

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE CIÊNCIAS ECONÔMICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA**

PEDRO GERHARDT GAVRONSKI

RISCO SISTÊMICO NO SISTEMA FINANCEIRO AMERICANO

Porto Alegre

2017

PEDRO GERHARDT GAVRONSKI

RISCO SISTÊMICO NO SISTEMA FINANCEIRO AMERICANO

Dissertação submetida ao Programa de Pós-Graduação em Economia da Faculdade de de Ciências Econômicas da UFRGS, como quesito parcial para obtenção do título de Mestre em Economia, com ênfase em Economia Aplicada.

Orientador: Prof.Dr. Flávio Augusto Ziegelmann

Porto Alegre

2017

CIP - Catalogação na Publicação

Gavronski, Pedro Gerhardt
Risco Sistêmico no sistema financeiro Americano /
Pedro Gerhardt Gavronski. -- 2017.
37 f.
Orientador: Flávio Augusto Ziegelmann.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Faculdade de Ciências Econômicas,
Programa de Pós-Graduação em Economia, Porto Alegre,
BR-RS, 2017.

1. Risco. 2. GAS. 3. CDS. I. Ziegelmann, Flávio
Augusto, orient. II. Título.

PEDRO GERHARDT GAVRONSKI

RISCO SISTÊMICO NO SISTEMA FINANCEIRO AMERICANO

Dissertação submetida ao Programa de Pós-Graduação em Economia da Faculdade de Ciências Econômicas da UFRGS, como quesito parcial para obtenção do título de Mestre em Economia, com ênfase em Economia Aplicada.

Aprovado em: Porto Alegre, 11 de Agosto de 2017.

BANCA EXAMINADORA

Prof. Dr. Flávio Ziegelmann - Orientador
PPGE - UFRGS

Prof. Dr. Cristiano Fernandes
DEE - PUC RJ

Prof. Dr. Emerson Marçal
FGV EESP

Prof. Dr. Márcio Poletti Laurini
FEA - USP RP

AGRADECIMENTO

Eu gostaria, primeiramente, agradecer e dedicar essa dissertação aos meus avós Arnaldo, Irma e Eros cuja conduta ética e profissional foram essenciais para a minha formação. Aos meus pais por terem me apoiado de todas as formas possíveis durante o mestrado, e em todas as demais partes da minha vida. Gostaria de fazer também um agradecimento a todos os colegas do mestrado, em especial Andrés Clavijo, Cláudio Samanaez, Frederico Castro, Giovani Baggio, Lucas Tesser, Luís Zago e Ricardo Schuch cujas conversas e idas aos sábados na biblioteca da PUCRS vão ficar guardados para sempre na memória. Por fim, não menos importante, gostaria de agradecer ao meu orientador, Flávio Augusto Ziegelmann, cuja amizade e enorme paciência tornaram possíveis a realização deste trabalho.

RESUMO

O objetivo deste artigo é propor uma nova maneira de mensurar o risco sistêmico do sistema financeiro e identificar as instituições financeiras sistemicamente importantes utilizando a teoria dos valores extremos e modelos da classe GAS. Para demonstrar a qualidade da nossa medida de risco, nós comparamos a nossa medida de risco com o BSI através de um horse race proposta por Rodríguez-Moreno e Peña (2013). Os nossos resultados apontam que a nossa medida tem boas características, porque a horse race entre ela e o BSI gerou um empate e que a instituição que teve maior influência na nossa amostra foi o JP Morgan, ao passo que a instituição menos relevante foi a AIG.

Palavras-chaves: Risco.GAS.CDS

ABSTRACT

The objective of this paper is to propose a new way of measuring the systemic risk of the financial system and to identify the systemically important financial institutions using the theory of extreme values and GAS class models. To demonstrate the quality of our risk measure, we compare our risk measure with the BSI through a horse race proposed by Rodríguez-Moreno e Peña (2013). Our results indicate that our measure has good characteristics because the horse race between it and BSI generated a tie and that the institution that had the greatest influence in our sample was JP Morgan, whereas the institution less was AIG.

Key-words: Risk. GAS. CDS.

SUMÁRIO

1	INTRODUÇÃO	8
2	MEDIDAS DE RISCO	11
3	ESTRATÉGIA EMPÍRICA E METODOLOGIA	16
3.1	MODELO	16
3.2	<i>HORSE RACE</i> E IDENTIFICAÇÃO DE INSTITUIÇÕES SISTEMICAMENTE IMPORTANTES	19
3.3	DADOS	21
4	RESULTADOS	25
4.1	RESULTADOS DOS PROCESSOS ARMA-Garch e ARMA-IGarch	25
4.2	RESULTADOS DA <i>HORSE RACE</i>	25
4.3	INSTITUIÇÕES SISTEMICAMENTE IMPORTANTES	31
5	CONSIDERAÇÕES FINAIS	34
	REFERÊNCIA	35

1 INTRODUÇÃO

As crises financeiras são eventos recorrentes nas economias, as quais causam grandes prejuízos para a sociedade, conforme reportado por Kindleberger (2005) e Reinhart e Rogoff (2010). Elas são resultados do acúmulo de risco gerado no sistema financeiro, por isso policy makers e pesquisadores de instituições multilaterais como o Bank of International Settlements ("BIS") tentam encontrar formas de medir o risco do sistema financeiro. No entanto, o advento da crise financeira de 2007 demonstrou que as medidas formuladas até então não tiveram o desempenho esperado, ou seja, existe espaço para propor novas formas de medir o risco do mercado financeiro.

Kindleberger (2005) segue a linha clássica do economista Hyman Minsky, e defende que o risco do sistema financeiro é gerado pela combinação de um choque exógeno que torna as pessoas otimistas em relação aos retornos de um ativo, um aumento no volume de crédito na economia. Esse autor considera que o choque positivo leva os agentes econômicos a ficarem mais otimistas, e assim mais dispostos a adquirir ativos financeiros. Simultaneamente, os bancos iriam fornecer quantidades crescentes de recursos para financiar essas compras. A combinação desses eventos faria com que os preços dos ativos financeiros aumentassem rapidamente. Os agentes econômicos, então, se tornariam especuladores, pois começariam a transacionar os ativos em função da expectativa de vendê-los por um preço maior no futuro. Nessa fase, o processo de endividamento se intensificaria, e os indivíduos não conseguiriam gerar recursos suficientes nem para pagar os juros dos seus empréstimos. Os bancos continuariam a renovar os empréstimos, porque os preços dos ativos financiados estariam aumentando, e porque estariam contaminados por um sentimento de euforia.

Esse processo teria um fim quando ocorresse um choque negativo na economia, porque ele levaria as pessoas a entrarem em pânico e a vender os seus ativos. Em consequência disso, os preços dos ativos financeiros cairiam substancialmente, fazendo com que os agentes econômicos sofressem perdas elevadas. Os bancos, então, reconheceriam os prejuízos com os empréstimos, e reduziriam significativamente o volume de crédito na economia, levando a uma crise econômica.

Essa visão sugere que o risco do mercado financeiro seria oriundo de um choque exógeno. Entretanto, Freixas, Laeven e Peydró (2015) afirmam que as pesquisas mais modernas consideram que o risco é resultado direto das decisões dos indivíduos, ou seja, ele é endógeno ao sistema econômico. As abordagens atuais consideram que o risco é causado por fatores comportamentais, problemas de agência, ou pela estrutura de mercado.

A abordagem comportamental considera que comportamentos irracionais são os responsáveis pelo acúmulo de risco no sistema financeiro. Desta linha de pesquisa, destacamos o trabalho de Gennaioli, Shleifer e Vishny (2013), no qual as instituições financeiras ignoram a ocorrência de eventos extremos. O pressuposto central desse modelo é que as pessoas são infini-

tamente avessas ao risco, ou seja, só financiam os ativos que tenham fluxos de caixa garantidos. Isso leva os intermediários financeiros a adotarem técnicas de securitização¹ para criarem portfólios com o menor risco possível. Eles utilizam esses portfólios como lastro de suas dívidas, e prometem a pagar aos investidores um retorno compatível com o pior cenário econômico. Quando as instituições financeiras ignoram os eventos extremos, elas prometem pagar um retorno maior do que o seria possível durante uma crise econômica. Assim, na presença um choque, os intermediários financeiros não seriam capazes de saldarem as suas dívidas, o que levaria a uma crise financeira.

Outro exemplo dessa linha de pesquisa é o artigo de Campbell e Cochrane (1999). Neste trabalho, os autores consideram que o consumo atual gera utilidade para as pessoas quando ele for maior que o nível médio de consumo passado. Através de exercícios numéricos, eles demonstram que em períodos de euforia², os indivíduos aceitariam um prêmio de risco menor para adquirir ativos financeiros. Já nos momentos em que o consumo não ultrapassa a sua média histórica, as pessoas pediriam um prêmio de risco bastante elevado para investir no mercado financeiro. Ou seja, quando ocorresse um choque negativo na economia, as pessoas começariam a vender os seus ativos, porque eles não conseguiriam gerar o retorno esperado por elas.

Na segunda linha de pesquisa, considera-se que os incentivos criados pelo mercado levam os agentes econômicos a tomarem riscos excessivos. Dentre os artigos dessa linha de pesquisa destacamos os trabalhos de Rajan (1994) e Agarwal e Ben-David (2014). O primeiro autor analisa as consequências dos executivos do mercado financeiro se importarem com a sua reputação. Ele identifica que os executivos teriam incentivos de esconder os resultados ruins dos empréstimos, porque levaria o mercado a considerar esses executivos como incompetentes. Eles tentariam ocultar os prejuízos através da adoção de políticas liberais de crédito, como por exemplo, renovação de linhas de créditos e novos desembolsos para clientes com desempenho ruim. A consequência disso é que o banco vai aumentar a sua exposição a clientes ruins, e assim ficar mais vulnerável a choques na economia.

