum índice adequado. O desempenho do HS pode indicar uma melhoria no uso de 252 dias para estimação do *VaR* para essa classe de ativo, haja vista que no teste para o período completo, o método não obteve um bom resultado. A hipótese nula do teste de Kupiec foi rejeitada apenas para o EWMA, no intervalo de 2011-2013, assim como o teste de independência de violações.

Por fim, para o LP 200, o período de 2008-2010 foi o que teve o maior número de índices precisos. Para este modelo, observa-se uma melhoria da análise do período, uma vez que, com exceção do EWMA, todos os modelos retornaram um índice adequado. O teste de Kupiec foi rejeitado para o EWMA, delta e MC para o intervalo de 2005-2007 e

para o Delta, HS e MC no período de 2014-2016. O teste de independência de violações foi rejeitado para o EWMA em 2005-2007 e HS em 2014-2016.

De forma geral, observa-se que embora os percentuais de desempenho da segunda análise tenham sido próximos dos da primeira análise, os índices de violação mudaram para determinadas classes de ativos, de forma que alguns modelos melhoraram seu desempenho com a redução da janela de estimação, enquanto que outros deterioraram, o que é decorrente das informações contidas nas volatilidades desses ativos. Para ativos mais voláteis, a redução da janela foi melhor no que tange em especial o peso dos últimos dias para o cálculo do *VaR*, enquanto que para ativos menos voláteis, uma janela reduzida não foi tão eficiente no aspecto de apuração do *VaR*. Como era de esperar, os intervalos próximos à crise financeiras foram aqueles que tiveram o maior número de rejeições dos testes estatísticos.

5.0 Considerações Finais

O presente trabalho teve como objetivo geral mensurar a acurácia de distintas abordagens de mensuração de risco de mercado para diferentes classes de ativos. Como modelos de estimação de risco foram aplicados os modelos de *Value at Risk* paramétricos (EWMA, Delta, Monte Carlo, GARCH) e não paramétricos (HS) e métodos alternativos semi-paramétricos (ES). A amostra é composta por ativos pertencentes às categorias de ações, câmbio, título de renda fixa público, título de renda fixa privado, fundo imobiliário, *commodities* e fundo de investimento multimercado. O período de início da análise foi de 1997, e, para ativos com início de negociação posterior a este período, foi considerada a data de sua primeira negociação, tendo como término, para todas as categorias, janeiro de 2017.

Primeiramente foi realizada uma estatística descritiva, haja vista que, o fator mais importante para implementação de uma métrica de risco consiste nas propriedades estatísticas específicas do ativo. Para todos os instrumentos financeiros da amostra, foi rejeitada a hipótese de normalidade, de forma que nenhum apresentou distribuição normal. Este fator já é um indicativo de alerta para os modelos paramétricos de *VaR* que partem da premissa de que as séries financeiras são normalmente distribuídas. O Ibov e o dólar, que

representam *proxy* do mercado de ações e câmbio, respectivamente, foram os ativos de maior volatilidade, enquanto que o IDA e LP 200, *proxies* de renda fixa privada e fundo multimercado, foram os menos voláteis.

Em seguida foram calculados os índices de violação, a partir do *VaR* a 99% de confiança, dos sete modelos para cada classe de ativo, considerando o período completo de cada categoria e uma janela de estimação de 1000 dias. Nesta primeira análise, o GARCH foi o modelo com maior número de índices precisos, enquanto que Delta e MC tiveram o pior desempenho. Para os ativos, o IMA-B e o IFIX retornaram o maior número adequado de índices apropriados, enquanto que o ICB não apresentou nenhum. Para validar estatisticamente o desempenho dos modelos da pesquisa, foram aplicados os testes estatísticos de Kupiec e Christofferson (independência de violações), considerando o nível de confiança de 95%. Os modelos com menor número de rejeições de hipóteses nulas foram o GARCH e ES, enquanto que o Delta e MC tiveram o maior número de rejeições, confirmando os resultados do índice de violação. Para o teste de independência, o modelo HS apresentou o maior número de rejeições, o que é um indicativo de aglomeração de violações de estimação, indicando que o modelo tem um maior *delay* para absorver as informações de mudança de volatilidade.

Adicionalmente, foi feito um segundo teste, dividindo cada ativo em períodos iguais, de forma a testar os modelos de *VaR* em diferentes ciclos econômicos e o efeito da redução da janela de estimação para 252 dias. Para esta nova análise, o modelo com melhor desempenho foi o ES, enquanto que Delta e MC apresentaram o menor número de índices apropriados. O dólar e o Ibov retornaram o maior percentual de índices adequados, enquanto que o IDA o menor. Esses resultados mostraram um indicativo de que para ativos mais voláteis, a redução da janela de estimação indica uma melhoria de mensuração, o que pode ser decorrente das considerações de eventos mais recentes na estimação de perda desses ativos. Enquanto que para ativos menos voláteis, a redução da janela de estimação pode prejudicar a capacidade de mensuração, haja vista que há poucas informações acerca do risco inerente ao ativo.

Quando aplicados os testes estatísticos para essa segunda análise, o percentual de rejeições foi inferior ao da primeira análise. Entretanto o intervalo de confiança utilizado para análise foi de 95%, o que aumenta o erro tipo 1, que consiste na rejeição da hipótese

nula quando verdadeira. De forma geral, não foi identificado um padrão das métricas de risco para as características estatísticas específicas dos ativos. Entretanto algumas considerações devem ser ressaltadas. A baixa performance do Delta, com base no índice de violação, mostra o baixo poder preditivo deste modelo quando comparados aos outros, o que vai de encontro as fragilidades levantadas por estudos anteriores. O bom desempenho do ES merece uma ressalva, uma vez que o modelo não é tido como uma métrica tradicional de *VaR* por focar-se nas perdas que excedem o *VaR*, ou seja, aquelas que estão abaixo do quantil da probabilidade p . Desta forma, levando em consideração as métricas tradicionais, o GARCH novamente apresentou melhor desempenho, o que pode ser derivado da capacidade desse modelo de incorporar a volatilidade condicional do ativo.

O estudo é relevante no aspecto de testar a capacidade preditiva de diferentes modelos de estimação de risco para as distintas classes de ativos no mercado brasileiro, de forma a contribuir não apenas para a literatura acadêmica financeira como também para decisões práticas de gestão de risco. Entretanto, conforme dito anteriormente, dificilmente irá existir um modelo de mensuração de risco que tenha sua hegemonia estabelecida, considerando que cada método possui suas particularidades positivas e negativas no que tange as características inerentes a ativos, mercados, risco e ciclos econômicos. Além disso, pode-se dizer que os estudos referentes às capacidades preditivas de *VaR* formam um processo contínuo e que dificilmente irá se saturar, haja vista que há sempre o interesse do sistema econômico de desenvolver e aprimorar métodos capazes de mensurar perdas financeiras.

