

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE PELOTAS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ORGANIZAÇÕES E MERCADOS



Tese

CONECTIVIDADE E INTEGRAÇÃO DINÂMICA ENTRE OS BANCOS NO BRASIL

MAIRTON NOGUEIRA DA SILVA

Pelotas, Novembro de 2022

MAIRTON NOGUEIRA DA SILVA

CONECTIVIDADE E INTEGRAÇÃO DINÂMICA ENTRE OS BANCOS NO BRASIL

Tese apresentada ao curso de doutorado do Programa de Pós-Graduação em Organizações e Mercados da Universidade Federal de Pelotas como requisito parcial para a obtenção do título de Doutor em Economia Aplicada.

Orientador: Prof. Dr. Marcelo de Oliveira Passos

Pelotas, Novembro de 2022

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

S586c Silva, Mairton Nogueira da

Conectividade e integração dinâmica entre os bancos no Brasil / Mairton Nogueira da Silva ; Marcelo de Oliveira Passos, orientador. — Pelotas, 2023.

83 f. : il.

Tese (Doutorado) — Programa de Pós-Graduação em Organizações e Mercados, Instituto de Ciências Humanas, Universidade Federal de Pelotas, 2023.

1. Ações de bancos. 2. Transmissões de volatilidade. 3. Conectividade dinâmica. 4. Modelo TVP-VAR. I. Passos, Marcelo de Oliveira, orient. II. Título.

CDD : 004.678

MAIRTON NOGUEIRA DA SILVA

CONECTIVIDADE E INTEGRAÇÃO DINÂMICA ENTRE OS BANCOS NO BRASIL

Tese aprovada, como requisito parcial para a obtenção do título de Doutor em Economia Aplicada, Doutorado do Programa de Pós-Graduação em Organizações e Mercados da Universidade Federal de Pelotas.

Aprovada pela banca examinadora em: 25/11/2022

BANCA EXAMINADORA:

Prof. Dr. Daniel de Abreu Pereira Uhr - Universidade Federal de Pelotas (UFPEL).

Prof. Dr. Fábio Massaud Caetano – Universidade Federal de Pelotas (UFPEL).

Prof. Dr. Marcelo de Oliveira Passos - Universidade Federal de Pelotas (UFPEL), Orientador.

Prof. Dr. Mathias Schneid Tessmann – Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa (IDP).

Prof. Dr. Vinícius Halmenschlager - Universidade Federal do Rio Grande do Sul (UFRGS).

Dedico de coração este singelo trabalho a melhor pessoa da minha família biológica, minha avó paterna Maria da Conceição, que veio a falecer em 2022. Vó, você é uma pessoa especial e agora está com o Criador.

Agradecimentos

Ao supremo Criador do Universo e ao herói dos heróis Jesus Cristo (mito ou realidade? Não importa).

Aos professores do Programa de Pós-Graduação em Organizações e Mercados da UFPel, especialmente aos professores Marcelo Passos, André Carraro, Régis Ely, César Tejada, Rodrigo Fernandez e Felipe Garcia.

Aos colegas de mestrado e doutorandos Victor Buttignon, Caio Rostirolla, Márcio Taveira, Silvio Paula, Dianifer Borges, Rafael Parfit e especialmente à minha amiga Raquel Pérez.

Às secretárias do PPGOM da UFPel Anne Gomes Sacco (já aposentada) e Vanessa.

Aos professores da banca de defesa desta tese.

À Universidade Federal de Pelotas.

À Universidade Federal do Ceará.

Aos professores da graduação do Departamento de Contabilidade da Universidade Federal do Ceará.

Aos professores da graduação do Departamento de Estatística e do Departamento de Matemática da Universidade Federal do Ceará, especialmente à professora Ana Maria e ao professor Maurício Mota.

Às minhas professoras do ensino fundamental.

Aos meus professores do ensino médio, especialmente ao professor de Matemática Ailton e ao de Física Bacelar.

À CAPES pelos dois primeiros anos de bolsa.

A todo o povo brasileiro pelo Ministério da Educação.

Muito obrigado.

*É preciso amar as pessoas como se não houvesse amanhã,
porque se você parar pra pensar
na verdade não há.
(Renato Russo)*

Resumo

Silva, Mairton Nogueira da. **Conectividade e integração dinâmica entre os bancos no Brasil**. Orientador: Marcelo de Oliveira Passos. 2022. 83 f. Tese (Doutorado em Economia Aplicada) – Programa de Pós-Graduação em Organizações e Mercados, Universidade Federal de Pelotas, Pelotas, 2022.