Agarwal e Ben-David (2014) analisam os efeitos de mudanças na estrutura de incentivos no desempenho dos funcionários da área de crédito de um grande banco dos EUA. No caso, o banco começou a compensar os seus funcionários pelo volume de crédito originado. Os resultados reportados pelos autores indicam que o volume de crédito liberado e a taxa de inadimplência aumentaram, apesar de não terem ocorrido mudanças significativas nas características dos tomadores de empréstimos. O aumento da taxa de default, segundo Agarwal e Ben-David (2014), foi causado pelos responsáveis pela aprovação do crédito. Os autores argumentam que esses funcionários começaram a dar menor peso à opinião dos executivos da área comercial do que para os modelos estatísticos, porque temiam que eles estivessem manipulando as informações. En-

¹ Securitização se refere ao processo de construir um portfólio com os empréstimos bancários para serem vendidos para investidores no mercado.

² Segundo os autores, os períodos de euforia seriam aqueles momentos em que o consumo corrente seria maior que a média de consumo passado.

tretanto, essa estratégia se mostrou equivocada, pois os modelos tinham sido estimados usando os empréstimos originados sob a política de crédito anterior, ou seja, os modelos subestimaram o risco das novas operações de crédito, levando a um aumento da inadimplência.

A terceira linha de pesquisa tem como objetivo estudar os efeitos do nível de competição, da desregulamentação e das inovações financeiras sobre o risco do mercado financeiro. Desta abordagem destacamos o artigo de Martinez-Miera e Repullo (2010), no qual os autores estudam os efeitos da competição sobre o risco do sistema financeiro. Eles identificam que o nível de competição influencia o risco dos bancos através dos efeitos risk-shifting e margin. Através do primeiro efeito um nível maior de competição diminuiria o risco, porque uma taxa de juros menor, segundo os autores, levaria os bancos a financiar projetos menos arriscados. Já o segundo efeito tem o resultado oposto sobre o risco, pois uma taxa de juros menor não permitiria que as instituições financeiras tivessem recursos suficientes para absorver os prejuízos com as operações de crédito.

O risco do mercado financeiro, segundo Hansen (2012), é formado pelo risco sistemático e o risco sistêmico. Esse autor define o primeiro componente como as perdas oriundas de choques macroeconômicos que não podem ser evitados por técnicas de diversificação, e afirma que não há um consenso sobre o conceito do segundo elemento. Segundo Smaga (2014), a definição de risco sistêmico muda de acordo com o elemento que o pesquisador ou órgão regulador queira enfatizar. O foco deste trabalho será o risco sistêmico, pois ele seria o componente do risco do mercado financeiro sobre o qual os órgãos reguladores poderiam atuar.

O objetivo deste trabalho é propor uma nova medida de risco sistêmico a partir do conceito dado por Freixas, Laeven e Peydró (2015), os quais definem esse risco como *the risk of the impairment of the financial system with strong negative consequences for the broader economy*. A nossa medida irá se basear no spread dos Credit Default Swaps ("CDS") das instituições financeiras, e ela será estimada através da junção dos modelos da classe Generalized Autoregressive Score ("GAS") e a teoria dos valores extremos.

Para demonstrar a qualidade da nossa medida de risco, comparamos ela com a métrica de risco proposta por Basurto e Goodhart (2009) através de uma horse race baseada nas ideias de Rodríguez-Moreno e Peña (2013). Em seguida, mostramos que através da nossa medida também é possível identificar e ordenar as instituições sistemicamente importantes, ou seja, conseguiremos apontar dentro da nossa amostra quais têm maior influência sobre o risco sistêmico. Este trabalho contém quatro seções além desta introdução: medidas de risco, estratégia empírica, resultados e considerações finais. A segunda seção tem como objetivo apresentar algumas das medidas de risco sistêmico utilizadas, enquanto a terceira explicará como construímos a nossa medida de risco, além de como realizamos o teste de comparação. Por fim, nas duas últimas seções apresentamos os resultados, e fazemos as nossas considerações finais. mos os resultados, e fazemos as nossas considerações finais.

2 MEDIDAS DE RISCO

O BIS (2011) propôs um indicador para identificar os bancos que tivessem uma grande influência no sistema financeiro global. Essa medida seria construída para captar 5 aspectos da instituição financeira, são estes: atividade interjurisdicional, tamanho, interconexão, substituíbilidade e complexidade. O primeiro aspecto tem como objetivo medir o nível de contágio entre países, usando como medida o volume de operações que um banco possui no exterior. A segunda dimensão tenta medir a importância que uma instituição financeira possui no mercado financeiro através do volume de operações financeiras. Ou seja, ela tenta captar o nível de risco absorvido por essa empresa. Já o aspecto da interconexão mensura o processo de difusão de choques no sistema financeiro através das relações contratuais dessas empresas. O aspecto da substituíbilidade mede a importância que uma determinada instituição financeira tem na realização de serviços, como custódia, subscrição, entre outros. E por fim, a última dimensão tentaria verificar a complexidade das operações dos bancos, a qual é mensurada a partir do volume de operações que o banco possui no mercado de balcão. O indicador seria calculado fazendo uma ponderação dessas dimensões, sendo que todos os elementos teriam o mesmo peso, ou seja, 20%. E então, a partir do nível do indicador, verificar quais instituições precisariam aumentar o seu nível de capital. O ponto positivo dessa abordagem é que ela é simples, e capta diferentes características do risco sistêmico. Porém ela é muito dependente de informações contábeis, as quais só podem ser fornecidas em longos períodos de tempo, além da forma de ponderação das variáveis ser um tanto arbitrarias.

Bisias et al. (2012) fizeram uma revisão bibliográfica de cerca de 31 métodos de medir o risco sistêmico. Hansen (2012) argumenta que essa grande quantidade de medidas é resultado da falta de consenso sobre a definição do risco sistêmico. Por isso relatamos apenas as técnicas baseadas em distribuição de probabilidades, já que a medida de risco proposta por nós pertence a essa classe. As medidas analisadas são as seguintes: a distância Mahalanobis, as medidas baseadas na densidade multivariada, CoVaR, Co-Risk e Systemic Expected Shortfall.

A primeira medida considera que o comportamento dos preços dos ativos durante as crises financeiras é muito diferente do seu padrão histórico, podendo atingir valores extremos. Essa técnica sugere calcular o quadrado da distância Mahalanobis, que é definida pela equação 2.1 e assim definir como períodos turbulentos, aqueles em que a medida está acima do 75º percentil. O ponto positivo dessa medida é que ela incorpora o valor de mercado das instituições financeiras, mas os resultados empíricos indicam, segundo Bisias et al. (2012), que essa medida tem melhor desempenho quando usada para analisar as consequências da crise financeira, não para antecipá-las.

Seja

$$d_t = (r_t - m)' \Sigma^{-1} (r_t - m), \quad (2.1)$$

a distância Mahalanobis, onde d_t é o valor da distância Mahalanobis no período t , r_t é o vetor de retornos dos ativos no tempo t , m é o vetor das médias amostrais do retorno dos ativos, e Σ é a matriz das covariâncias dos retornos dos ativos.

A segunda abordagem consiste em estimar a densidade multivariada do sistema financeiro, e assim construir indicadores de risco sistêmico. Essa estratégia utiliza o método proposto por Segoviano (2006) para obter a distribuição multivariada dos valores dos ativos das instituições financeiras. O método tem como objetivo encontrar a densidade multivariada do valor dos ativos do sistema financeiro ao minimizar a diferença Kullback- Leibler, a qual é definida pela equação 2.2, impondo as restrições de que a integral em R^n da densidade multivariada deve ser igual a 1, onde n representa a quantidade de ativos totais do sistema financeiro, e que ela seja consistente com a probabilidade de default individual de cada uma das instituições, como mostra a equação 2.2. O resultado final deste processo de minimização é dada pela equação 2.3, a qual nos possibilita expressar a densidade multivariada dos ativos do sistema financeiro através de uma densidade multivariada a priori $q()$, dos multiplicadores de Lagrange da minimização restrita da diferença Kullback- Leibler, e dos limiares de default das instituições financeiras. A partir desta equação, Segoviano (2006) propõem duas medidas de risco, o Joint Probability of default ("JPOD"), e o Bank Stability Index ("BSI"), as quais são representadas, respectivamente, pelas equações 2.4 e 2.5. O JPOD representa a probabilidade de todas as empresas entrarem em default, e o BSI¹ calcula a quantidade esperada das instituições problemáticas dado que pelo menos uma delas entrou em default. O problema de utilizarmos o método por Segoviano (2006) para obter a densidade multivariada dos ativos do sistema financeiro é que precisamos definir arbitrariamente a função $q()$, e Rodríguez-Moreno e Peña (2013) argumentam que esses métodos são difíceis de calcular quando temos um grande número de ativos. Seja

$$\min_{p(x_1, \dots, x_n)} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p(x_1, \dots, x_n) \log \frac{p(x_1, \dots, x_n)}{q(x_1, \dots, x_n)} \partial x_1 \dots \partial x_n$$

s.a.

$$POD_i^t = \int_{-\infty}^{\infty} \dots \int_{x_i^d}^{\infty} \dots \int_{-\infty}^{\infty} p(x_1, \dots, x_n) I(x_i < x_i^d) \partial x_1 \dots \partial x_n \forall i, t, \quad (2.2)$$

$$1 = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p(x_1, \dots, x_n) \partial x_1 \dots \partial x_n,$$

a representação do processo de minimização restrita da diferença Kullback-Leibler, onde $p()$ é a densidade multivariada dos ativos das instituições financeiras, $q()$ é uma distribuição a priori para a distribuição multivariada dos ativos das instituições financeiras, x_i é o valor do CDS do banco i , $I(x_i < x_i^d)$ é uma função indicadora que assume o valor 1 quando $x_i < x_i^d$, e 0