Sendo assim, para fins de pesquisas futuras, é sugerida a aplicação de outros métodos de estimação de risco para as categorias de ativos pertencentes à amostra deste trabalho. Outro tema relevante seria a replicação deste estudo nos mesmos ativos de economias emergentes e desenvolvidas, de forma a realizar comparativos e também expandir a abrangência dos resultados encontrados. Por fim, sugere-se um teste segregando os setores econômicos de ações e títulos de renda fixa privados, uma vez que o *VaR* tem suas raízes na teoria do portfólio de Markowitz, e que cada ativo pertencente a um tipo de indústria possui suas características específicas.

A principal limitação do trabalho reside na amostra, uma vez que foram utilizados índices, isto é, carteiras teóricas que contém diversos tipos de ativos, de forma que, caso os

modelos tivessem sido aplicados individualmente entre os ativos pertencentes a esses portfólios, os resultados poderiam ter sido distintos.

6.0 REFERÊNCIAS

ACERBI, C.; NORDIO, C.; SIRTORI, C.. Expected shortfall as a tool for financial risk management. arXiv preprint cond-mat/0102304, 2001.

ACERBI, C.; TASCHE, D.. Expected shortfall: a natural coherent alternative to value at risk. *Economic notes*, v. 31, n. 2, p. 379-388, 2002.

ADAMS Z., FUSS, R., KAISER, D. G., *Macroeconomic determinants of commodity futures returns*. The handbook of commodity investing, 87-112, 2008.

ALEXANDER, C. *Practical Financial Econometrics*-Suppressed-Added to 1265420. 2008.

ALEXANDER, C.. *Market Risk Analysis, Value at Risk Models*. John Wiley & Sons, 2009.

ALEXANDER, C.; SARABIA, J. M. *Quantile Uncertainty and Value-at-Risk Model Risk*. Risk Analysis, v. 32, n. 8, p. 1293-1308, 2012.

ARNDT, H. W. *The valuation effect of changes in exchange rates*. PSL Quarterly Review, v. 41, n. 167, 2013.

ARNOLD, G. *The Financial Times Guide to Investing: The definitive companion to investment and the financial markets*. Pearson UK, 2012.

ARTZNER, P. et al. *Coherent measures of risk*. Mathematical finance, v. 9, n. 3, p. 203-228, 1999.

BASAK, S.; PAVLOVA, A. A model of financialization of commodities. *The Journal of Finance*, v. 71, n. 4, p. 1511-1556, 2016.

BARONE-ADESI, G.; GIANNOPOULOS, K.. Non parametric var techniques. myths and realities. *Economic Notes*, v. 30, n. 2, p. 167-181, 2001.

BERAN, J.; OCKER, D.. *Volatility of Stock-Market Indexes—An Analysis Based on SEMIFAR Models*. Journal of Business & Economic Statistics, 2012.

BHANDARI, L. C. *Debt/equity ratio and expected common stock returns: Empirical evidence*. The Journal of Finance, v. 43, n. 2, p. 507-528, 1988.

BLANCHARD, O.; GIAVAZZI, F.; SA, F.. *International investors, the US current account, and the dollar*. Brookings Papers on Economic Activity, v. 2005, n. 1, p. 1-65, 2005.

BORDO, M. D.; EICHENGREEN, B. (Ed.). *A retrospective on the Bretton Woods system: lessons for international monetary reform*. University of Chicago Press, 2007.

BROWN, S. J.; GOETZMANN, W. N. Hedge funds with style. *The Journal of Portfolio Management*, v. 29, n. 2, p. 101-112, 2003.

BRUEGGEMAN, W. B.; FISHER, J. D. *Real estate finance & investments*. McGraw-Hill/Irwin, 2008.

CHAVEZ-DEMOULIN, V.; EMBRECHTS, P.; NEŠLEHOVÁ, J.. *Quantitative models for operational risk: extremes, dependence and aggregation*. Journal of Banking & Finance, v. 30, n. 10, p. 2635-2658, 2006.

CHEN, N.; ROLL, R.; ROSS, S. A. *Economic forces and the stock market*. Journal of business, p. 383-403, 1986.

CHOUDHRY, M. *Bond and money markets: strategy, trading, analysis*. Butterworth-Heinemann, 2003.

CHOUDHRY, M. *An introduction to bond markets*. John Wiley & Sons, 2006.

CHOUDHRY, M. *An introduction to value-at-risk*. John Wiley & Sons, 2013.

COLLIER, P.1 M. *Fundamentals of risk management for accountants and managers*. Routledge, 2009.

COMMITTEE OF SPONSORING ORGANIZATIONS OF THE TREADWAY COMMISSION (COSO) et al. *Coso gerenciamento de riscos corporativos-estrutura integrada: sumário executivo*. Recuperado em, v. 26, 2011.

CROUHY, M.; GALAI, D.; MARK, R.. *The essentials of risk management*. New York: McGraw-Hill, 2006.

CRUZ, M.; COLEMAN, R.; SALKIN, G. *Journal of Risk*, v. 1, n. 1, p. 63-72, 1998.

CROUHY, M.; GALAI, D.; MARK, R.. *The essentials of risk management*. New York: McGraw-Hill, 2006.

CROWE, C. et al. *How to deal with real estate booms: Lessons from country experiences*. *Journal of Financial Stability*, v. 9, n. 3, p. 300-319, 2013.

DAMODARAN, A.. *Strategic risk taking: a framework for risk management*. Pearson Prentice Hall, 2007.

DANIELSSON, J. et al. *Subadditivity re-examined: the case for value-at-risk*. 2005.

DANIELSSON, J. et al. *Fat tails, VaR and subadditivity*. *Journal of econometrics*, v. 172, n. 2, p. 283-291, 2013.

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.

DIEBOLD, F. X.; SCHUERMAN, T.; STROUGHAIR, J. D. *Pitfalls and opportunities in the use of extreme value theory in risk management*. *The Journal of Risk Finance*, v. 1, n. 2, p. 30-35, 2000.

DUFFIE, D.; PAN, J. *An overview of value at risk*. *The Journal of derivatives*, v. 4, n. 3, p. 7-49, 1997.

ENGLE, R. F.; MANGANELLI, S. *CAViaR: Conditional autoregressive value at risk by regression quantiles*. *Journal of Business & Economic Statistics*, v. 22, n. 4, p. 367-381, 2004.

FABOZZI, F. J.; FRANCIS, J. C. *Mutual fund systematic risk for bull and bear markets: an empirical examination*. *The Journal of Finance*, v. 34, n. 5, p. 1243-1250, 1979.

FABOZZI, F. J.; FLEMING, M. J. *US Treasury and agency securities*. *The Handbook of Fixed Income Securities* (6th ed.) McGraw Hill, New York, NY, 2000.