Esta tese buscou analisar a conectividade e a integração dinâmica entre os bancos que operam no Brasil em dois ensaios. No primeiro ensaio, investigou-se a integração dinâmica e o risco de contágio entre as ações dos principais bancos do mercado de ações brasileiro. O período de análise vai de 30 de abril de 2009 a 11 de março de 2022, captando assim os efeitos de contágio do período mais crítico da pandemia de COVID-19 no Brasil. A base de dados é composta por 14 ações dos principais bancos listados na Bolsa de valores de São Paulo (B3). Utilizou-se a metodologia de conectividade dinâmica no domínio da frequência baseada em um modelo TVP-VAR. Os resultados mostraram uma integração influenciada por eventos políticos, sociais, econômicos e, principalmente, pela pandemia de COVID-19. O nível dessa integração variou de 20% a mais de 50%. O pico mais alto coincidiu com o início do aumento de casos de COVID-19 no ano de 2020. As transmissões de curta duração foram predominantes em todo o período analisado. Os bancos que apresentaram os maiores potenciais de risco de contágio foram o Banco do Brasil (BBAS3), Bradesco (BBDC3) e Itaú-Unibanco (ITUB3) com predominância de transmissões de choques de curto prazo. O comportamento dinâmico da integração amostral revelou que existe a possibilidade de diversificação de risco em uma carteira composta por ações desses bancos, uma vez que as ações dos bancos analisados apresentaram diferentes padrões de resposta aos mesmos eventos. O segundo ensaio teve como objetivo geral analisar a conectividade de volatilidade entre as ações dos principais bancos que operam no Brasil que estão listados na B3 durante períodos normais de mercado. O período de análise vai de 01 de fevereiro de 2016 a 17 de março de 2020. A base de dados é composta por 12 ações dos principais bancos listados na B3. Utilizou-se a metodologia da conectividade dinâmica no domínio da frequência. Os resultados mostraram que em períodos normais de mercado e também quando há situações pontuais de incerteza, a volatilidade das ações bancárias no Brasil é transmitida aos preços inicialmente dentro de uma semana. Posteriormente, há um período de um mês no qual a conexão é reduzida a níveis abaixo dos 5%. Nesse período, os agentes processam as informações que possam gerar repercussões mais duradouras no mercado, o que culmina em um novo aumento da conectividade após um mês da ocorrência daqueles eventos que consideraram como relevantes. Além disso, a conectividade direcional líquida de baixa frequência foi a única frequência com conexão em nível relevante, depois da faixa de frequência de 1 a 5 dias. Constatou-se também que os maiores transmissores líquidos de choques foram o Banco do Brasil, o Itaú, o Bradesco e o banco ABC Mercantil. Com isto, evidenciou-se o potencial que as ações desses bancos têm de afetar sistematicamente o desempenho do mercado de ações bancárias brasileiro. Principalmente porque os choques nos preços das ações desses bancos persistem por mais tempo e com mais força do que os choques dos demais bancos.

Palavras-chave: ações de bancos, transmissões de volatilidade; conectividade dinâmica, modelo TVP-VAR.

Classificação JEL: G21, G01, G11, G14.

Abstract

Silva, Mairton Nogueira da. **Connectedness and dynamic integration between banks in Brazil**. Advisor: Marcelo de Oliveira Passos. 2022. 83 f. Thesis (Doctorate in Applied Economics) – Posgraduate Program in Organizations and Markets, Federal University of Pelotas, Pelotas, 2022.

This thesis sought to analyze connectedness and dynamic integration between banks operating in Brazil in two essays. In the first essay, the dynamic integration and the risk of contagion between the stock of the main banks in the Brazilian stock market were investigated. The analysis period runs from April 30, 2009 to March 11, 2022, thus capturing the contagion effects of the most critical period of the COVID-19 pandemic in Brazil. The database is made up of 14 stocks from the main banks listed on the São Paulo Stock Exchange (B3). The methodology of dynamic connectedness in the frequency domain based on a TVP-VAR model was used. The results showed an integration influenced by political, social, economic events and, mainly, by the COVID-19 pandemic. The level of this integration ranged from 20% to over 50%. The highest peak coincided with the beginning of the increase in cases of COVID-19 in the year 2020. Short-term transmissions were predominant throughout the analyzed period. The banks that showed the greatest potential risk of contagion were Banco do Brasil (BBAS3), Bradesco (BBDC3) and Itaú-Unibanco (ITUB3) with a predominance of transmissions of short-term shocks. The dynamic behavior of the sample integration revealed that there is the possibility of risk diversification in a portfolio composed of stocks of these banks, since the stocks of the analyzed banks showed different patterns of response to the same events. The second essay had the general objective of analyzing the volatility connectedness between the stocks of the main banks operating in Brazil that are listed on B3 during normal market periods. The period of analysis runs from February 1, 2016 to March 17, 2020. The database is composed of 12 stocks of the main banks listed on B3. The methodology of dynamic connectedness in the frequency domain was used. The results showed that in normal market periods and also when there are specific situations of uncertainty, the volatility of bank stocks in Brazil is transmitted to prices initially within a week. Afterwards, there is a period of one month in which the connection is reduced to levels below 5%. During this period, the agents process the information that may generate more lasting repercussions in the market, which culminates in a new increase in connectedness one month after the occurrence of those events that they considered relevant. Furthermore, low-frequency net directional connectedness was the only frequency connected at a relevant level, after the 1-5 day frequency range. It was also found that the largest net transmitters of shocks were Banco do Brasil, Itaú, Bradesco and Banco ABC Mercantil. With this, the potential that the stocks of these banks have to systematically affect the performance of the Brazilian banking stock market was evidenced. Mainly because the shocks to the stock prices of these banks persist longer and with more force than the shocks of the other banks.

Keywords: bank stocks, volatility transmissions; dynamic connectedness, model TVP-VAR.

JEL Classification: G21, G01, G11, G14.

Sumário

1	Integração dinâmica e transmissão de choques entre os bancos no Brasil: Uma abordagem em TVP-VAR.....	11
1.1	Introdução.....	11
1.2	Revisão da literatura empírica.....	13
1.2.1	Conectividade entre instituições financeiras.....	16
1.2.2	O impacto de eventos no mercado de ações.....	17
1.2.3	COVID-19 e o mercado de ações.....	18
1.3	Dados, softwares e metodologia.....	19
1.3.1	Dados e softwares.....	19
1.3.2	Detalhes sobre o cálculo dos retornos e relatório estatístico.....	20
1.3.3	Conectividade de frequência baseado em TVP-VAR.....	25
1.3.4	Estatísticas de rede complexas.....	29
1.4	Resultados.....	32
1.4.1	Conectividade dinâmica média.....	33
1.4.2	Redes complexas de conectividades dinâmicas totais.....	36
1.4.3	Conectividade dinâmica total	40
1.4.4	Conexão dinâmica direcional total líquida.....	42
1.5	Considerações finais.....	50
	Referências.....	53
	Anexo A	56
2	Conexões de volatilidade entre os principais bancos no Brasil em tempos normais de mercado: Uma abordagem no domínio da frequência.....	61
2.1	Introdução.....	61
2.2	Revisão de literatura.....	63
2.3	Dados e metodologia.....	66
2.3.1	Dados.....	67
2.3.2	Conectividade de Diebold e Yilmaz.....	67
2.3.3	Parcelas da variância.....	68
2.3.4	Spillovers totais.....	68
2.3.5	Spillovers direcionais.....	69
2.3.6	Spillovers líquidos.....	69
2.3.7	Spillovers líquidos em pares.....	69