¹ É possível mostrar que o valor esperado das instituições financeiras que entram em default dado que uma delas apresentou problemas através das probabilidades de default, como mostra a equação 2.5.

caso contrário, POD_t^i é a probabilidade de default empírica da instituição i no tempo t , e μ e λ_i são os multiplicadores de Lagrange, respectivamente, das restrições que garantem que a integral múltipla de $p()$ seja igual a 1 e que ela seja consistente com a probabilidade da instituição i entrar em default.

$$p(x_1, \dots, x_n) = q(x_1, \dots, x_n) e^{-(1+\mu + \sum_{i=1}^n \lambda_i I_{x_i < x_i^d})}. \quad (2.3)$$

$$JPOD = \int_{x_1^d}^{\infty} \int_{x_n^d}^{\infty} p(x_1, \dots, x_n) \quad (2.4)$$

$$BSI = \frac{Pr(x_i \geq x_i^d) + Pr(x_j \geq x_j^d)}{1 - Pr(x_i < x_i^d, x_j < x_j^d)}. \quad (2.5)$$

Adrian e Brunnermeier (2008) propuseram o $CoVaR_i$ para medir o impacto de uma instituição financeira sobre o risco do sistema financeiro como um todo, essa técnica é baseada no Value at Risk ("VaR"). O CoVaR é definido pelos autores como o valor do VaR do sistema financeiro dado que a instituição i apresentou dificuldades, ou seja, ele é definido como q %-quantil da equação 2.6. A influência de uma determinada instituição sobre o risco do sistema financeiro é medida pela diferença entre o Covar calculado quando essa instituição apresenta resultados "normais"² e o CoVaR estimado quando ela tem perdas extremas. Seja

$$P(X^{system} | C(X^i) \leq CoVaR_q^{system} | C(X^i)) = q\%, \quad (2.6)$$

a probabilidade de perda do sistema financeira condicional a um evento que é influenciado pelas perdas da instituição i , $C(X^i)$ é um evento que é afetado pelas perdas da instituição i e q é o quantil.

$$\Delta CoVaR_q^{system|i} = CoVaR_{qn}^{system|X^i=VaR_q^i} - CoVaR_q^{system|X^i=VaR_{50}^i} \quad (2.7)$$

Essa medida é de fácil interpretação e Bisias et al. (2012) apontam que o CoVaR conseguiria identificar instituições sistemicamente importantes. Entretanto, os resultados reportados por Rodríguez-Moreno e Peña (2013) demonstram que ele não teve um bom desempenho quando comparado com outras medidas de risco sistêmico.

Também podemos medir o risco sistêmico através do Co-Risk. Essa medida tem como objetivo medir a influência que uma instituição financeira tem sobre o risco de outra através dos spreads do CDS. Para calcularmos essa medida, devemos primeiramente estimar a regressão

² Adrian e Brunnermeier (2008) definem normal como o CoVaR calculado com o $q = 50$.

quantílica dada pela equação 2.8. A seguir, utilizamos esses resultados para estimar a equação 2.9. Nota-se que essa medida capta apenas as relações bilaterais entre as instituições financeiras. Seja

$$CDS_{i,t} = \alpha_{qn}^i + \sum_{qn,m}^i R_{m,t} + \beta_{qn,j} CDS_{j,t} + e_{i,t}, \quad (2.8)$$

a relação do spread do CDS da instituição i no período t com os fatores de risco e o spread do CDS da instituição j no tempo t , onde $CDS_{i,t}$ é o valor do spread do CDS da empresa i no período t , $R_{m,t}$ é o fator³ de risco m no tempo t , e $e_{i,t}$ representa todos os demais fatores que influenciam o spread do CDS da instituição i no período t .

Seja

$$CoRisk_t^{i,j} = 100 \left(\frac{\alpha_{95}^i + \sum_{m=1}^K \beta_{95,m}^i R_{m,t} + \beta_{95}^i CDS_{95,j}^i(95)}{CDS_i(95)} - 1 \right), \quad (2.9)$$

a equação que representa a influência da instituição j na instituição i no tempo t , onde α_{qn} é uma constante do quantil qn , e $\beta_{qn,j}$ é a sensibilidade da companhia i a mudanças no spread da empresa j no quantil qn , e $CoRisk_t^{i,j}$ representa o valor do impacto da instituição j sobre a instituição i no período t .

A terceira medida de risco é conhecida como Systemic Expected Shortfall⁴. Ela foi proposta por Acharya et al. (2010) e é definida como a propensão de uma instituição financeira não possuir capital suficiente para atender as suas obrigações, quando o sistema financeiro também está apresentando dificuldades. Ele mensura a contribuição da instituição i no risco do sistema financeiro a partir da regressão entre os piores retornos das ações, e o nível de alavancagem da instituição i , como pode ser visto na equação 2.10. O risco sistêmico é calculado em duas etapas, no primeiro estágio estimamos os parâmetros b e c da equação 2.10, e depois utilizamos esses valores estimados para calcular o risco sistêmico através da equação 2.11.

Os pontos positivos desta medida são que o processo de estimação utiliza como fonte de informação os valores extremos dos retornos de cada instituição, e ainda permite isolar o efeito que o grau de alavancagem tem no risco do sistema financeiro. No entanto, esse método depende de informações contábeis para medir a alavancagem das instituições financeiras, as quais só podem ser disponibilizadas após períodos de longo de tempo.

$$S\hat{E}S_i = \alpha + bMES_i + cLVG_i + e_i, \quad (2.10)$$

Onde MES_i é a média dos piores retornos do banco i , LVG_i o nível de alavancagem do banco i , e SES_i é a propensão de a instituição i não ter recursos suficientes para manter as suas

³ Alguns dos fatores de risco listado por Bisias et al. (2012) são: retorno do S&P 500 e o spread da Libor.

⁴ Essa medida também é conhecida como CVAR.

operações, quando o mercado não possui capital para funcionar adequadamente⁵.

$$\hat{S}_i = \frac{\hat{b}}{\hat{b} + \hat{c}} MES_i^t + \frac{\hat{c}}{\hat{b} + \hat{c}} LVG_i^t, \quad (2.11)$$

onde \hat{S}_i é o risco sistêmico estimado do banco i .

⁵ Bisias et al. (2012) sugerem medir isso através de testes de estresse, aumento do spread do CDS da instituição, ou através da queda no valor das ações da firma de interesse.

3 ESTRATÉGIA EMPÍRICA E METODOLOGIA

Esta seção está subdividida em três partes. Na primeira parte, descrevemos detalhadamente o modelo e os fundamentos teóricos da nossa medida de risco. Depois explicamos o método de comparação da nossa medida de risco com o BSI e como identificamos as instituições sistemicamente importantes. Ao final descrevemos os dados utilizados neste trabalho.

3.1 MODELO

A estratégia empírica deste trabalho se baseou na teoria dos valores extremos para medir o risco sistêmico do sistema financeiro americano. Esse ramo da estatística se mostra adequado para atingir os objetivos deste artigo, pois a definição dada por Freixas, Laeven e Peydró (2015) nos permite descrever o risco sistêmico como um evento extremo, já que ele é um fenômeno capaz de causar prejuízos elevados para o sistema financeiro e a economia real. Os resultados mais importantes da teoria dos valores extremos, para fins desta dissertação, são os teoremas 1 e 2 apresentados por Coles (2001) e enunciados abaixo.

Teorema 1 Seja $Pr()$ uma função distribuição acumulada de probabilidade univariada, $Max()$ é uma função que representa o máximo de uma sequência de variáveis aleatórias, $\{X_1, \dots, X_n\}$ uma sequência de variáveis aleatórias identicamente e independentemente distribuídas de tamanho n , e $M_n = Max(X_1, \dots, X_n)$. Se existe uma sequência de constantes a_n e b_n , onde $a_n > 0$, tais que $Pr(\frac{M_n - b_n}{a_n} \leq z) \rightarrow G(z)$, quando $n \rightarrow \infty$, então $G(z)$ é um membro da família de distribuição generalizada de valor extremo $G(z) = exp\{-[1 + \xi(\frac{z-\mu}{\sigma})]\}$ definida em $\{z : 1 + \xi(\frac{z-\mu}{\sigma}) > 0\}$, onde $-\infty < \mu < \infty, \sigma > 0$ e $-\infty < \xi < \infty$.

Teorema 2 Seja $\{X_1, \dots, X_n\}$ uma sequência de variáveis aleatórias igualmente e independentemente distribuídas, e seja $M_n = Max(\{X_1, \dots, X_n\})$. Denote um termo arbitrário da sequência X_i por X , e suponha que função de distribuição acumulada satisfaça o teorema 1. Então para um n grande, $P(M_n \leq z) = G(z)$, onde $G(z) = exp\{-[1 + \xi(\frac{z-\mu}{\sigma})]\}$ para μ e σ maiores que 0 e ξ . Então, para um τ grande, a função de distribuição de $(X - \tau)$, condicional a $X > \tau$, é aproximadamente $H((X - \tau)) = 1 - (1 + \xi \frac{(X - \tau)}{\sigma + \xi(\tau - \mu)})^{\frac{-1}{\xi}}$

Tendo em mente esses dois teoremas, Coles (2001) sugere duas formas de modelar os eventos extremos de uma variável aleatória. A partir do teorema 1, Coles (2001) propôs dividir a amostra em blocos, coletar os maiores valores de cada bloco, e então utilizar essas observações juntamente com a distribuição generalizada de valores extremos para estimar os parâmetros de interesse através do método de máxima verossimilhança. A segunda estratégia proposta por Coles (2001) seria a de definir um limiar, calcular a diferença entre os valores da amostra e o

limiar especificado, coletar os excessos positivos dessa operação, e então utilizar esses valores juntamente com a distribuição generalizada de Pareto, para estimar os parâmetros de interesse através do método da máxima verossimilhança. Coles (2001) argumenta que esse método seria melhor do que a primeira estratégia, porque além da primeira abordagem estar sujeita ao "trade-off" entre viés e variância pela escolha do tamanho dos blocos, ele desperdiçaria informação, pois os demais valores do bloco não seriam utilizados no processo de estimação, mesmo que esses valores fossem muito próximos do valor máximo do bloco.