- FABOZZI, F. J.; GUPTA, F.; MARKOWITZ, H. M. *The legacy of modern portfolio theory. The Journal of Investing*, v. 11, n. 3, p. 7-22, 2002.
- FAMA, E. F.; FRENCH, K. R. *The capital asset pricing model: Theory and evidence. The Journal of Economic Perspectives*, v. 18, n. 3, p. 25-46, 2004.
- FAMA, E. F.; FRENCH, K. R. *Multifactor explanations of asset pricing anomalies. The journal of finance*, v. 51, n. 1, p. 55-84, 1996.
- FAMA, E. F., FRENCH, K. R.. *A five-factor asset pricing model. Journal of Financial Economics*, 116, 1–22, 2015.
- FRANKEL, J. A.; FROOT, K.. *Chartists, fundamentalists and the demand for dollars. NBER Working Paper*, n. R1655, 1991.
- FRANKEL, J. A. Effects of speculation and interest rates in a “carry trade” model of commodity prices. *Journal of International Money and Finance*, v. 42, p. 88-112, 2014.
- FÜSS, R.; ADAMS, Z.; KAISER, D. G. The predictive power of value-at-risk models in commodity futures markets. *Journal of Asset Management*, v. 11, n. 4, p. 261-285, 2010.
- GAGLIANONE, W. Pi et al. *Evaluating value-at-risk models via quantile regression. Journal of Business & Economic Statistics*, 2012.
- GRAVES, R., *Qualitative Risk Assessment*, PMNetwork- The Professional Magazine of the Project Management Institute, p. 80, October 2000
- GREGORIOU, G. N. *The VaR implementation handbook*. McGraw Hill Professional, 2010.
- GUJARATI, D. N.; PORTER, D. C. *Econometria Básica-5*. AMGH Editora, 2011.
- GUPTA, J.; CHAUDHRY, S. M.; REKIK, S. GREGORIOU, A.. *Financial Distress and Downside Risk*. 2016.
- HAMPTON, J. J. *Fundamentals of enterprise risk management: How top companies assess risk, manage exposure, and seize opportunity*. AMACOM Div American Mgmt Assn, 2009.

HARMANTZIS, F. C.; MIAO, L.; CHIEN, Y.. Empirical study of value-at-risk and expected shortfall models with heavy tails. *The journal of risk finance*, v. 7, n. 2, p. 117-135, 2006.

HOLZMANN, R.; JØRGENSEN, S.. *Social Risk Management: A new conceptual framework for Social Protection, and beyond*. *International Tax and Public Finance*, v. 8, n. 4, p. 529-556, 2001.

HOU, K.; XUE, C.; ZHANG, L.. Digesting anomalies: An investment approach. *The Review of Financial Studies*, v. 28, n. 3, p. 650-705, 2015.

HUANG, J.; SIALM, C.; ZHANG, H.. Risk shifting and mutual fund performance. *The Review of Financial Studies*, v. 24, n. 8, p. 2575-2616, 2011.

HUANG, Z. et al. *Credit rating analysis with support vector machines and neural networks: a market comparative study*. *Decision support systems*, v. 37, n. 4, p. 543-558, 2004.

JANSEN, A. et al. Hedge funds and financial market dynamics. *International monetary fund*, 1998.

JORION, P.. *The pricing of exchange rate risk in the stock market*. *Journal of financial and quantitative analysis*, v. 26, n. 03, p. 363-376, 1991.

JORION, P.. *Risk2: Measuring the risk in value at risk*. *Financial Analysts Journal*, v. 52, n. 6, p. 47-56, 1996.

JORION, P., *Value-at-Risk: The new benchmark for controlling market risk*, McGrawHill, New York, 2007.

KAUFMAN, G. G. *Bank failures, systemic risk, and bank regulation*. *Cato J.*, v. 16, p. 17, 1996.

KLOMAN, H. F. *Reshaping the discipline: 'risk management agonists'*. *Risk Management*, v. 37, n. 4, p. 60-72, 1990.

LONGERSTAEY, J. (1996). *Riskmetrics technical manual* (4th ed.). , available at <http://www.riskmetrics.com>

- MAGINN, J. L. et al. (Ed.). *Managing investment portfolios: a dynamic process*. John Wiley & Sons, 2007.
- MALEVERGNE, Y.; SORNETTE, D. *Value-at-Risk-efficient portfolios for a class of super- and sub-exponentially decaying assets return distributions*. *Quantitative Finance*, v. 4, n. 1, p. 17-36, 2004.
- MARKERT, V.; ZIMMERMANN H. . *The relationship between risk premium and convenience yield models*. John Wiley & Sons, Inc., 2008
- MARKOWITZ, H. *Portfolio selection*. *The journal of finance*, v. 7, n. 1, p. 77-91, 1952.
- MARTELLINI, L.; PRIAULET, P.; PRIAULET, S.. *Fixed-income securities: valuation, risk management and portfolio strategies*. John Wiley & Sons, 2003.
- MCNEIL, A. J.; FREY, R.; EMBRECHTS, P. *Quantitative risk management: Concepts, techniques and tools*. Princeton university press, 2015.
- MELNIKOV, A.. *Risk analysis in finance and insurance*. CRC Press, 2011.
- MISHKIN, F. S. EAKINS, S. G. *Financial Markets & Institutions* 7 ed. Boston: Prentice Hall, 2012.
- OET, M. V.; DOOLEY, J. M.; ONG, S. J. *The financial stress index: Identification of systemic risk conditions*. *Risks*, v. 3, n. 3, p. 420-444, 2015.
- PASTOR, L.; STAMBAUGH, R. F. *Liquidity risk and expected stock returns*. National Bureau of Economic Research, 2001.
- REILLY, F. K.; BROWN, K. C. *Investment Analysis and Portfolio Management*: South-Western, 10th ed., 2002.
- ROCKAFELLAR, R. T.; URYASEV, S. *Optimization of conditional value-at-risk*. *Journal of risk*, v. 2, p. 21-42, 2000.
- ROLL, R.; ROSS, S. A. *An empirical investigation of the arbitrage pricing theory*. *The Journal of Finance*, v. 35, n. 5, p. 1073-1103, 1980.
- ROSS, S. A. WESTERFIELD et al. *Corporate finance*. McGraw-Hill, 2009.

SAUNDERS, A.; CORNETT, M, M. *Financial institutions management: A risk management approach*. Irwin/McGraw-Hill, 2003.

STEPHENSON, J. *The little book of commodity investing*. 2010

SZYMANOWSKA, M. et al. *An anatomy of commodity futures risk premia*. The Journal of Finance, v. 69, n. 1, p. 453-482, 2014.

WANG, P.. *The economics of foreign exchange and global finance*. Springer Science & Business Media, 2009.