2.3.8	Conectividade no domínio da frequência de Baruník e Krehlík.....	70
2.4	Resultados.....	73
2.5	Considerações finais.....	80
	Referências.....	82

1 INTEGRAÇÃO DINÂMICA E TRANSMISSÃO DE CHOQUES ENTRE OS BANCOS NO BRASIL E IMPACTO DA PANDEMIA DE COVID-19: UMA ABORDAGEM EM TVP-VAR

1.1 Introdução

O histórico de crises financeiras motivadas por pânicos bancários é bastante anterior à Crise Financeira Internacional de 2008. O trabalho seminal de Kindleberger e Aliber (2005) e as obras de Krugman (2000) e Ferguson (2020) retratam bem as causas e os efeitos da história dessas crises. Ainda assim, ela evidenciou que a falta de regulação adequada para as transações que envolvem o mercado bancário e os ativos financeiros, como ações e derivativos, podem desencadear sérios problemas para a economia global. Bastam apenas algumas falências ou grandes perdas de alguns bancos considerados sistemicamente importantes para que o aumento da incerteza gere pânico nos vários segmentos do mercado financeiro e se transfira para a economia real, com queda dos investimentos e desemprego. Um banco é considerado sistemicamente importante, dentro de um sistema complexo como uma rede de transações financeiras, se sua falência afetar pesadamente esta rede. Nesse sentido, estudar a resiliência da rede à choques externos é um ponto crucial para o exame do funcionamento, das fragilidades e da solidez dos sistemas financeiros. E os estudos que investigam integração entre ações de bancos podem efetivamente contribuir para a compreensão deste assunto, uma vez que ajudam tanto em assuntos relacionados à mesoeconomia (regulação financeira, principalmente), quanto a temas relacionados à teoria do investimento (decisões de alocação de aplicações em carteiras que envolvam ações de bancos, sobretudo).

Para além das crises financeiras, outros fatores exógenos críticos como a recente Guerra da Ucrânia e as sanções financeiras contra a Rússia ou a pandemia de COVID-19 causaram impactos relevantes nos mercados acionários de vários países. Em relação à pandemia, Al-Awadhi *et al.* (2021) revelaram que ela gerou externalidades negativas significativas nos retornos de ações de muitas empresas no mercado de ações chinês. Ahmad *et al.* (2021) mostraram que a pandemia reverteu o ciclo de negócios global com impactos de dimensões micro e macroeconômicas. Engelhardt *et al.* (2021) concluíram que o número crescente de anúncios de casos de COVID-19 levou a uma maior volatilidade nos mercados financeiros globais. Izzeldin *et al.* (2021) investigaram os impactos do COVID-19 nas bolsas dos países do G7,

encontrando evidências de transição para uma situação crítica em praticamente todos os países e setores, porém com intensidades variadas.

Neste sentido, esta pesquisa teve como objetivos gerais analisar a extensão da integração do mercado de ações bancárias no Brasil e identificar o potencial de risco de contágio dentro desta rede de ações bancárias. Estes dois objetivos gerais provocaram vários questionamentos, que correspondem aos objetivos específicos: o quanto conectado está o mercado de ações de bancos no Brasil? Há possibilidades de diversificação em uma carteira composta somente de ações desses bancos? Quais são os bancos que possuem o maior potencial de transmissão de choques de preços para o restante da rede de bancos que operam no Brasil? Em qual faixa de frequência temporal as conectividades das transmissões se concentraram? As ações dos bancos brasileiros são conhecidas por sua alta resiliência à choques econômicos, financeiros, políticos etc., mas, ainda assim, como a pandemia de COVID-19 afetou as ações dos bancos brasileiros? As ações desses bancos respondem de forma homogênea aos mesmos eventos?

Com efeito, para atingir os objetivos mencionados, foi utilizado uma metodologia econométrica de mensuração de conectividade dinâmica no domínio de frequência por meio de vetores autorregressivos de parâmetros variáveis no tempo, desenvolvida por Chatziantoniou *et al.* (2021), Antonakakis *et al.* (2020), Baruník e Krelík (2018), Koop e Korobilis (2014) e Diebold e Yilmaz (2012, 2014). Foram calculadas medidas de conectividade de curtíssimo, curto, longo e longuíssimo prazos e elaboradas redes complexas e estatísticas de *network science* capazes de descrever tal dinâmica.

Nenhum dos trabalhos publicados, até o momento, investigou a conectividade entre as ações dos principais bancos que operam no Brasil utilizando a metodologia robusta adotada neste trabalho. Ver, por exemplo, os estudos anteriores que envolvem o mercado bancário brasileiro numa abordagem de integração tais como Silva *et al.* (2018), De Souza (2016), De Souza *et al.* (2015) e Hernandez *et al.* (2020).

1.2 Revisão da literatura empírica

1.2.1 Conectividade entre instituições financeiras

Hernandez *et al.* (2020) examinaram os transbordamentos de redes, as características de alocação de portfólio e o potencial de diversificação dos retornos bancários dos maiores bancos capitalizados da América desenvolvida e emergente.