Assim, decidimos usar os modelos baseados em limiar para atingir os objetivos desse artigo. Rootzén e Tajvidi (2006) enunciam a versão multivariada do teorema 2, e demonstram que a distribuição de probabilidade de um vetor de excesso será uma distribuição multivariada generalizada de Pareto cuja forma genérica é representada pela equação 3.1.

$$H(\mathbf{X}) = \begin{cases} 1 - \frac{G(\mathbf{X})}{G(0)}, & \mathbf{X} > 0 \\ 0, & \mathbf{X} < 0 \end{cases} \quad (3.1)$$

onde \mathbf{X} é um vetor de excesso, $G()$ é uma distribuição valor extremo.

Para fins desta dissertação iremos restringir o espaço paramétrico para que os excessos possuem a distribuição multivariada de Pareto do tipo II descrita por Arnold (2015), a qual é representada pela equação 3.2. A partir desta equação podemos perceber que quanto maior for o valor de α , maior será a probabilidade de observarmos um vetor de valores extremos, logo a partir dele poderíamos identificar em quais momentos é mais provável de ocorrer uma crise financeira.

$$F(\mathbf{Y}) = 1 - \left(1 + \sum_{i=1}^n \frac{y_i - \tau_i}{\sigma_i}\right)^\alpha, \alpha < 0, y_i > \tau_i \text{ e } \sigma_i > 0 \forall i, \quad (3.2)$$

onde y_i é o valor do ativo financeiro da instituição i , τ_i e σ_i são, respectivamente, o limiar e parâmetros de escala da instituição i da distribuição. Escreveremos, como Zhang e Schwaab (2016), que $\alpha = -e^{-\lambda}$, dessa forma conseguimos assegurar durante o processo de estimação que o parâmetro α seja sempre negativo. Permitimos que α varie no tempo a partir do parâmetro λ e de um modelo da classe GAS, representado na equação 3.3. Esses modelos foram propostos pela primeira vez por Creal, Koopman e Lucas (2013)¹ e Harvey, Chakravarty et al. (2008). O objetivo desses modelos é fazer com que a evolução do parâmetro ao longo do tempo vá na direção que maximize o valor da função de verossimilhança.

$$\lambda_{t+1} = \omega + \sum_{i=1}^p \kappa_i s_{t-i+1} + \sum_{j=1}^q \delta_j \lambda_{t-j+1}, s_i = \frac{\partial \log(p(y_i, \lambda_i, \theta))}{\partial \lambda_i}, \quad (3.3)$$

onde λ_t é o parâmetro de interesse no período t , ω é uma constante, $p()$ é a função de densidade de probabilidade, θ são os demais parâmetros da densidade de probabilidade, e κ_i e δ_j são os

¹ Esses autores demonstram que muitos modelos, inclusive do tipo Garch, são casos específicos do modelo GAS.

coeficientes da equação. Como em Zhang e Schwaab (2016), utilizamos o modelo GAS(1,1) descrito pela equação 3.4.

$$\lambda_t = \omega + \kappa s_{t-1} + \delta \lambda_{t-1}. \quad (3.4)$$

Os ativos financeiros nunca possuem dependência perfeita, logo nem todos os ativos vão atingir um valor extremo no mesmo dia. Para lidar com essa situação utilizamos a estratégia sugerida por Coles (2001) e Ledford e Tawn (1996), na qual censuramos a função de verossimilhança de forma a considerar apenas as informações referentes as marginais das instituições financeiras que ultrapassaram o seu limiar, abaixo segue um exemplo para o caso bivariado. Seja $L(\theta, (x_1, y_1), \dots, (x_T, y_T)) = \prod_{t=1}^T \psi(\theta, (x_t, y_t))$, a função de verossimilhança, então temos que:

$$\psi(\theta, (x_t, y_t)) = \begin{cases} \frac{\partial^2 F}{\partial x_t \partial y_t}, & \text{se } x_t > \tau_x \text{ e se } y_t > \tau_y \\ \frac{\partial F}{\partial x_t} |_{(x_t, \tau_y)}, & \text{se } x_t > \tau_x \text{ e } y_t \leq \tau_y \\ \frac{\partial F}{\partial y_t} |_{(\tau_x, y_t)}, & \text{se } x_t \leq \tau_x \text{ e } y_t > \tau_y \\ F(\tau_x, \tau_y) & \text{se } x_t \leq \tau_x \text{ e } y_t \leq \tau_y \end{cases} \quad (3.5)$$

onde x_t e y_t são as variáveis de interesse no período t , τ_i é o limiar da variável de interesse i , e $F()$ é a distribuição multivariada de Pareto. Intuitivamente, estamos incorporando apenas a informação de que o ativo não ultrapassou o limiar, não importando o quão longe ele ficou desse limite.

Antes de realizarmos o processo de estimação do parâmetro α , nós utilizamos modelos das classes ARMA-Garch e ARMA-IGarch para retirar os efeitos da autocorrelação das nossas observações. Esse procedimento é importante para termos certeza que o valor extremo observado não decorreu de um aumento da média condicional, ou da variância condicional. A partir disso as nossas observações podem ser descritas pela equação 3.6. Incorporando todos os aspectos mencionados acima, a nossa função de verossimilhança é descrita pela equação 3.7. Assim como Zhang e Schwaab (2016), supomos que σ_i é igual a 1 $\forall i$.

$$y_t = \begin{cases} \frac{v_t - \sum_{i=1}^p \phi_i v_{t-i} - \sum_{j=1}^q \theta_j \epsilon_{t-j}}{\epsilon_t}, \\ \epsilon_t = h_t z_t, \\ h_t = c + \sum_{k=1}^P \gamma_k \epsilon_{t-k}^2 + \sum_{l=1}^Q \psi_l h_{t-l}, \quad |\sum_{k=1}^P \gamma_k + \sum_{l=1}^Q \psi_l| \leq 1 \end{cases}, \quad (3.6)$$

onde v_t é a nossa observação no período t , p , q , P e Q denotam, respectivamente, as ordens dos processos autorregressivo, de médias móveis, ARCH e GARCH, z_t é uma variável aleatória

com distribuição Normal(0;1), ϕ_i , θ_j , γ_k e ψ_l são parâmetros do modelo.

$$L(\lambda_t) = \begin{cases} \log(\prod_{t=1}^T (\psi(\tilde{Y}_t, \alpha_t))) \\ \psi(\tilde{Y}_t, \lambda_t) = \frac{\partial^j F(y_{1,t}, \dots, y_{j,t}, \tau_{j+1,t}, \dots, \tau_n, \alpha_t)}{\partial y_1 \dots \partial y_j} \Big|_{\tilde{y}_1, \dots, \tilde{y}_j, \tau_{j+1}, \dots, \tau_n} \\ \alpha_t = -e^{-\lambda_t} \\ \lambda_t = \omega + \kappa s_{t-1} + \delta \lambda_{t-1} \end{cases}, \quad (3.7)$$

onde n é a quantidade de instituições financeiras na amostra, e j é o número de instituições cujos valores dos ativos ultrapassaram o seu respectivo limiar, \tilde{Y}_t é o vetor de excessos padronizados pela variância condicional no período t , $\tilde{y}_{i,t}$ é o excesso padronizado da instituição i no instante t , e ϵ_t possui distribuição $N(0;1)$. Por fim cabe destacar que utilizamos apenas os dias em que a variação do spread do CDS de pelo menos uma das instituições ultrapassou o seu respectivo limiar.

3.2 HORSE RACE E IDENTIFICAÇÃO DE INSTITUIÇÕES SISTEMICAMENTE IMPORTANTES

Para verificar a efetividade da nossa medida de risco, comparamos ela com o BSI proposto por Basurto e Goodhart (2009), através de uma horse race semelhante à proposta por Rodríguez-Moreno e Peña (2013). Porque nos resultados reportados por esses autores, o BSI foi o indicador que teve melhor desempenho na classe das medidas micro². Esse teste compara as medidas duas a duas, e é formado por três etapas, são elas: cálculo da causalidade Granger, métrica Gonzalo-Granger e a média do R^2 .

Na fase de testes, utilizamos apenas os dados do JP Morgan, Citibank e do Bank of America, em função de que foram as mesmas instituições utilizadas por Rodríguez-Moreno e Peña (2013) para examinar a efetividade do BSI. Decidimos trabalhar com poucas instituições financeiras, porque conforme mencionado por Rodríguez-Moreno e Peña (2013), o BSI é difícil de calcular quando temos um grande número de empresas.

O cálculo do BSI, como mostrado na seção 2, depende da distribuição a priori $q()$, da probabilidade de default individual das instituições financeiras, e do limiar de default. Assim utilizamos a distribuição multivariada $N(0;I)$, a equação 3.8 sugerida por Hull (2014) e Chan-Lau (2006) para calcular as chances de a empresa de referência do CDS não cumprir com as suas obrigações, e a equação 3.9 para quantificar o limiar de default, conforme descrito por Segoviano (2006). Essa equação é oriunda da seguinte condição de arbitragem: o valor esperado do prejuízo deve ser igual ao ganho gerado pelo spread do CDS.

$$pod_{i,t} = \frac{sp_{i,t}(1 + tl v_t)}{1 - RR}, \quad (3.8)$$

² Segundo Rodríguez-Moreno e Peña (2013), medidas micro são aquelas que consideram as informações individuais das instituições financeiras.

$$\chi_i = \Phi^{-1}(1 - \bar{pod}_i), \quad (3.9)$$

onde $pod_{i,t}$ é a probabilidade de default da instituição i no período t , $sp_{i,t}$ é o valor do spread do CDS da instituição i no tempo t , tlv_t é a taxa livre de risco no período t , RR é a taxa de recuperação do empréstimo da companhia de referência, χ_i é o limiar de default da instituição i , $\Phi(\cdot)$ é a distribuição de probabilidade Normal padrão, e \bar{pod}_i é a média das probabilidades de default da empresa i .