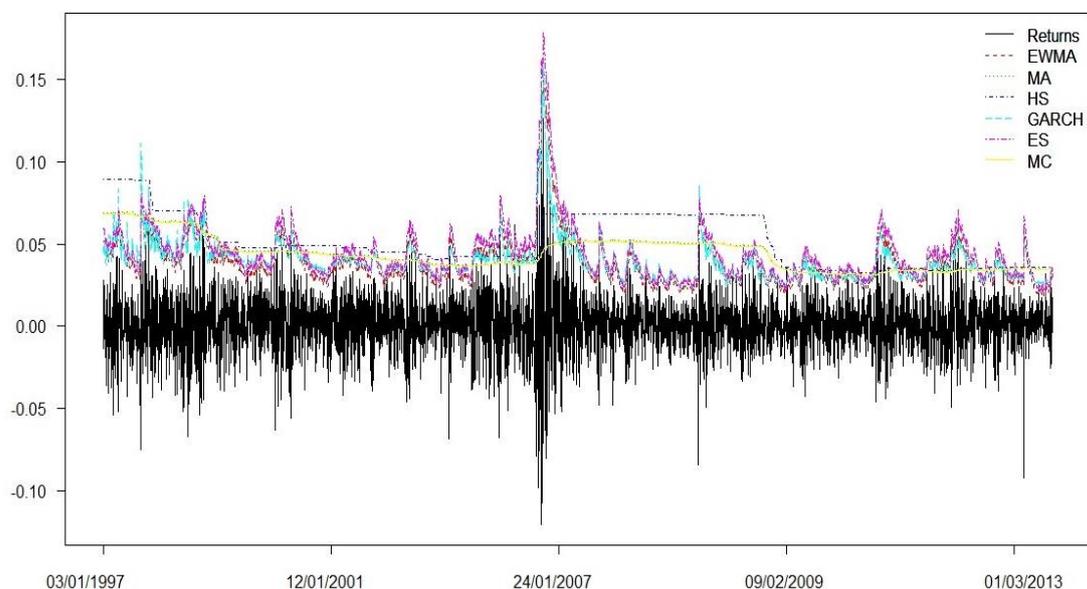
YAMAI, Y., & YOSHIBA, T. Comparative analyses of expected shortfall and value-at-risk: their estimation error, decomposition, and optimization. *Monetary and economic studies*, 20(1), 87-121, (2002)

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.

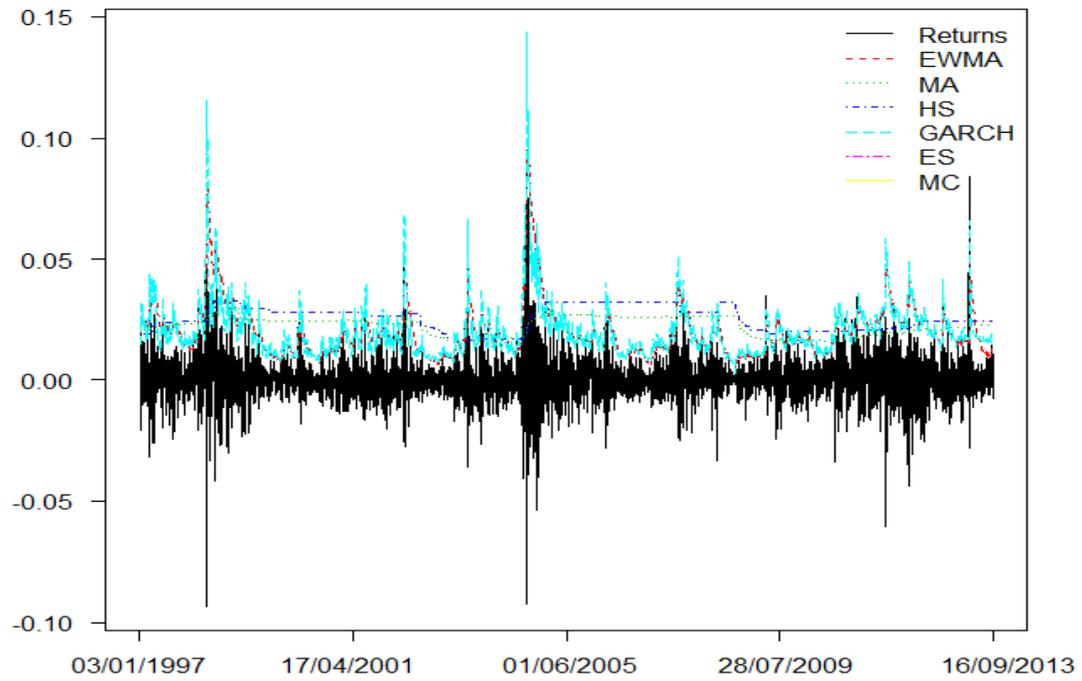
7.0 APÊNDICES

7.1 Gráficos de volatilidade do VaR

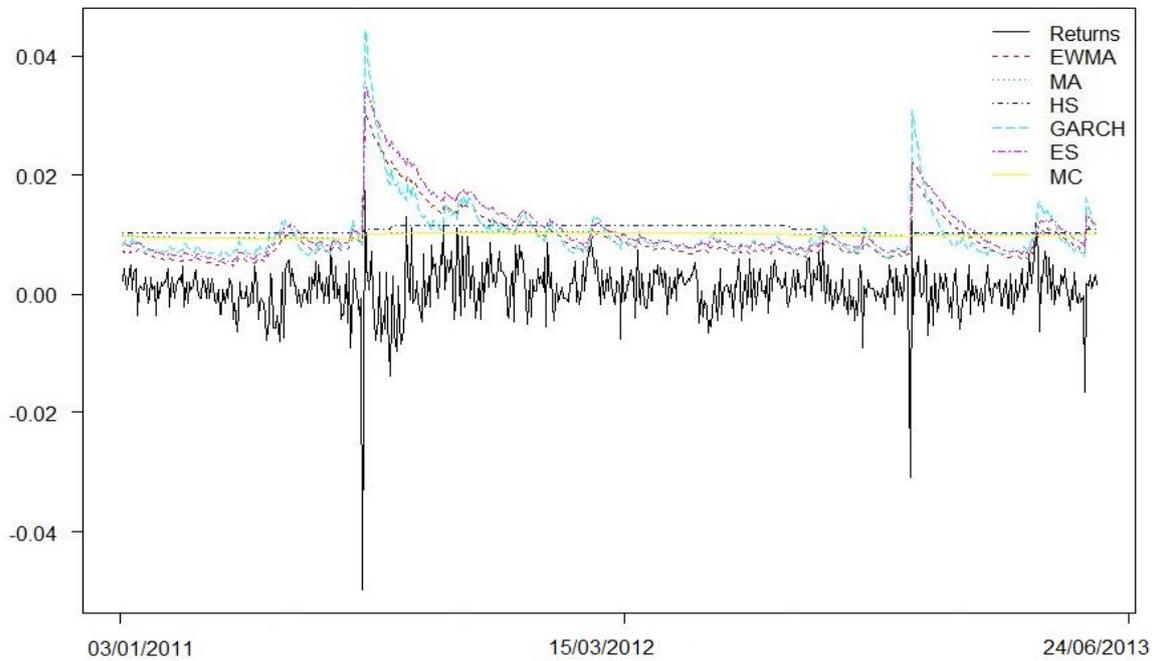
Ibov: Volatilidade de previsibilidade do VaR