Uma das metodologias utilizada para analisar os efeitos dos spillovers nos retornos bancários foi a medida de conectividade baseada na decomposição de variância do erro de previsão generalizada desenvolvida por Diebold e Yilmaz (2012, 2014, 2015). Os autores utilizaram as séries de preços das ações dos bancos de frequência diária no período de 11 de janeiro de 2011 a 10 de janeiro de 2019. As séries de preços dos bancos da América emergente incluem bancos do Brasil, México, Chile, Colômbia e Peru. No entanto, os únicos bancos brasileiros incluídos na amostra foram o Banco do Brasil, o Bradesco e o Santander Brasil. Além disso, os resultados mostraram que o Banco do Brasil e o Bradesco foram os maiores transmissores líquidos de spillovers de volatilidades entre os bancos da América emergente, seguido pelo Santander Brasil como o maior receptor líquido dos choques. Os autores também destacam que os transbordamentos de volatilidade são maiores entre os bancos do mesmo país.

De Souza et al. (2015) propuseram uma nova forma de modelar e analisar o contágio entre redes bancárias. Especificamente, analisaram o processo de contágio da insolvência por inadimplência na rede do mercado interbancário brasileiro utilizando a metodologia de Eisenberg e Noe (2001). A amostra foi composta por dados contábeis de instituições financeiras bancárias e não bancárias que operam no Brasil, visto que no Brasil são poucas as instituições financeiras que tem ações listadas na bolsa de valores. Eles constataram que o porte das instituições financeiras brasileiras não é o único determinante do potencial de contágio que cada uma pode ter na rede, além de que são os bancos que originam o contágio para as demais instituições financeiras da rede.

De Souza (2016) simula os efeitos do risco de crédito, das exigências de capital e dos choques de preços no sistema bancário brasileiro. Segundo o autor, o modelo utilizado não leva em consideração o comportamento dos bancos aos choques e, por isso, não serve como um indicador de alerta precoce. Os resultados da simulação mostraram que aumentos relativamente grandes na taxa de inadimplência levam a perdas moderadas no sistema, portanto o sistema bancário brasileiro pode ser considerado robusto. O autor também investigou a contribuição de cada instituição financeira para perdas sistêmicas sobre choques severos e descobriu que as contribuições de bancos de médio porte podem ser significativas e que as perdas sistêmicas dos bancos de grande porte se tornam as únicas significativas quando os choques são ainda mais graves.

Silva et al. (2018) simulam choques no setor real da economia brasileira e avaliam como o sistema financeiro brasileiro reage e amplifica esses eventos. Os autores utilizaram um modelo baseado em redes multicamadas para capturar as heterogeneidades entre bancos e empresas. Além disso, eles ressaltam que esse modelo considera uma rede de interdependências enquanto contabiliza conexões interbancárias, empréstimos bancários a empresas e feedback entre empresas e bancos. Os autores constataram que a estrutura de rede pode atenuar ou amplificar choques do setor real e desempenhar um papel importante no processo de contágio entre os setores real e financeiro. Além disso, descobriram que os bancos estatais são os bancos brasileiros mais suscetíveis a receberem choques de empresas de qualquer setor econômico.

Antonakakis et al. (2020) aprimoraram as medidas de conectividade dinâmica desenvolvidas inicialmente pelos trabalhos de Diebold e Yilmaz (2012, 2014), por meio de um modelo de vetor autorregressivo de parâmetro variável no tempo (TVP-VAR - *Time-Varying Parameter Vector Autoregressive model*) que se baseia em uma estrutura de variância-covariância que oscila ao longo do tempo. Segundo os autores, esta nova forma de medir a conectividade dinâmica por meio dos choques de preços entre os ativos de diversas naturezas de um determinado mercado, ou entre mercados, permite capturar possíveis mudanças na estrutura subjacente dos dados de forma mais flexível e robusta. As vantagens desta inovação metodológica são que: mudanças potenciais nos valores dos parâmetros podem ser determinadas com mais precisão; não há necessidade de definir arbitrariamente o tamanho da janela rolante; não há perdas de observações nos cálculos das medidas dinâmicas, porque nenhuma análise de janela rolante está envolvida; e esta abordagem é menos sensível à outliers, pois se baseia em filtros multivariados de Kalman.

No Brasil, outro trabalho que envolve técnicas de TVP-VAR foi desenvolvido por Caldeira, Moura e Santos (2015). Nesse trabalho, a abordagem dos já citados Koop & Korobilis (2013) foi adotada para efetuar previsões referentes à inflação (IPCA), taxa de juros (SELIC) e do indicador mensal do PIB elaborado pelo Banco Central (IBC-Br). Tais previsões foram feitas para vários horizontes temporais, sendo também implementadas algumas estratégias de previsão fundamentadas em seleção e combinação dinâmicas entre diferentes especificações. Após isto, os autores compararam as previsões com outras provenientes de modelos VAR bayesianos, modelos VAR aumentados com fatores e outros modelos concorrentes por intermédio

da metodologia *model confidence set*. Finalmente, os resultados indicaram que a especificação TVP-VAR persistiu sendo a única presente, de modo perene, no rol dos melhores modelos, para qualquer variável analisada ou do horizonte temporal de previsão selecionado.