Na primeira etapa, o cálculo da causalidade de Granger³ tem como objetivo identificar se as variações de uma medida de risco precedem a outra. Intuitivamente, se o indicador de risco A causar-Granger à medida B , e o contrário não for verdadeiro, então ela captaria mais rápido as mudanças de risco sistêmico, logo seria uma medida melhor que B . Se a medida A causar-Granger a medida B , e a medida B não causar-Granger A , então a medida A recebe 1 ponto e B perde 1 ponto, e se o resultado do teste de Granger for positivo ou negativo para ambas, então elas não recebem pontos.

As métricas Gonzalo-Granger são baseadas no modelo proposto por Gonzalo e Granger (1995) para calcular a tendência comum entre duas variáveis cointegradas. A partir desse modelo é possível estimar a tendência utilizando uma combinação linear das variáveis de interesse. Rodríguez-Moreno e Peña (2013) utilizam os parâmetros dessa combinação linear para construir as métricas Gonzalo-Granger, as quais são representadas pela equação 3.10. Se o valor da métrica Gonzalo-Granger de A for maior que 50%, então a medida A recebe 1 ponto, e a métrica B perde 1 ponto, ou seja, quanto maior a contribuição do indicador de risco sistêmico para "explicar" a tendência comum do risco sistêmico, melhor será o indicador.

$$GG_A = \frac{\alpha_B}{\alpha_B - \alpha_A}, GG_B = \frac{-\alpha_A}{\alpha_B - \alpha_A}, \quad (3.10)$$

onde o α_i é parâmetro do modelo de Gonzalo-Granger referente à variável i .

Na última etapa dos testes, Rodríguez-Moreno e Peña (2013) estimam uma regressão multinomial logística entre as medidas de risco defasadas e uma função indicadora que assume os valores -1, 0 e 1 quando no dia ocorre, respectivamente, um evento que diminui o risco do mercado, nenhum evento relevante para o risco do sistema financeiro, e uma situação que aumenta o risco da economia no período da crise financeira. Essa fase tem como objetivo identificar qual medida tem maior sucesso em prever a ocorrência de eventos sistêmicos. Cabe destacar que Rodríguez-Moreno e Peña (2013) não mostram a metodologia que utilizaram para classificar os eventos durante o período da crise financeira, por isso resolvemos modificar a última fase da horse race.

³ Utilizamos o critério de informação de Schwarz para definir o número de defasagens utilizadas no teste de causalidade de Granger.

Na nossa última fase de teste, estimamos uma regressão linear entre a variação do índice de risco sistêmico calculado pelo FED de Cleveland, o spread da diferença entre average-distance-to-default e portfolio-distance-to-default⁴ ("SR"), para cada uma das variações das medidas de risco com defasagem de até 10 períodos, como fizeram Rodríguez-Moreno e Peña (2013) e conforme mostra a equação 3.11. Daí calculamos a média do R^2 de cada uma das regressões, e atribuímos 1 ponto para a medida que tiver o maior R^2 , e -1 para a métrica que possuir a menor média do R^2 .

$$\Delta SR_t = \beta_0 + \beta_1 \Delta M_{i,t-j} + \epsilon_t, \quad (3.11)$$

onde ΔSR_t é a variação da métrica de risco sistêmico do FED no período t , β_0 uma constante, β_1 é o parâmetro de inclinação, $M_{i,t}$ é a medida de risco i no tempo t , j é a quantidade de defasagens, que no caso vai de 0 até 10, e ϵ_t é uma choque com distribuição $N(0;1)$.

O último ponto que devemos chamar a atenção é que consideramos para a nossa análise apenas os dias em que pelo menos o valor do spread de uma instituição financeira ultrapassou o seu respectivo limiar. Isso se justifica pelo fato de que a distribuição multivariada de Pareto só considera a informação da cauda das distribuições dos ativos, ou seja, lida somente com os eventos extremos.

Após a fase de comparação, estimamos o nosso modelo com todas as instituições financeiras da nossa amostra, e então utilizamos os valores de $\hat{\omega}$, $\hat{\kappa}$ e $\hat{\delta}$ da equação 3.7 para calcular o nosso parâmetro de risco, $\hat{\alpha}_t$. Por fim, estimamos a regressão linear dada pela equação 3.12 para cada uma das instituições financeiras, e a partir dos resultados desta regressão comparamos os valores dos β_i s de cada uma das empresas, quanto maior for o β , maior o efeito da instituição sobre o risco do sistema financeiro.

$$\Delta \hat{\alpha}_t = \theta_i + \beta_i w_{i,t} + \epsilon_t, \quad (3.12)$$

onde $w_{i,t}$ é a variação do spread do CDS da instituição i no tempo t , β_i é o quanto a instituição i influencia no risco do sistema financeiro, e θ_i é uma constante da regressão em que usa dados da companhia i , ϵ_t é o resíduo da regressão que possui distribuição $N(0;1)$.

3.3 DADOS

O CDS é um ativo financeiro, no qual o vendedor desse contrato se prontifica a absorver o prejuízo sofrido pelo comprador quando a empresa de referência do contrato entrar em default, em troca de pagamentos periódicos durante o período firmado no contrato, esse fluxo é conhecido como spread do CDS. Assim, quanto maior for o risco de uma instituição não conseguir cumprir com as suas obrigações, maior será o valor do spread cobrado pelo vendedor para

⁴ O período disponível desta medida era 24/03/2008 até 14/12/2016.

absorver o prejuízo do comprador. Ou seja, acreditamos que o bom funcionamento do sistema financeiro é dado pela capacidade das instituições financeiras cumprirem com as suas obrigações.

Os dados utilizados na realização deste trabalho foram os valores diários dos spreads de CDS seniores com prazo de 5 anos de instituições financeiras que atuam nas áreas de bancos de investimento, banco comercial, seguros, e empréstimos, totalizando 8 empresas que atuam no ramo financeiro dos EUA. A nossa série temporal inicia no dia 11/09/2002 e vai até o dia 21/09/2016, totalizando 3661 observações diárias para cada uma das instituições financeiras. Definimos os limiares τ_i como o percentil 95 de cada uma das séries, assim como Zhang e Schwaab (2016), o período usado para calcular cada um dos τ_i foi de 11/09/2002 a 26/02/2007, ou seja, até um dia antes do início da crise financeira, conforme a linha temporal do FED. O motivo de fazermos isso foi para tentar estimar o limiar com base em um período "normal".

A série foi coletada da base de dados da Bloomberg, e utilizamos o filtro de Kalman de tendência local para interpolar os dados nas datas em que não houvesse informações sobre o spread do CDS. Usamos a taxa dos títulos do tesouro americano com vencimento de 5 anos como a nossa taxa livre de risco, e definimos a taxa de recuperação como 40%, já que essa é a taxa normalmente utilizada pela International Swaps and Derivatives Association ("ISDA") para o cálculo do CDS, conforme mostra ??.