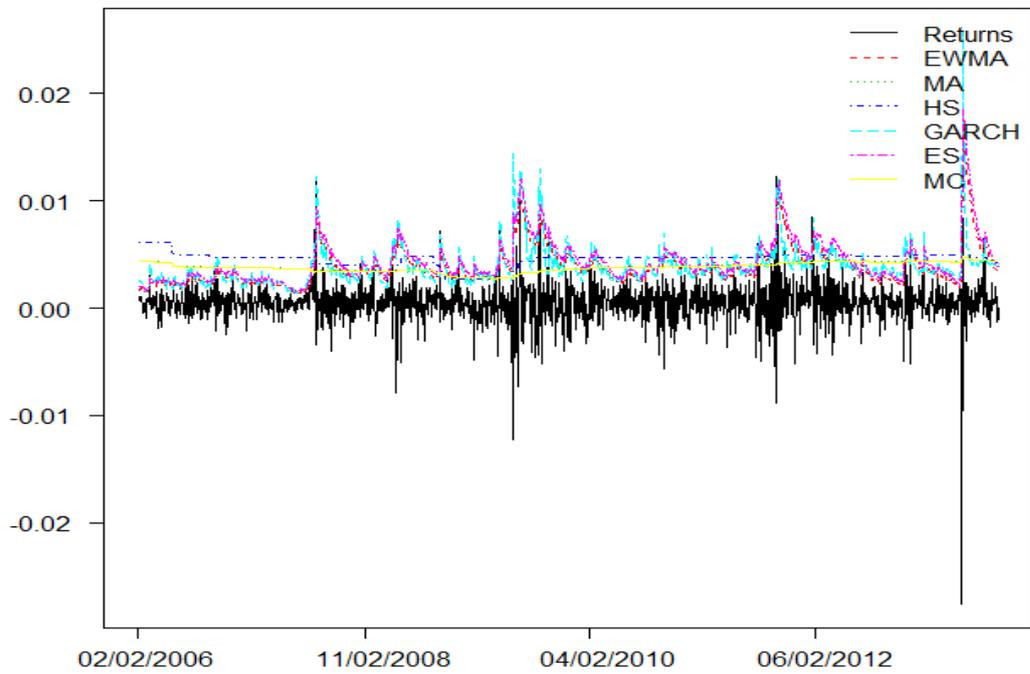
Dólar: Volatilidade de previsibilidade do *VaR*



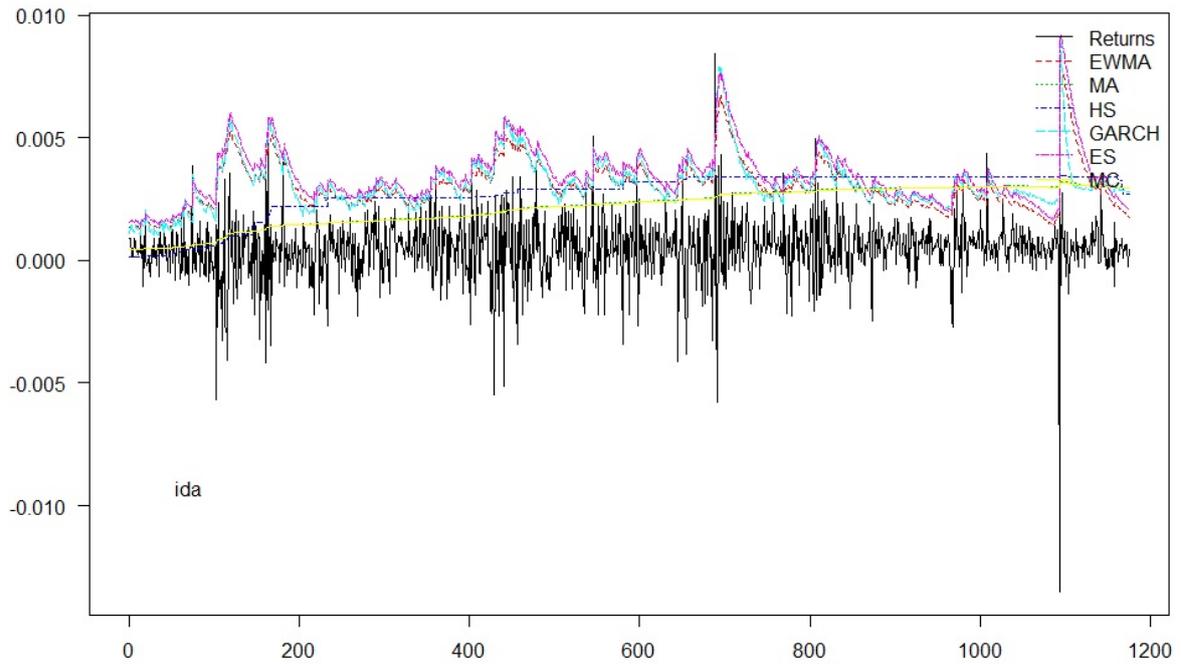
IFIX: Volatilidade de previsibilidade do *VaR*



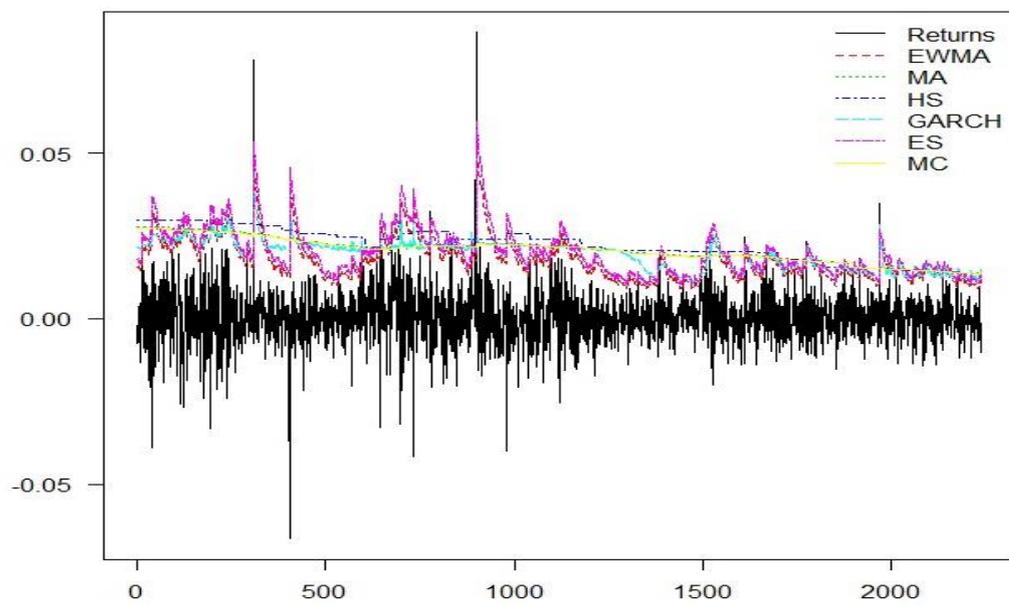
IMA-B: Volatilidade de previsibilidade do *VaR*