Um dos trabalhos mais recentes publicado que envolve medição de rede de conectividade de volatilidade de retornos de ações bancárias na linha de Diebold e Yilmaz é o trabalho de Demirer et al. (2018). A sua importância está no fato de que ele é o único trabalho, apesar da amostra limitada, que teve uma abrangência global quando o assunto é transmissão de volatilidade de retornos dos bancos. Os referidos autores utilizaram uma amostra de 96 bancos de 29 economias entre desenvolvidas e emergentes. O período de estudo foi de 12 de setembro de 2003 a 7 de fevereiro de 2014. Contudo, os únicos bancos brasileiros incluídos na análise foram o Itaú e o Bradesco. Apesar disso, tal trabalho revelou resultados interessantes para a literatura. O primeiro deles é que existe um forte agrupamento de transmissão dentro de cada país e que esse agrupamento interno difere de país para país. O segundo resultado interessante é que existe um forte agrupamento de transmissão entre países, porém esses agrupamentos são regionais. Os resultados revelaram que os maiores cluster são, nessa ordem, o anglo/europeu, o americano/canadense e o japonês. Por fim, os autores geraram uma tabela de conectividade de rede entre os seis continentes: África, Ásia, Europa, América do Norte, América do Sul e Oceania. Os resultados foram que o continente que mais transmite volatilidade é a Europa seguida por América do Norte, Ásia, América do sul, Oceania e África. Em relação ao recebimento de *spillovers* de volatilidade, a ordem é Europa, América do Norte, Ásia, Oceania, América do Sul e África.

Diebold e Yilmaz (2016) estudaram as volatilidades diárias dos retornos das ações de 35 grandes instituições financeiras, 18 europeias e 17 norte-americanas. O período de análise foi de janeiro de 2004 a junho de 2014. Os dados europeus foram compostos de bancos comerciais, enquanto os americanos foram compostos de quase todas as instituições financeiras importantes dos EUA. De acordo com os autores, a maioria dessas instituições financeiras utilizadas no trabalho é classificada como bancos globais sistematicamente importantes. O primeiro resultado destacado foi que durante o período de 2006 e 2007 a direção da conectividade era dos EUA para a Europa, porém a partir de 2008 essa conexão se tornou bidirecional. O segundo resultado importante foi que houve um aumento substancial, em junho de 2011, da

conexão entre as instituições financeiras dos EUA e da União europeia, consistente com a abrangente deterioração das instituições financeiras da União europeia na época. Um último resultado interessante de Diebold e Yilmaz (2016) é que bancos de tamanhos semelhantes não tiveram necessariamente uma transmissão de volatilidade homogênea, mas sim foi revelado que a transmissão de volatilidade das instituições financeiras dessas regiões apresentou um comportamento heterogêneo quanto ao tamanho. O maior banco na amostra, HSBC, não teve uma alta transmissão de volatilidade do período de análise.

Baruník e Krehlík (2018) investigaram a conectividade intra-mercado do setor financeiro dos EUA em termos de conectividade de volatilidade em diferentes frequências. Os autores concluíram que houve uma menor conexão entre os participantes do mercado norte americano durante os períodos normais de mercado, visto que não há motivo para pânico em condições normais de mercado. Contudo, durante períodos de crise, as conexões alcançaram níveis elevados.

1.2.2 O impacto de eventos no mercado de ações

O impacto de eventos, de diversas naturezas, sobre o mercado de ações vem sendo constantemente estudado pela literatura. Bash e Alsaif (2019) investigaram o efeito do desaparecimento, no ano de 2017, do jornalista saudita Jamal Khashoggi na bolsa de valores da Arábia Saudita. Khashoggi começou a fazer críticas de cunho político ao governo saudita. Os autores concluíram que tal evento suporta uma tendência de queda nos retornos anormais acumulados em todas as empresas, implicando um efeito negativo da incerteza nos retornos das ações.

He et al. (2017) investigaram os efeitos econômicos da tensão política não violenta causada pelo debate sobre a soberania de Taiwan. Os pesquisadores concluíram que eventos políticos não violentos levam a uma queda média de 200 pontos base nos retornos das ações de Taiwan.

Zach (2003) analisou os padrões de retorno do índice da bolsa de valores de Tel-Aviv e das ações de empresas israelenses negociadas nos EUA após anúncios de notícias relacionadas ao processo de paz na região. O autor concluiu que os retornos na bolsa são mais extremos após eventos políticos, inclusive para as ações duplamente listadas nos EUA e em Israel, do que os retornos em dias que não seguem eventos políticos.

Dangol (2008) estudou a reação do mercado de ações nepalês aos anúncios de eventos políticos não previstos por meio da metodologia de estudo de eventos. Seus resultados revelam que os anúncios políticos considerados de boas notícias geram retornos anormais positivos, o contrário acontece quando tais anúncios são considerados más notícias. Além disso, o autor afirma que há uma forte ligação entre incerteza política e retorno de ações ordinárias.

1.2.3 COVID-19 e o mercado de ações

No Brasil, assim como em outros países, a pandemia de COVID-19 fez com que muitas empresas diminuíssem suas receitas, tivessem seus custos aumentados e, com isto, houve aumento da incerteza em relação aos lucros futuros. Naturalmente, tal aumento da incerteza e do risco de inadimplência, decorrente do aumento de falências e do desemprego, refletiu-se no mercado de ações e no setor bancário, dado que ambos estão muito associados à atividade produtiva. Nesse sentido, cabe uma breve revisão da literatura de como a pandemia afetou os mercados acionários internacionais.