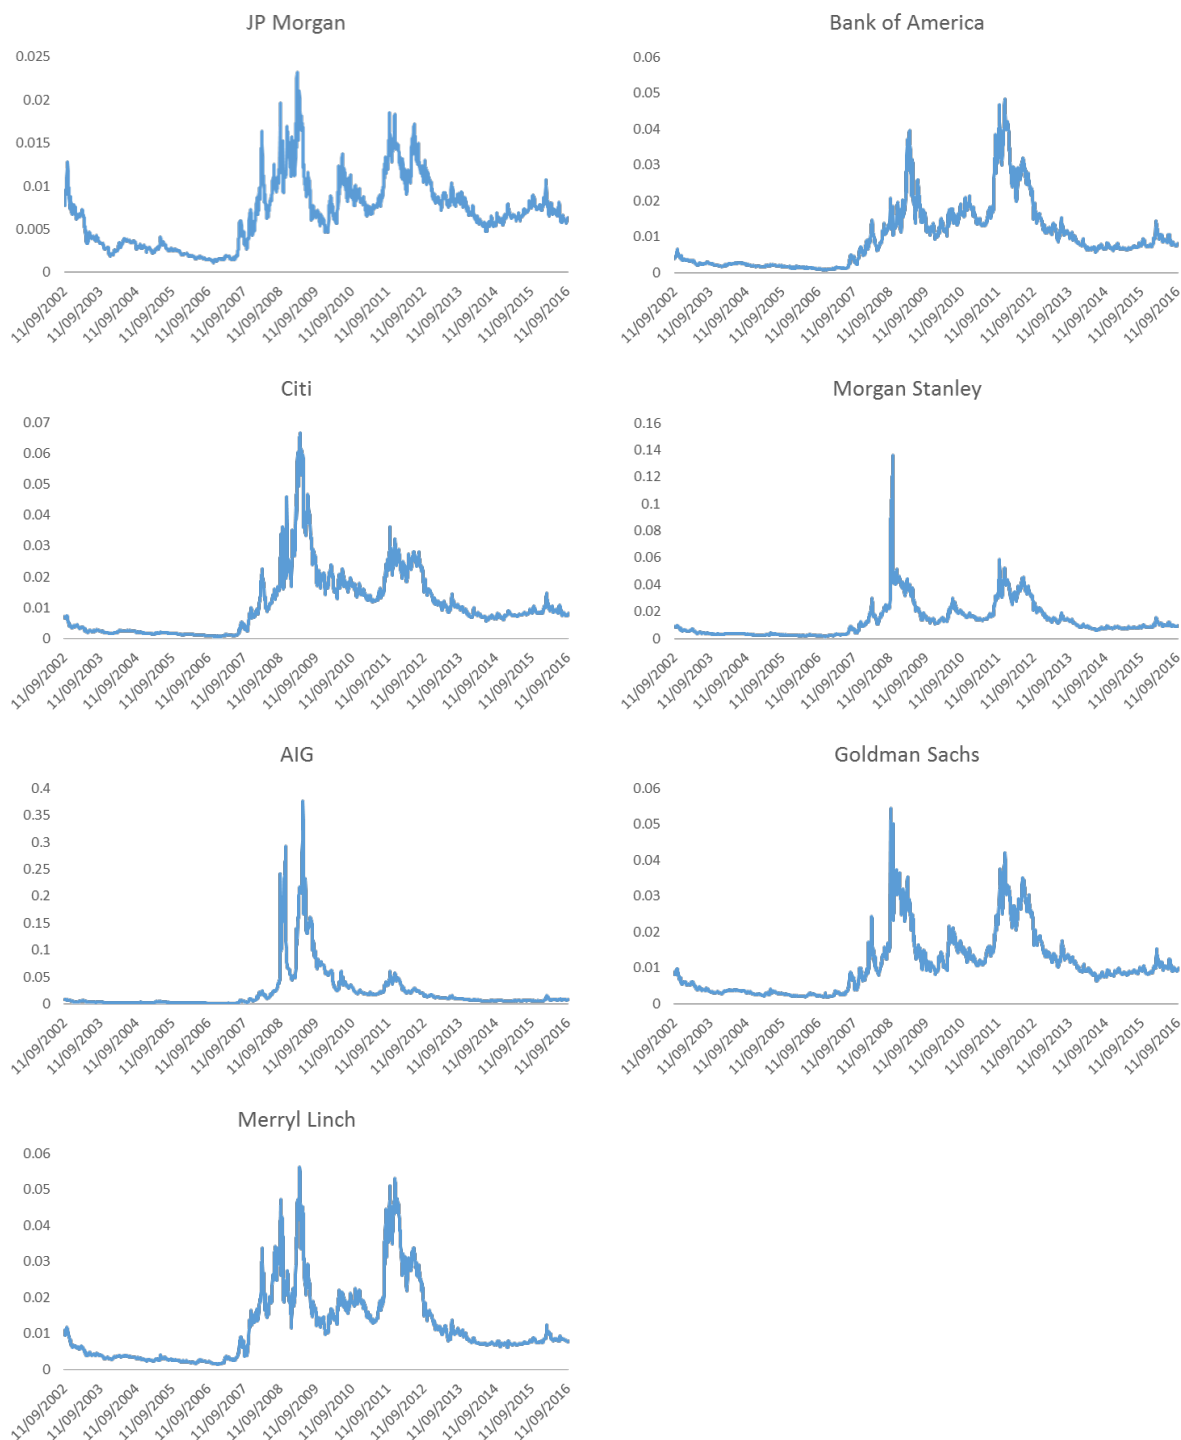
Na tabel 1 podemos visualizar as estatísticas descritivas de todas as instituições financeiras analisadas, e no gráfico 1 podemos ver como as séries dessas companhias se comportaram no período analisado. A análise da Tabela 1 mostra que o American International Group ("AIG") apresentou o maior spread do CDS no período analisado, e as séries temporais dos spreads das instituições financeiras mostram que a partir de 2008 o nível dos spreads aumentou consideravelmente.

Tabela 1 – Estatísticas descritivas

Instituições	Máximo	Mínimo	Média	Desvio-Padrão
JP Morgan	0.0232	0.0011	0.0069	0.0038
Bank of America	0.0483	0.0008	0.0097	0.0087
Citibank	0.0666	0.0007	0.0108	0.0103
Morgan Stanley	0.1360	0.0015	0.0131	0.0126
AIG	0.3759	0.0008	0.0217	0.0407
Goldman Sachs	0.0545	0.0019	0.0108	0.0083
Merryl Lynch	0.0562	0.0015	0.0119	0.0104

Fonte: Elaboração própria (2017).

Figura 1 – Spreads dos CDSs do JP Morgan, Bank of America, Citibank, Morgan Stanley, AIG, Goldman Sachs, Merrill Lynch e Metlife.



Fonte: Elaboração própria (2017).

A Tabela 2 mostra os resultados do teste KPSS para verificar a presença de raiz unitária nas séries analisadas, e que tem como hipótese nula a ausência de raiz unitária. Os resultados dessa Tabela indicam que a 5% de significância podemos rejeitar a hipótese nula para todas as séries. Assim, analisamos as primeiras diferenças. Na Tabela 3 observa-se que as primeiras

diferenças parecem ser todas estacionárias.

Tabela 2 – Resultado do teste KPSS para o nível do spread do CDS.

Instituições	Estatística de Teste	P-Valor
JP Morgan	7.9617	<0.01
Bank of America	8.3092	<0.01
Citibank	5.9905	<0.01
Morgan Stanley	5.0986	<0.01
AIG	2.3226	<0.01
Goldman Sachs	7.3398	<0.01
Merryl Linch	5.4061	<0.01

Fonte: Elaboração própria (2017).

Tabela 3 – Resultado do teste KPSS para a variação do spread do CDS.

Instituições	Estatística de Teste	P-Valor
JP Morgan	0.0349	>0.1
Bank of America	0.0489	>0.1
Citibank	0.0419	>0.1
Morgan Stanley	0.0161	>0.1
AIG	0.0193	>0.1
Goldman Sachs	0.0302	>0.1
Merryl Linch	0.0400	>0.1

Fonte: Elaboração própria (2017).

A partir dos resultados desses testes, decidimos trabalhar com a primeira diferença dos spread do CDS. Uma variação positiva do CDS indica que o risco da instituição piorou, logo o nosso parâmetro de interesse, α_t , irá determinar a probabilidade de ocorrer simultaneamente uma deterioração na capacidade de as instituições saldarem as suas dívidas. O parâmetro α está diretamente relacionado com a definição de risco sistêmico dado por Freixas, Laeven e Peydró (2015), uma vez que consideramos que o sistema financeiro estará funcionando bem, se é somente se as instituições financeiras forem capazes de cumprir com as suas obrigações.

4 RESULTADOS

A presente seção foi dividida em três partes. Na primeira subseção, mostramos os resultados dos procedimentos ARMA-Garch e ARMA-IGarch. Na segunda seção, mostramos os resultados da horse race, na qual a nossa medida de risco "empatou" com o BSI. E na terceira parte, apresentamos quais são as instituições financeiras que têm maior influência no risco sistêmico.

4.1 RESULTADOS DOS PROCESSOS ARMA-Garch e ARMA-IGarch

Os resultados da estimação dos modelos ARMA-Garch e ARMA-IGarch são apresentados nas Tabelas 4,5,6,7,8, 9, 10,11,12,13,14,15,16 e 17, eles nos permitem afirmar que as estimativas de todos os parâmetros foram significantes a um nível de 95%. Nas tabelas 18 e 19 apresentamos, respectivamente, os resultados dos testes de Ljung-Box sobre os resíduos e os quadrados dos resíduos, os quais nos permitem falar que a um nível de confiança de significância de 5% não há a presença de autocorrelação.

Tabela 4 – Estimativas dos parâmetros do modelo ARMA do JP Morgan

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_1$	1.3026	19.6601	<0.01
$\hat{\phi}_2$	-0.5512	-8.2289	<0.01
$\hat{\theta}_1$	-1.1509	-15.6983	<0.01
$\hat{\theta}_2$	0.3844	5.1705	<0.01

Fonte: Elaboração própria (2017).

Tabela 5 – Estimativas dos parâmetros do modelo ARMA do Bank of America

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_1$	0.8664	8.8220	<0.01
$\hat{\phi}_2$	-0.0982	-3.1941	<0.01
$\hat{\phi}_3$	-0.0859	-4.9189	<0.01
$\hat{\theta}_1$	-0.6644	-6.7841	<0.01

Fonte: Elaboração própria (2017).

4.2 RESULTADOS DA HORSE RACE

O primeiro passo da horse race foi estimar o valor do limiar para cada uma das instituições, conforme explicamos na subseção 3.1. Os limiares, estimados como o percentil 95 de cada uma das séries, podem ser visualizados na Tabela 20. Após aplicarmos o limiar 1, ficamos com

Tabela 6 – Estimativas dos parâmetros do modelo ARMA do Citibank

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_1$	0.2504	15.1398	<0.01
$\hat{\phi}_2$	-0.0403	-2.3653	0.018
$\hat{\phi}_3$	-0.0735	-4.4483	<0.01
$\hat{\phi}_5$	-0.1017	-6.1197	<0.01

Fonte: Elaboração própria (2017).

Tabela 7 – Estimativas dos parâmetros do modelo ARMA do Morgan Stanley

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_1$	-0.0634	-3.8416	<0.01
$\hat{\phi}_2$	-0.0637	-3.8898	<0.01
$\hat{\phi}_3$	-0.1351	-8.2460	<0.01
$\hat{\phi}_4$	-0.0543	-3.2890	<0.01

Fonte: Elaboração própria (2017).

Tabela 8 – Estimativas dos parâmetros do modelo ARMA da AIG

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_4$	0.4301	26.0758	<0.01
$\hat{\theta}_1$	0.1835	10.2973	<0.01
$\hat{\theta}_2$	0.1041	5.5934	<0.01
$\hat{\theta}_3$	-0.0973	-5.1803	<0.01

Fonte: Elaboração própria (2017).