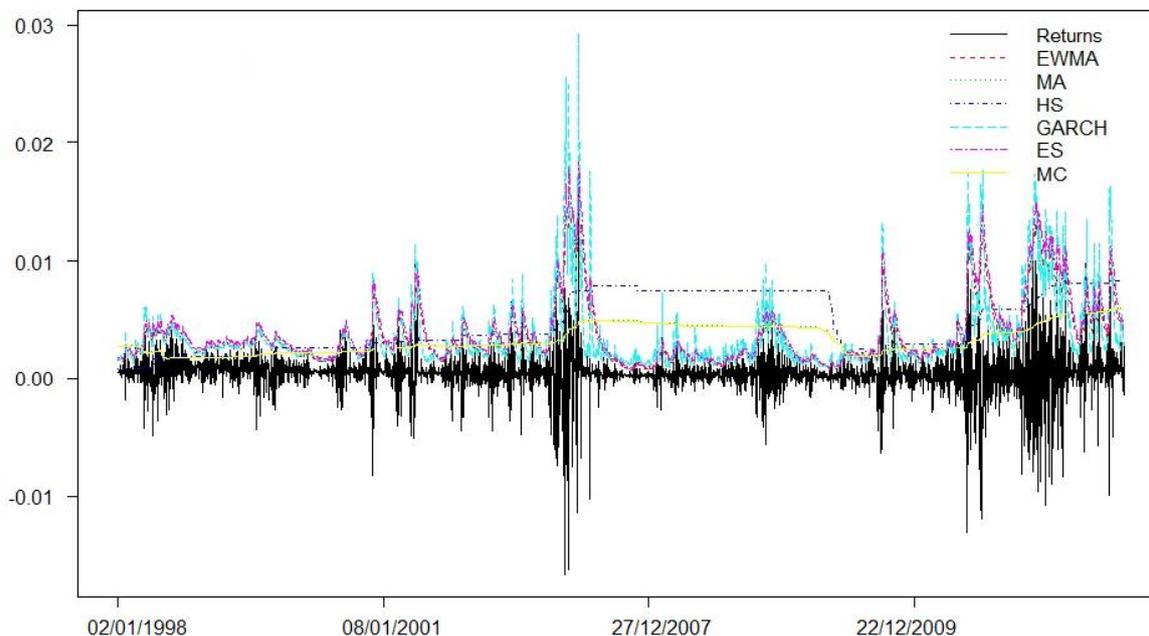
IDA: Volatilidade de previsibilidade do *VaR*



ICB: Volatilidade de previsibilidade do VaR



LP 200: Volatilidade de previsibilidade do *VaR*



7.2 Resultados da estimação do índice de violação, volatilidade e testes estatísticos para janela de estimação de 1000 dias

IBOV						
Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.76	0.0157	19.03	0	0.05	0.82
Delta	1.36	0.01	4.68	0.03	7.44	0
HS	0.98	0.0157	0.012	0.91	7.48	0
GARCH	1.31	0.0131	3.51	0.06	1.38	0.24
ES	1.41	0.009	0.87	0.35	1.08	0.29
MC	0.71	0.0207	5.99	0.01	6.94	0

Dólar						
Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.14	0.01	0.75	0.39	2.5	0.11

Delta	1.56	0.003	10.92	0	26.01	0
HS	1.31	0.005	3.62	0.06	26.62	0
GARCH	1.06	0.011	0.17	0.68	0.49	0.48
ES	1.61	0.003	3.6	0.06	5.69	0.02
MC	1.58	0.01	12.79	0	24.91	0

IMA-B

Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.2	0.001	0.73	0.39	4.74	0.03
Delta	1.56	0.0004	5.29	0.02	6.51	0.01
HS	1.15	0	0.41	0.52	5.1	0.02
GARCH	0.99	0.002	0	0.97	0.38	0.54
ES	1.62	0.0006	2.25	0.13	0.18	0.67
MC	1.6	0.0004	6.24	0.01	6.16	0.01

IDA

Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.37	0	0.83	0.36	0.39	0.53
Delta	4.08	0.0008	63.75	0	3.69	0.05
HS	4.25	0.0007	69.58	0	10.97	0
GARCH	0.85	0.001	0.27	0.59	0.17	0.68
ES	4.17	0.001	11.94	0	6.14	0.01
MC	1.49	0.001	74.44	0	2.81	0.09

ICB

Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.43	0.006	3.69	0.05	0.93	0.33
Delta	0.45	0.003	8.71	0	4.5	0.03
HS	0.45	0.005	8.71	0	4.5	0.03
GARCH	0.71	0.004	2.03	0.15	2.66	0.1
ES	0.49	0.003	0.27	0.61	0.36	0.55
MC	1.23	0.007	7.18	0	4.11	0.04

IFIX

Modelo	Índice de violação	Volatilidade IBOV	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.19	0.0044	0.17	0.67	0.14	0.7
Delta	0.4	0.0003	2.43	0.12	0.02	0.89

HS	0.4	0.0006	2.41	0.12	0.02	0.9
GARCH	0.8	0.0048	0.24	0.62	0.06	0.8
ES	0.59	0.0003	0.24	0.62	0.06	0.8
MC	0.8	0.0006	0.98	0.32	0.03	0.85

LP 200

Modelo	Índice de violação	Volatilidade IBOV	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
EWMA	1.74	0.002	17.29	0	2.16	0.14
Delta	3.38	0.001	133.75	0	58.09	0
HS	2.29	0.002	47.13	0	25.49	0
GARCH	1.4	0.003	5.45	0.01	1.5	0.21
ES	3.38	0.001	0.96	0.33	0.37	0.54
MC	1.2	0.003	133.75	0	58.09	0

7.3 Resultados da estimação do índice de violação, volatilidade e testes estatísticos para janela de estimação de 252 dias

Ibov							
Ano	Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2005-2007	EWMA	2.05	0.005	4.17	0.04	0.26	0.61
	Delta	2.66	0.003	9.37	0	0.41	0.52
	HS	0.82	0.002	0.17	0.68	0.04	0.85
	GARCH	2.04	0.006	4.17	0.04	0.23	0.63
	ES	1.13	0.009	0.17	0.68	0.07	0.8
	MC	2.66	0.001	9.37	0	0.71	0.4
2008-2010	EWMA	1.53	0.022	1.29	0.25	0.25	0.62
	Delta	0.96	0.021	0.01	0.92	0.09	0.76
	HS	0.19	0.03	5.17	0.02	0	0.95
	GARCH	1.72	0.017	2.27	0.13	2.2	0.14
	ES	1.15	0.009	0.3	0.58	0.06	0.8
	MC	2.69	0.001	10.28	0	0.78	0.38
2011-2013	EWMA	1.43	0.006	0.8	0.37	0.2	0.65

	Delta	0.82	0.003	0.18	0.67	0.07	0.8
	HS	0.61	0.011	0.86	0.35	0.04	0.85
	GARCH	1.22	0.005	0.23	0.63	0.15	0.7
	ES	1.04	0.006	0.18	0.67	0.07	0.8
	MC	0.82	0.003	0.18	0.67	0.07	0.8
2014-2016	EWMA	1.22	0.008	0.23	0.63	0.15	0.7
	Delta	0.41	0.002	2.23	0.14	0.02	0.9
	HS	0.61	0.003	0.86	0.35	0.04	0.85
	GARCH	0.82	0.007	0.18	0.67	0.07	0.8
	ES	1.02	0.009	2.23	0.14	0.02	0.9
	MC	0.61	0.002	0.86	0.35	0.04	0.85