Para Azimli (2020) a pandemia de COVID-19 afetou o mercado de ações por dois canais principais. O primeiro canal refere-se ao impacto da maior incerteza sobre os fluxos de caixa esperados das empresas listadas nas bolsas, visto que os modelos de *valuation* estipulam que o valor de uma ação resulta do valor presente dos fluxos de caixas estimados. O segundo canal diz respeito ao aumento das taxas de retornos exigidas pelos investidores no ambiente de maior incerteza. Este autor examinou o efeito da COVID-19 no grau e na estrutura da dependência risco-retorno nos EUA. Os resultados de sua análise de regressão quantílica evidenciaram uma estrutura de dependência assimétrica de cauda esquerda dos retornos setoriais com carteira de mercado. Após o primeiro e mais forte surto de COVID-19, o grau de dependência entre retornos e portfólio de mercado aumentou nos quantis mais altos. Ademais, o surto converteu a dependência de cauda esquerda em uma dependência de cauda direita. A interação entre o *Google Search Index for coronavirus* (GSIC) e os retornos também foram examinados, com a descoberta de uma dependência assimétrica GSIC-retorno significativa nas caudas.

Al-Awadhi, Alsaifi et al. (2020) analisaram se as doenças infecciosas contagiosas afetam os resultados do mercado de ações. Com base em um

experimento natural, eles usaram a análise de dados em painel para investigar o efeito do vírus COVID-19, que é uma doença infecciosa contagiosa, no mercado de ações chinês. Chegaram a evidências que sugerem que o crescimento diário no total de casos confirmados e no total de casos de morte causados por COVID-19 geraram externalidades negativas expressivas nos retornos das ações em todas as empresas.

Cheng et al. (2022), analisaram o período de 4 de janeiro de 2016 a 1 de dezembro de 2020. Utilizaram dados *intraday* de alta frequência de índices do mercado de ações de 19 economias da região Ásia-Pacífico. Com essa amostra, calcularam as volatilidades e as utilizaram no índice de transmissão de volatilidade (*volatility spillovers*) desenvolvido por Diebold e Yilmaz (2014) juntamente com o penalizador de parâmetros lag sparse LASSO proposto por Simon et al. (2013) para um VAR de alta dimensão. O objetivo dos autores foi testar como a pandemia de COVID-19 afetou a rede de conectividade de volatilidade do mercado de ações dessas 19 economias. Os autores concluíram que o surto da pandemia de COVID-19 fortaleceu e aumentou o nível de conectividade na referida região. Este nível manteve-se alto durante todo o ano de 2020.

1.3 Dados, softwares e metodologia

1.3.1 Dados e softwares

Os dados utilizados consistem nas séries temporais dos retornos dos preços diários das ações de 14 bancos (Tabela 1) listados no Ibovespa (B3). Tais ações são as únicas que possuíam um histórico de cotações mais extenso possível na B3, portanto o tamanho de tal amostra é o maior possível. O período da análise foi do dia 30 de abril de 2009 a 11 de março de 2022. Esses dados foram coletados do site Yahoo Finanças inicialmente na forma de séries temporais dos preços diários das ações desses bancos e em seguida foram calculadas as séries dos retornos. O conjunto completo de dados é composto por 3191 observações diárias para cada banco totalizando 44.674 observações diárias dos retornos e das volatilidades das ações dos bancos em análise.

Foram calculadas medidas de conectividade em curto, médio, longo e longuíssimo prazo no pacote econométrico “*ConnectednessApproach*”¹ do software livre R 3.3.0 (RStudio Desktop 2022²). Para estimar as redes e as estatísticas das

¹ <https://cran.r-project.org/src/contrib/Archive/ConnectednessApproach/>

² <https://www.rstudio.com/products/rstudio/download/>.

mesmas, foi utilizado o software livre Gephi 0.9.3. A distribuição de layout utilizada foi a Fruchterman-Reingold, também disponível nessa versão do Gephi³.

Tabela 1. Ações e nomes dos bancos

BBAS3	Banco do Brasil
BBDC3	Banco Bradesco
BNBR3	Banco do Nordeste
ITUB3	Banco Itaú
ABCB4	Banco ABC Brasil
SANB3	Banco Santander
BMEB3	Banco Mercantil do Brasil
BPAN4	Banco Pan
PINE4	Banco Pine PN
RPAD3	Alfa Holding ON
BAZA3	Banco da Amazônia ON
	Banco Mercantil de
BMIN3	Investimentos ON
BRSR3	Banco Banrisul ON
BRIV3	Banco Alfa de Investimento ON

Fonte: Elaborada pelo autor.

O período considerado neste trabalho abrange vários eventos críticos de natureza política e econômica que ocorreram no Brasil, além da questão sanitária da Covid-19. Neste período, houve três eleições presidenciais (2010, 2014 e 2018). Além disso, o ano de 2013 foi marcado por uma série de manifestações populares que revelaram a insatisfação da população com a classe política e com a má qualidade dos serviços públicos.

1.3.2 Detalhes sobre o cálculo da volatilidade e breve relatório estatístico

Os resultados empíricos foram baseados nas séries diárias dos retornos absolutos das ações dos 14 bancos, os quais foram calculados da seguinte forma: $r_{ir} = |C_{it} - C_{it-1}| / C_{it-1} * 100$, onde C_{it} é o registro do preço diário de fechamento da ação do banco i no dia t . Os preços de fechamento utilizados foram ajustados para dividendos e desdobramentos. Os retornos absolutos estão representados na Figura 1.

³ <https://gephi.org/users/download/>




Figura 1. Retornos absolutos das ações de Bancos da B3

Fonte: Cálculos do autor no RStudio.

A Tabela 2 indica as propriedades estatísticas das séries dos retornos absolutos dos bancos em análise. De acordo com essa tabela, a volatilidade dos preços é, em média, mais alta para o Banco Santander (SANB3), seguida por Banco Pan (BPAN4) e Banco do Brasil (BBAS3).