Tabela 9 – Estimativas dos parâmetros do modelo ARMA do Goldman Sachs

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_1$	-0.3056	-3.2307	<0.01
$\hat{\phi}_4$	0.5222	5.5557	<0.01
$\hat{\theta}_1$	0.0757	2.5369	<0.01
$\hat{\theta}_2$	-0.1878	-9.7890	0.0112
$\hat{\theta}_3$	-0.1858	-7.4184	<0.01

Fonte: Elaboração própria (2017).

Tabela 10 – Estimativas dos parâmetros do modelo ARMA do Merrill Lynch

Parâmetro	Valor	Est. Teste	P-Valor
$\hat{\phi}_1$	0.1690	10.1574	<0.01
$\hat{\phi}_2$	-0.0447	-2.6550	<0.01
$\hat{\phi}_3$	-0.0394	-2.3815	0.0172
$\hat{\phi}_5$	0.1058	6.3209	<0.01

Fonte: Elaboração própria (2017).

Tabela 11 – Estimativas dos parâmetros do modelo Garch do JP Morgan

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	2.21509467	2422.525	<0.01
$\hat{\gamma}_1$	0.77144004	32.579	<0.01

Fonte: Elaboração própria (2017).

Tabela 12 – Estimativas dos parâmetros do modelo Garch do Bank of America

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	0.0149926	6.8656	<0.01
$\hat{\gamma}_1$	0.1319162	19.3894	<0.01
$\hat{\psi}_1$	0.8680838	397.5244	<0.01

Fonte: Elaboração própria (2017).

Tabela 13 – Estimativas dos parâmetros do modelo Garch do Citibank

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	0.0144516	5.7768	<0.01
$\hat{\gamma}_1$	0.6407067	46.9119	<0.01
$\hat{\gamma}_2$	0.17159	123.2985	<0.01

Fonte: Elaboração própria (2017).

Tabela 14 – Estimativas dos parâmetros do modelo IGarch do Morgan Stanley

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	0.0447566	8.4614	<0.01
$\hat{\gamma}_1$	0.2175525	23.2963	<0.01
$\hat{\psi}_1$	0.7824475	147.9252	<0.01

Fonte: Elaboração própria (2017).

Tabela 15 – Estimativas dos parâmetros do modelo IGarch da AIG

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	0.0230965	7.295	<0.01
$\hat{\gamma}_1$	0.2341912	34.752	<0.01
$\hat{\psi}_1$	0.7658088	241.881	<0.01

Fonte: Elaboração própria (2017).

Tabela 16 – Estimativas dos parâmetros do modelo IGarch do Goldman Sachs

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	0.0348469	9.0348	<0.01
$\hat{\gamma}_1$	0.1412654	23.7998	<0.01
$\hat{\psi}_1$	0.8587346	222.6451	<0.01

Fonte: Elaboração própria (2017).

Tabela 17 – Estimativas dos parâmetros do modelo IGarch do Merrill Lynch

Parâmetro	Valor	Est. Teste	P-Valor
\hat{C}	0.0230768	7.9962	<0.01
$\hat{\gamma}_1$	0.1410751	19.795	<0.01
$\hat{\psi}_1$	0.8589249	297.6193	<0.01

Fonte: Elaboração própria (2017).

Tabela 18 – Resultado do teste Ljung-Box para o resíduo de y_t

Instituição	Est. Teste	P-Valor
JP Morgan	3.3647	0.644
Bank of America	1.003	0.9623
Citibank	9.8246	0.08036
Morgan Stanley	0.83199	0.9749
AIG	6.7392	0.2408
Goldman Sachs	0.44655	0.994
Merryl Linch	7.8609	0.1641

Fonte: Elaboração própria (2017).

Tabela 19 – Resultado do teste Ljung-Box para y_t

Instituição	Est. Teste	P-Valor
JP Morgan	5.1041	0.4033
Bank of America	1.9604	0.8546
Citibank	1.7596	0.8813
Morgan Stanley	3.4784	0.6267
AIG	3.5605	0.6143
Goldman Sachs	1.6495	0.8952
Merryl Linch	1.4869	0.9146

Fonte: Elaboração própria (2017).

748 dias, nos quais pelo menos uma das variações do spread padronizado do CDS ultrapassou o seu respectivo limiar.

Tabela 20 – Limiar das instituições financeiras

Instituição	$\hat{\tau}$
JP Morgan	0.7589
Bank of America	1.4278
Citibank	1.0121

Fonte: Elaboração própria (2017).

Nas Tabelas 21 e 22 visualizamos, respectivamente, os valores estimados por máxima verossimilhança e os resultados do teste da razão de verossimilhança¹. Cabe destacar que os

¹ O teste foi construído a partir da descrição de Cuthbertson, Hall e Taylor (1992), e a hipótese nula do teste é

parâmetros κ e δ foram testados conjuntamente, e que os valores da Tabela 22 indicam que as estimativas dos parâmetros foram significantes a um nível de 5%.

Tabela 21 – Parâmetros do modelo GAS

Parâmetro	Valor
$\hat{\omega}$	0.0072
$\hat{\kappa}$	0.0406
$\hat{\delta}$	0.9341

Fonte: Elaboração própria (2017).

Tabela 22 – Resultado do teste da razão de Verossimilhança

Parâmetro	Est. Teste	P-Valor
$\hat{\omega}$	4.0159	0.0451
$\hat{\kappa}$ e $\hat{\delta}$	246.3471	<0.01

Fonte: Elaboração própria (2017).

O resultado da primeira etapa mostra que nenhuma das medidas é capaz de causar a outra no sentido de Granger, como mostra a 24. Antes de realizarmos a segunda fase de testes, verificamos se as duas métricas são cointegradas. Os resultados das Tabelas 23 e 25 apontam que a 5% de significância, as duas medidas devem ser cointegradas.

Tabela 23 – Resultado do teste KPSS das medidas de risco

Parâmetro	Est. Teste	P-Valor
$\hat{\alpha}$	0.6354	0.0194
BSI	2.2041	<0.01
$\Delta\hat{\alpha}$	0.0613	>0.1
ΔBSI	0.0112	>0.1

Fonte: Elaboração própria (2017).

Tabela 24 – Resultado do teste da causalidade de Granger

Parâmetro	Est. Teste	P-Valor
Δ BSI causa-Granger $\Delta\hat{\alpha}$	0.8676	0.4829
$\Delta\hat{\alpha}$ causa-Granger BSI	1.7239	0.1428

Fonte: Elaboração própria (2017).

que os parâmetros são iguais a 0.

Tabela 25 – Resultado do teste de cointegração de Johansen

Traço	Est. Teste	Johansen
0	47.4400	17.9500

Fonte: Elaboração própria (2017).

Em seguida, calculamos as métricas de Gonzalo-Granger, conforme a equação 26, cujos valores foram apresentados na Tabela 3.10. Eles indicam que o BSI "explica" mais a tendência comum das medidas do que a nossa medida de risco.

Tabela 26 – Valores das métricas Gonzalo-Granger

Parâmetro	Valor
GG_{α}	0.0820
GG_{BSI}	0.9180

Fonte: Elaboração própria (2017).

Por fim, realizamos a última etapa de testes, na qual comparamos a média dos R_s^2 dos modelos lineares que utilizam como variáveis explicativas as defasagens do BSI e da nossa medida de risco. Os valores da Tabela 27 indicam que a nossa medida de risco teria melhor desempenho do que o BSI em antecipar os movimentos do risco sistêmico. Assim, o resultado final da horse race é um empate entre a nossa medida de risco, como mostra a Tabela 28. Nos gráficos abaixo visualizamos a série temporal do BSI ² e do parâmetro $\hat{\alpha}$, a partir dos quais verificamos que ambas as medidas apresentaram aumento em 2007 e 2008, período no qual ocorreu a crise financeira.

Tabela 27 – Média do R^2 das medidas de risco

Parâmetro	Média do R^2
$\Delta \hat{\alpha}$	0.0039
ΔBSI	0.0032


Fonte: Elaboração própria (2017).

² Acreditamos que alguns valores ficaram um pouco abaixo de 1 devido ao fato de problemas de arredondamento do software assim como do fato de termos utilizados integrais numéricas para calcularmos os parâmetros do BSI.

Tabela 28 – Pontuação da horse race

Etapa	$\hat{\alpha}$	BSI
Causalidade de Granger	0	0
Métrica Gonzalo-Granger	-1	1
Média do R^2	1	-1
Total	0	0

Fonte: Elaboração própria (2017).

Figura 2 – Séries temporais das estimações do BSI e do α .

Fonte: Elaboração própria (2017).

4.3 INSTITUIÇÕES SISTEMICAMENTE IMPORTANTES

Após verificarmos que a nossa medida de risco teve um desempenho razoável na horse race, estimamos novamente o modelo, mas agora iremos utilizar todas as variáveis para estimar o parâmetro α . Após aplicarmos o limiar, identificamos 1064 dias em que pelo menos um dos spreads de alguma das instituições ultrapassou o limiar, em seguida estimamos por máxima verossimilhança o parâmetro α . Os resultados deste processo podem ser verificados na Tabela 30, e na Tabela 31 vemos que as estimativas dos parâmetros κ e δ são significativas a um nível de 5% de confiança, enquanto que a estimativa do parâmetro ω não é significativamente diferente de 0 a um nível de confiança de 5%. No gráfico 3, podemos perceber pelo gráfico que a partir de 2007 o $\hat{\alpha}$ aumentou, o que nos dá evidências de que as condições de mercado já estavam se deteriorando naquele ano.

Tabela 29 – Limiar das instituições financeiras

Instituição	$\hat{\tau}$
JP Morgan	0.7589
Bank of America	1.4278
Citibank	1.0121
Morgan Stanley	1.2651
AIG	1.4575
Goldman Sachs	1.2289
Merryl Lynch	1.3445

Fonte: Elaboração própria (2017).