Dólar

Ano	Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2005-2007	EWMA	1.01	0.008	0	0.99	4.46	0.03
	Delta	2.22	0.003	5.52	0.02	1.42	0.23
	HS	1.81	0.004	2.68	0.1	2.11	0.15
	GARCH	1.41	0.009	0.75	0.39	3.07	0.08
	ES	1.16	0.01	0.91	0.34	6.79	0.01
	MC	2.42	0.003	7.23	0.01	1.14	0.29
2008-2010	EWMA	0.8	0.008	0.23	0.63	0.06	0.8
	Delta	0.4	0.011	2.39	0.12	0.02	0.9
	HS	0.4	0.018	2.39	0.12	0.02	0.9
	GARCH	1.19	0.007	0.18	0.67	0.15	0.7
	ES	1.02	0.009	2.39	0.12	0.02	0.9
	MC	0.4	0.011	2.39	0.12	0.02	0.9
2011-2013	EWMA	1.59	0.005	1.51	0.22	0.26	0.61
	Delta	1.99	0.004	3.87	0.05	0.41	0.52
	HS	0.6	0.003	0.96	0.33	0.04	0.85
	GARCH	1.59	0.006	1.51	0.22	0.23	0.63
	ES	1.21	0.006	0.18	0.67	0.15	0.7
	MC	1.99	0.004	3.87	0.05	0.41	0.52
2014-2016	EWMA	1.1	0.006	0.05	0.83	0.1	0.75
	Delta	1.4	0.004	0.71	0.4	0.2	0.66
	HS	0.8	0.009	0.22	0.64	0.06	0.8
	GARCH	0.8	0.006	0.22	0.64	0.06	0.8

ES	1.17	0.006	0.09	0.76	0.14	0.71
MC	2.08	0.004	4.75	0.03	0.47	0.49

IDA

Ano	Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2011-2013	EWMA	0.4	0.0009	4.71	0.03	0.03	0.86
	Delta	-	-	-	-	-	-
	HS	3.3	0.0014	0.03	0.86	0.13	0.72
	GARCH	-	-	-	-	-	-
	ES	1.28	0.001	13.48	0	0	0.96
	MC	1.1	0.0008	0.1	0.75	15.19	0
2014-2016	EWMA	1.29	0.0008	0.54	0.46	0.24	0.63
	Delta	1	0.0002	0	1	0.14	0.71
	HS	0.86	0.0005	0.15	0.7	0.1	0.75
	GARCH	1	0.0006	0	1	0.14	0.71
	ES	1.07	0.0009	0.93	0.33	0.07	0.8
	MC	1.34	0.0003	0.78	0.38	0.27	0.6

IMA-B

Ano	Modelo	Índice de violação	Volatilidade IBOV	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2006-2008	EWMA	1.23	0.005	0.2	0.66	0.12	0.72
	Delta	1.47	0.002	0.8	0.37	0.18	0.67
	HS	0.74	0.002	0.32	0.57	0.04	0.83
	GARCH	1.23	0.007	0.2	0.66	0.12	0.72
	ES	1.35	0.002	2.23	0.14	6.67	0.01
	MC	1.62	0	2.23	0.14	6.67	0.01
2009-2011	EWMA	0.88	0.005	0.07	0.79	0.07	0.79
	Delta	0.22	0.01	4.1	0.04	0	0.95
	HS	0.22	0.016	4.1	0.04	0	0.95

	GARCH	1.1	0.005	0.04	0.83	0.11	0.74
	ES	1.02	0.006	1.83	0.18	0.02	0.89
	MC	0.22	0.01	4.1	0.04	0	0.95
2012-2014	EWMA	1.54	0.005	1.16	0.28	0.22	0.64
	Delta	2.2	0.003	4.94	0.03	0.45	0.5
	HS	0.88	0.003	0.07	0.79	0.07	0.79
	GARCH	1.32	0.006	0.43	0.51	0.16	0.69
	ES	1.24	0.006	0.05	0.83	0.11	0.74
	MC	2.2	0.003	4.94	0.03	0.45	0.5
2015-2016	EWMA	1.11	0.006	0.05	0.82	0.11	0.74
	Delta	1.55	0.004	1.18	0.28	0.22	0.64
	HS	1.11	0.006	0.05	0.82	0.11	0.74
	GARCH	0.88	0.006	0.06	0.8	0.07	0.79
	ES	1.17	0.007	0.59	0.44	0.04	0.84
	MC	1.55	0.003	1.18	0.28	0.22	0.64

ICB

Ano	Modelo	Índice de violação	Volatilidade IBOV	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2005-2007	EWMA	2.07	0.004	2.12	0.14	0.21	0.65
	Delta	2.07	0.001	2.12	0.14	0.21	0.65
	HS	1.65	0.005	0.87	0.35	0.14	0.71
	GARCH	2.07	0.003	2.12	0.14	0.21	0.65
	ES	1.11	0.004	0.08	0.78	0.03	0.85
	MC	2.07	0.001	2.12	0.14	0.21	0.65
2008-2010	EWMA	1.66	0.006	0.88	0.35	0.14	0.71
	Delta	2.9	0.002	5.84	0.02	1.78	0.18
	HS	1.24	0.004	0.14	0.71	5.35	0.02
	GARCH	1.24	0.006	0.14	0.71	0.08	0.78
	ES	1.24	0.007	0.14	0.71	0.08	0.78

	MC	2.9	0.002	5.84	0.02	1.78	0.18
2011-2013	EWMA	1.22	0.004	0.23	0.63	0.15	0.7
	Delta	0.2	0.004	4.67	0.03	0	0.95
	HS	0.41	0.004	2.24	0.13	0.02	0.9
	GARCH	0.41	0.005	2.24	0.13	0.02	0.9
	ES	1.12	0.005	0.62	0.43	0.19	0.66
	MC	0.39	0.004	2.51	0.11	0.02	0.9
2014-2016	EWMA	1.43	0.002	0.8	0.37	0.2	0.65
	Delta	0.61	0.001	0.86	0.35	0.04	0.85
	HS	1.22	0.001	0.23	0.63	0.15	0.7
	GARCH	0.82	0.002	0.18	0.67	0.07	0.8
	ES	1.04	0.003	0.18	0.67	0.07	0.8
	MC	0.82	0.001	0.18	0.67	0.07	0.8

IFIX

Ano	Modelo	Índice de violação	Volatilidade IBOV	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2011-2013	EWMA	2.64	0.003	7.79	0.01	4.88	0.03
	Delta	1.44	0.001	0.71	0.4	0.18	0.68
	HS	1.2	0.003	0.16	0.69	0.12	0.73
	GARCH	1.44	0.003	0.71	0.4	0.18	0.68
	ES	1.17	0.007	0.59	0.44	0.04	0.84
	MC	1.55	0.003	1.18	0.28	0.22	0.64
2014-2016	EWMA	1.11	0.005	0.04	0.84	0.09	0.76
	Delta	1.67	0.002	1.35	0.25	0.2	0.65
	HS	0.83	0.001	0.11	0.74	0.05	0.82
	GARCH	1.11	0.007	0.04	0.84	0.09	0.76
	ES	2.12	0.006	0.11	0.74	0.05	0.82
	MC	1.67	0.002	1.35	0.25	0.2	0.65

LP 200

Ano	Modelo	Índice de violação	Volatilidade	Teste Estatístico (Kupiec)	P-value	Teste Estatístico (Coverage)	P-value
2005-2007	EWMA	2.41	0.001	7.2	0.01	0.6	0.44
	Delta	2.62	0.001	9.07	0	0.91	0.34
	HS	0.6	0	0.92	0.34	0.04	0.85
	GARCH	1.41	0.002	0.74	0.39	0.2	0.65