Em relação à volatilidade dos preços, a maior está associada ao Banco Barinsul (BRSR3), seguido por Alfa Holdings (RPAD3), Banco Mercantil de Investimentos (BMIN3) e Banco Santander (SANB3), enquanto a menor variação pertence ao Banco Itaú (ITUB3), seguido por Banco Bradesco (BBDC3), Banco ABC Brasil (ABCB4) e Banco do Brasil.

Além disso, todas as volatilidades de preços têm uma distribuição assimétrica à direita, isto é, há predominância de valores baixos e baixa frequência da ocorrência de valores altos. Além disso, essas distribuições são leptocúrticas, isto é, possuem uma curva de frequência mais fechada do que uma distribuição normal, o que corrobora com o teste de normalidade de Jarque e Bera (1980), também informado na Tabela 2, indicando que nenhuma das séries é normalmente distribuída.

Adicionalmente, a Tabela 2 informa por meio do teste de raiz unitária ERS, que todas as séries são estacionárias. Também informa que todas as séries dos retornos são autocorrelacionadas e exibem erros ARCH/GARCH por meio das estatísticas Lung-Box ponderadas de Fisher e Gallagher (2012) com 1% de significância.

Essas características reforçam a aplicação do modelo TVP-VAR com variância-covariância heteroscedástica como um modelo adequado para modelar a interdependência do mercado de ações dos bancos no Brasil.

Tabela 2. Estatísticas descritivas

	BBAS3	BBDC3	BNBR3	ITUB3	ABCB4
Média	1.813	1.525	0.941	1.359	1.601
Variância	3.334	2.149	5.653	1.754	2.338
Assimetria	3.022*** (0.000)	2.648*** (0.000)	3.737*** (0.000)	2.953*** (0.000)	2.888*** (0.000)
Curtose	17.346*** (0.000)	13.479*** (0.000)	17.597*** (0.000)	20.682*** (0.000)	20.358*** (0.000)
JB	44878.785*** (0.000)	27895.785*** (0.000)	48615.311*** (0.000)	61527.184*** (0.000)	59557.379*** (0.000)
ERS	[-7.079]*** (0.000)	[-6.294]*** (0.000)	[-15.865]*** (0.000)	[-3.705]*** (0.000)	[-9.077]*** (0.000)
Q(20)	1091.96*** (0.000)	817.85*** (0.000)	335.82*** (0.000)	435.47*** (0.000)	367.46*** (0.000)
Q(20)^2	1119.50*** (0.000)	1381.77*** (0.000)	171.54*** (0.000)	204.59*** (0.000)	316.92*** (0.000)
	SANB3	BMEB3	BPAN4	PINE4	RPAD3
Média	2.537	1.345	2.06	1.70	1.142
Variância	11.876	8.487	6.86	5.07	13.709
Assimetria	12.096*** (0.000)	4.798*** (0.000)	4.838*** (0.000)	5.35*** (0.000)	6.351*** (0.000)
Curtose	374.460*** (0.000)	45.055*** (0.000)	46.943*** (0.000)	50.213*** (0.000)	62.448*** (0.000)
JB	18727178.242*** (0.000)	282233.641*** (0.000)	305543.82*** (0.000)	350553.24*** (0.000)	540128.57*** (0.000)
ERS	-0,25 (0.806)	[-3.035]*** (0.002)	[-15.933]*** (0.000)	[-13.193]*** (0.000)	[-19.395]*** (0.000)
Q(20)	101.99*** (0.000)	154.31*** (0.000)	1073.40*** (0.000)	1026.49*** (0.000)	114.65*** (0.000)
Q(20)^2	0.297 -1.000	14.17 (0.161)	732.09*** (0.000)	577.54*** (0.000)	48.47*** (0.000)
	BAZA3	BMIN3	BRSR3	BRIV3	
Média	1.404	0.690	1.545	1.148	
Variância	4.130	12.266	14.711	8.349	
Assimetria	2.928*** (0.000)	12.061*** (0.000)	8.494*** (0.000)	9.953*** (0.000)	
Curtose	15.442*** (0.000)	243.472*** (0.000)	136.192*** (0.000)	224.392*** (0.000)	
JB	36276.36*** (0.000)	7961420.45*** (0.000)	2505284.06*** (0.000)	6749480.82*** (0.000)	
ERS	[-18.330]*** (0.000)	[-20.202]*** (0.000)	[-16.463]*** (0.000)	[-10.260]*** (0.000)	
Q(20)	592.58*** (0.000)	166.30*** (0.000)	315.85*** (0.000)	270.56*** (0.000)	
Q(20)^2	457.03*** (0.000)	5.01 (0.955)	194.83*** (0.000)	6.24 (0.885)	

Notas: * $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$. () representa os erros padrão. D'Agostino (1970) e Anscombe e Glynn (1983) são usadas para capturar os níveis de assimetria e curtose. JB (Jarque e Bera, 1980) é o teste para Normalidade. ERS (Stock et al. , 1996) é o teste para estacionariedade. Q(20) e Q(20)^2 são as estatísticas Ljung-Box ponderada para correlação serial nos retornos e série quadrada de Fisher e Gallagher (2012), respectivamente.

A Tabela 3 apresenta os coeficientes de correlação não paramétricos de Kendall entre os retornos absolutos dos bancos analisados. Tais coeficientes informam que a maioria dos retornos absolutos são positivamente correlacionados. No entanto, há retornos negativamente correlacionados. Entre os positivamente correlacionados, as correlações mais fortes são entre o Itaú (ITUB3) e o Bradesco (BBDC3), entre o Bradesco (BBDC3) e o Banco do Brasil (BBAS3) e entre o Banco do Brasil (BBAS3) e o Itaú (ITUB3), respectivamente. Já as correlações negativas são entre os retornos do Banco do Brasil (BBAS3) e o Banco Mercantil do Brasil (BMEB3), Banco do Brasil (BBAS3) e o Banco Mercantil de Investimentos (BMIN3), Banco do Brasil e Banco Alfa de Investimentos (BRIV3), seguidas por Banco ABC Brasil (ABCB4) e Banco Alfa de Investimentos (BRIV3), Banco Santander (SANB3) e o Banco Mercantil do Brasil (BMEB3) e por Banco Santander (SANB3) e o Banco Alfa de Investimentos (BRIV3).