Tabela 30 – Estimativas dos parâmetros do modelo GAS.


Parâmetro	Valor
$\hat{\omega}$	-0.0022
$\hat{\kappa}$	0.0239
$\hat{\delta}$	0.9653

Fonte: Elaboração própria (2017).

Tabela 31 – Resultado do teste da razão de verossimilhança.

Parâmetro	Est. Teste	P-Valor
$\hat{\omega}$	1.7024	0.1920
$\hat{\kappa}$ e $\hat{\delta}$	456.3448	<0.01

Fonte: Elaboração própria (2017).

Figura 3 – Série temporal do parâmetro $\hat{\alpha}$ 

Fonte: Elaboração própria (2017).

Por fim identificamos as instituições sistemicamente importante através da estratégia empírica descrita na subseção 3.2, cujos resultados podem ser observados na Tabela 32. Os valores da segunda coluna mostram o quanto a instituição financeira influencia o mercado como um todo, e a terceira e quarta colunas mostram, respectivamente, os valores referentes ao teste da razão de verossimilhança e o P-Valor do teste, os quais nos permitem afirmar que a 5% de confiança apenas a estimativa do parâmetro β da AIG não foi significativa.

Tabela 32 – Efeito das instituições financeiras sobre o risco sistêmico.

Instituição	$\hat{\beta}$	Est. Teste	P-Valor
JP Morgan	40.4065	9.6920	<0.01
Bank of America	20.3946	8.0750	<0.01
Goldman Sachs	12.6968	7.4160	<0.01
Citibank	11.0015	6.1360	<0.01
Merryl Lynch	9.467386	5.375	<0.01
Morgan Stanley	4.7280	4.3530	<0.01
AIG	0.3192	0.8740	0.382

Fonte: Elaboração própria (2017).

A Tabela 32 nos permite afirmar que a instituição que tem maior impacto no mercado é o JP Morgan, enquanto que a AIG é a empresa que tem menor influência no mercado formado pela nossa amostra. Destacamos que o fato de o parâmetro $\hat{\beta}$ da AIG não ter sido significativo não nos permite dizer que ela não influencia o risco sistêmico do sistema financeiro, pois qualquer deterioração extrema é considerada no cálculo de $\hat{\alpha}$ através da função score, esse fato significaria apenas que variações "normais" no spread do CDS não afetam o risco sistêmico do mercado.

5 CONSIDERAÇÕES FINAIS

Os resultados apresentados na subseção 4.2 indicam que a nossa medida de risco conseguiu "empatar" com o BSI, ou seja, ele possui algumas propriedades melhores que o BSI. No caso, a nossa medida de risco conseguiu antecipar melhor as movimentações do risco sistêmico, conforme mostra o resultado da tabela 3.2.

Na subseção 4.3, conseguimos demonstrar que a nossa medida de risco pode ser utilizada para ordenar o tamanho do efeito que os participantes da nossa amostra têm sobre o risco sistêmico. Isso se mostra como uma vantagem em relação ao BSI, pois ele indica apenas o número esperado de instituições financeiras que podem entrar em default dado que uma delas apresentou problemas, ou seja, ele não especifica quais instituições podem apresentar problemas.

A possibilidade de identificar quais são as instituições sistemicamente importantes é interessante para os órgãos responsáveis por regular e supervisionar o sistema financeiro, porque eles poderiam focar melhor as medidas prudenciais, como por exemplo, exigir um nível de capital maior para aquelas empresas que têm maior efeito sobre o risco do sistema como um todo. E ainda, no caso de uma crise financeira, na qual o governo se vê obrigado a resgatar as instituições financeiras, ele poderia utilizar o parâmetro β para definir quais empresas ele deveria salvar e o volume de recursos que deveria alocar para cada uma delas.

A partir disso acreditamos que a nossa medida de risco possa contribuir para avançar as técnicas de mensurar o risco sistêmico, pois ele consegue apontar quais são as instituições mais importantes no sistema financeiro. Por fim destacamos que essa metodologia poderia ser utilizada em outros contextos, por exemplo, seria possível calcular o parâmetro α para uma carteira de ações, nesse caso o objetivo seria identificar a facilidade com as ações pudessem simultaneamente apresentar enormes perdas, e que as pesquisas futuras deveriam focar em formas de calcular o limiar de forma que ele variasse ao longo do tempo.

REFERÊNCIAS

- ACHARYA, V. V. et al. Measuring systemic risk. In: ACHARYA, V. V. et al. (Org.). *Regulating Wall Street: the Dodd-Frank Act and the new architecture of global finance*, New Jersey: Princeton University, 2010. p. 87-120.
- ADRIAN, T.; BRUNNERMEIER, M. K. *CoVaR*. New York: Federal Reserve Bank of New York, 2008. (Staff Report, 348).
- AGARWAL, S.; BEN-DAVID, I. *Loan prospecting and the loss of soft information*. Cambridge: The National Bureau of Economic Research, 2014. (NBER Working Paper, 19.945).
- ARNOLD, B. C. Pareto distribution. [S.l.]: Wiley Online Library, 2015. Disponível em: <<http://onlinelibrary.wiley.com/doi/10.1002/9781118445112.stat01100.pub2/references>>. Acesso em: 12/06/2016.
- BASURTO, M. S.; GOODHART, C. *Banking stability measures*. Washington, DC: International Monetary Fund, 2009. (IMF Working paper, 09/4).
- BANK FOR INTERNATIONAL SETTLEMENTS – BIS. *Global systemically important banks: assessment methodology and the additional loss absorbency requirement*. Basel: 2011.
- BISIAS, D. et al. *A survey of systemic risk analytics*. Washington, DC: Office of Financial Research, 2012. (Working Paper, 1).
- CAMPBELL, J. Y.; COCHRANE, J. H. By force of habit: a consumption-based explanation of aggregate stock market behavior. *Journal of Political Economy*, Chicago, v. 107, n. 2, p. 205-251, 1999.
- CHAN-LAU, J. A. *Market-Based Estimation of Default Probabilities and Its Application to Financial Market Surveillance*. Washington, DC: International Monetary Fund, 2006. (Working Paper, 06/104).
- COLES, S. *An introduction to statistical modeling of extreme values*. London: Springer, 2001.
- CREAL, D.; KOOPMAN, S. J.; LUCAS, A. Generalized autoregressive score models with applications. *Journal of Applied Econometrics*, New Jersey, v. 28, n. 5, p. 777–795, 2013.
- CUTHBERTSON, K.; HALL, S.; TAYLOR, M. *Applied econometric techniques*. Michigan : University of Michigan Press, 1992. Disponível em: <<https://books.google.com.br/books?id=uA-7AAAAIAAJ>>. Acesso em: 12/06/2016
- FREIXAS, X.; LAEVEN, L.; PEYDRÓ, J.-L. *Systemic Risk, Crises, and Macroprudential Regulation*. Massachusetts: MIT Press, 2015. Disponível em: <<http://www.jstor.org/stable/j.ctt17kk82g>>. Acesso em: 12/06/2016.

- GENNAIOLI, N.; SHLEIFER, A.; VISHNY, R. W. A model of shadow banking. *The Journal of Finance*, [S.l.], v. 68, n. 4, p. 1331–1363, 2013.
- GONZALO, J.; GRANGER, C. Estimation of common long-memory components in cointegrated systems. *Journal of Business Economic Statistics*, Alexandria, v. 13, n. 1, p. 27–35, 1995.
- HANSEN, L. P. *Challenges in identifying and measuring systemic risk*. Madrid: Center for Monetary and Financial Studies, 2012.
- HARVEY, A. C.; CHAKRAVARTY, T. et al. *Beta-t(e) garch*. Cambridge: University of Cambridge, Faculty of Economics, 2008.
- HULL, J. *Options, Futures, and Other Derivatives*. 8. ed. New Jersey: Prentice-Hall Internat., 2014. (Student solutions manual).
- KINDLEBERGER, C. P. *Manias, Panics, and Crashes: a history of financial crises*. New Jersey: Palgrave Macmillan, 2005.
- LEDFORD, A. W.; TAWN, J. A. Statistics for near independence in multivariate extreme values. *Biometrika Trust*, Oxford, v. 83, n. 1, p. 169–187, 1996.
- MARTINEZ-MIERA, D.; REPULLO, R. Does competition reduce the risk of bank failure? review of financial studies. *Society Financial Studies*, Raleigh, v. 23, n. 10, p. 3638–3664, 2010.
- RAJAN, R. G. Why bank credit policies fluctuate: a theory and some evidence. *The Quarterly Journal of Economics*, v. 109, n. 2, Oxford, p. 399–441, 1994.
- REINHART, C. M.; ROGOFF, K. *Oito Séculos de Delírios Financeiros: desta vez é diferente*. Rio de Janeiro: Elsevier, 2010.
- RODRÍGUEZ-MORENO, M.; PEÑA, J. I. Systemic risk measures: the simpler the better?. *Journal of Banking Finance*, [S.l.], v. 37, n. 6, p. 1817–1831, 2013.
- ROOTZÉN, H.; TAJVIDI, N. Multivariate generalized pareto distributions. *Bernoulli*, [S.l.], v. 12, n. 5, p. 917–930, 2006.
- SEGOVIANO, M. A. *Consistent information multivariate density optimizing methodology*. London: Financial Markets Group, 2006. (Discussion paper, 557).
- SMAGA, P. *The concept of systemic risk*. London: London School of Economics and Political Science, 2014. (Systemic Risk Centre Special Paper, 5).
- ZHANG, X.; SCHWAAB, B. *Tail risk in government bond markets and ecb unconventional policies*. Frankfurt: European Central Bank, 2016. (Working Paper).