	ES	1.12	0.002	1.58	0.21	0.26	0.61
	MC	2.62	0.001	9.07	0	0.91	0.34
2008-2010	EWMA	0.8	0.001	0.23	0.63	0.06	0.8
	Delta	0.99	0.003	0	0.99	0.1	0.75
	HS	0.4	0.006	2.39	0.12	0.02	0.9
	GARCH	0.8	0.001	0.23	0.63	0.06	0.8
	ES	1.51	0.002	0.23	0.63	0.06	0.8
	MC	0.99	0.003	0	0.99	0.1	0.75
2011-2013	EWMA	1.59	0.002	1.51	0.22	2.57	0.11
	Delta	1.79	0.001	2.58	0.11	13.92	0
	HS	1.2	0.002	0.18	0.67	10.87	0
	GARCH	0.6	0.002	0.96	0.33	0.04	0.85
	ES	1.22	0.002	0.96	0.33	0.04	0.85
	MC	1.79	0.001	2.58	0.11	13.92	0
2014-2016	EWMA	1.59	0.003	1.51	0.22	0.26	0.61
	Delta	1.99	0.001	3.87	0.05	0.41	0.52
	HS	0.2	0.001	4.85	0.03	0	0.95
	GARCH	1.79	0.003	2.58	0.11	0.33	0.57
	ES	1.29	0.003	0	0.99	0.1	0.75
	MC	1.99	0.001	3.87	0.05	0.41	0.52

7.3 Códigos utilizados na programação R

```
#####Estatística Descritiva
library("PerformanceAnalytics")
"ativo"<- read.table(file='ativo.csv', sep=';', dec = '.',
header=T)
ativo$Data = as.Date(ativo$Data, format="%d/%m/%Y")
Retorno <-xts(x = ativo$Retorno,order.by = ativo$Data)
table.Stats(Retorno)
library(moments)
jarque.test(ativo$Retorno)
```

```

library("car")
qqPlot(Retorno, distribution = "norm", mean = 0, sd= 1, main="ativo", xlab="Quantil
normal", ylab="Quantil Retorno")

#####3índice de violação e teste estatístico

“ativo” <- read.table(file=”ativo”.csv', sep=';', dec = '.',header=T)
“ativo”$Data = as.Date(ativo$Data, format="%d/%m/%Y")
y= “ativo”$Retorno
y=coredata(y)
TT = length(y)
WE = 1000
p = 0.01
l1 = WE * p
value = 1
VaR = matrix(nrow=TT,ncol=4)
lambda = 0.94;
s11 = var(y[1:30]);
for(t in 2:WE) s11 = lambda * s11 + (1 - lambda) * y[t - 1]^2
for (t in (WE + 1):TT){
t1 = t - WE;
t2 = t - 1;
window = y[t1:t2]
s11 = lambda * s11 + (1 - lambda) * y[t - 1]^2
VaR[t,1] = -qnorm(p) * sqrt(s11) * value
VaR[t,2] = -sd(window) * qnorm(p)* value
ys = sort(window)
VaR[t,3] = -ys[l1]* value
g=garchFit(formula = ~ garch(1,1), window ,trace=FALSE,
include.mean=FALSE)
par=g@fit$matcoef

```

```

s4=par[1]+par[2]* window[WE]^2+par[3]* g@h.t[WE]
VaR[t,4] = -sqrt(s4) * qnorm(p) * value
}
W1=WE+1
for (i in 1:4){
VR = sum(y[W1:TT]< -VaR[W1:TT,i])/(p*(TT-WE))
s = sd(VaR[W1:TT,i])
cat(i,"VR",VR,"VaR vol",s,"\n")
}
bern_test=function(p,v){
lv=length(v)
sv=sum(v)
al=log(p)*sv+log(1-p)*(lv-sv)
bl=log(sv/lv)*sv +log(1-sv/lv)*(lv-sv)
return(-2*(al-bl))
}
ind_test=function(V){
J=matrix(ncol=4,nrow=length(V))
for (i in 2:length(V)){
J[i,1]=V[i-1]==0 & V[i]==0
J[i,2]=V[i-1]==0 & V[i]==1
J[i,3]=V[i-1]==1 & V[i]==0
J[i,4]=V[i-1]==1 & V[i]==1
}
V_00=sum(J[,1],na.rm=TRUE)
V_01=sum(J[,2],na.rm=TRUE)
V_10=sum(J[,3],na.rm=TRUE)
V_11=sum(J[,4],na.rm=TRUE)
p_00=V_00/(V_00+V_01)
p_01=V_01/(V_00+V_01)
p_10=V_10/(V_10+V_11)

```

```

p_11=V_11/(V_10+V_11)
hat_p=(V_01+V_11)/(V_00+V_01+V_10+V_11)
a=(1-hat_p)^(V_00+V_10)*(hat_p)^(V_01+V_11)
b=(p_00)^(V_00)*(p_01)^(V_01)*(p_10)^(V_10)*p_11^(V_11)
return(-2*log(a/b))
}
W1=WE+1
ya=y[W1:TT]
VaRa=VaR[W1:TT,]
m=c("MA","EWMA","HS","GARCH")
for (i in 1:4){
q= y[W1:TT]< -VaR[W1:TT,i]
v=VaRa*0
v[q,i]=1
ber=bern_test(p,v[,i])
ind=ind_test(v[,i])
cat(i,m[i],'Bernoulli',ber,1-pchisq(ber,1),"independence",ind,1-pchisq(ind,1),"\n")
}
#####ES & MC
T = length(y)
WE = 1000
p = 0.01
l1 = WE*p
value = 1
VaR = matrix(nrow=T,ncol=4)
lambda = 0.94
x<-runif(1e7, max=0.99, min=-0.99)
mc=sort(x)*qnorm(0.01)
s11 = var(y[1:30])
for(t in 2:WE) s11 = lambda * s11 + (1-lambda) * y[t-1]^2
for (t in (WE+1):T){

```

```

t1 = t-WE
t2 = t-1
window = y[t1:t2]
s11 = lambda * s11 + (1-lambda) * y[t-1]^2
VaR[t,1] = -1*(VaR(window, alpha = 0.01, type = "sample", tail = c("lower", "upper")))
VaR[t,2] = -1*(CVaR(window, alpha = 0.01, type = "sample", tail = c("lower", "upper")))
ES[t,3] = sqrt(s11) * dnorm(qnorm(p)) / p
yd= mc*sd(window)
VaR[t,4] = -yd[1e7]*value
}
W1=WE+1
ESa = ES[W1:TT,]
VaRa = VaR[W1:TT,]
for (i in 1:2){
q = ya <= -VaRa[,i]
nES = mean(ya[q] /-ESa[q,i])
cat(i,"nES",nES,"\n")
}
W1=WE+1
for (i in 1:4){
VR = sum(y[W1:T]< -VaR[W1:T,i])/(p*(T-WE))
s = sd(VaR[W1:T,i])
cat(i,"VR",VR,"VaR vol",s,"\n")
}

```