Tabela 3. Coeficientes de correlação não paramétrico de Kendall

	BBAS3	BBDC3	BNBR3	ITUB3	ABCB4	SANB3	BMEB3	BPAN4	PINE4	RPAD3	BAZA3	BMIN3	BRSR3	BRIV3
BBAS3	1.000	0.320	0.013	0.268	0.131	0.120	-0,026	0.066	0.053	0.014	0.054	-0,005	0.019	-0,015
BBDC3	0.320	1.000	0.041	0.337	0.142	0.107	0.019	0.081	0.089	0.040	0.070	0.014	0.051	0.004
BNBR3	0.013	0.041	1.000	0.014	0.015	0.046	0.087	0.075	0.075	0.058	0.060	0.126	0.131	0.038
ITUB3	0.268	0.337	0.014	1.000	0.151	0.097	0.000	0.075	0.068	0.023	0.055	0.034	0.048	0.031
ABCB4	0.131	0.142	0.015	0.151	1.000	0.045	0.023	0.064	0.023	0.013	0.059	0.018	0.023	-0,009
SANB3	0.120	0.107	0.046	0.097	0.045	1.000	-0,004	0.031	0.051	0.020	0.006	0.013	0.033	-0,003
BMEB3	-0,026	0.019	0.087	0.000	0.023	-0,004	1.000	0.067	0.059	0.111	0.036	0.116	0.075	0.096
BPAN4	0.066	0.081	0.075	0.075	0.064	0.031	0.067	1.000	0.080	0.111	0.060	0.080	0.070	0.033
PINE4	0.053	0.089	0.075	0.068	0.023	0.051	0.059	0.080	1.000	0.037	0.055	0.022	0.082	0.044
RPAD3	0.014	0.040	0.058	0.023	0.013	0.020	0.111	0.111	0.037	1.000	0.066	0.131	0.162	0.192
BAZA3	0.054	0.070	0.060	0.055	0.059	0.006	0.036	0.060	0.055	0.066	1.000	0.051	0.059	0.050
BMIN3	-0,005	0.014	0.126	0.034	0.018	0.013	0.116	0.080	0.022	0.131	0.051	1.000	0.113	0.089
BRSR3	0.019	0.051	0.131	0.048	0.023	0.033	0.075	0.070	0.082	0.162	0.059	0.113	1.000	0.114
BRIV3	-0,015	0.004	0.038	0.031	-0,009	-0,003	0.096	0.033	0.044	0.192	0.050	0.089	0.114	1.000

Fonte: Cálculos do autor no RStudio.

1.3.3 Conectividade de frequência baseado em TVP-VAR

O presente trabalho utilizou a abordagem de conectividade de frequência baseada em um modelo de vetores autorregressivos com parâmetros variantes ao longo do tempo ou TVP-VAR (*time varying parameters - vector autorregressive model*) desenvolvida e descrita por Chatziantoniou *et al.* (2021). Esta abordagem é uma extensão que combina as metodologias utilizadas nos trabalhos de Antonakakis *et al.* (2020), Baruník e Krehlík (2018), Koop e Korobilis (2014) e de Diebold e Yilmaz (2012, 2014). Chatziantoniou *et al.* (2021) enfatizam que tal metodologia é adequada para investigar questões relacionadas à interdependência dos mercados de ações, por exemplo, visto que tal estrutura permite medir a conectividade em diferentes faixas de frequência e melhora a precisão dessas medidas de conectividade dinâmica porque elas são baseadas em um VAR de parâmetros variáveis no tempo. Assim sendo, tem-se o seguinte TVP-VAR(p):

$$x_t = \phi_{1t}x_{t-1} + \phi_{2t}x_{t-2} + \dots + \phi_{pt}x_{t-p} + \varepsilon_t \quad \varepsilon_t \sim N(0, \Sigma_t) \quad 1)$$

onde x_t, x_{t-1} e ε_t são vetores de dimensão $N \times 1$, ao passo que Σ_t e ϕ_{it} , com $i = 1, \dots, p$, são matrizes de dimensão $N \times N$, com a primeira representando a matriz de variância-covariância variável no tempo e a segunda, o coeficiente VAR variável no tempo. Por simplicidade, utiliza-se a matriz polinomial com defasagens $\phi(L) = [I_N - \phi_{1t}L - \dots - \phi_{pt}L^p]$, onde I_N retrata a matriz identidade. Assim, o modelo pode ser reescrito como sendo $\phi(L)x_t = \varepsilon_t$. Se o processo TVP-VAR for estacionário, ele pode ser escrito como um TVP-VMA (∞), a partir do uso do teorema de Wold: $x_t = \psi(L)\varepsilon_t$ onde a matriz de polinômios de defasagens infinitas $\psi(L)$, é calculada recursivamente de $\phi(L) = [\psi(L)]^{-1}$. No entanto, como $\psi(L)$ inclui um número infinito de defasagens, ela é aproximada por ψ_h e calculada em um horizonte de $h = 1, \dots, H$.

Precisa-se dos coeficientes TVP-VMA, ψ_h , para calcular a decomposição de variância do erro de previsão generalizada (GFEVD) (Ver Koop *et al.*, 1996, e Pesaran e Shin, 1998). Tal procedimento é essencial nessa abordagem de conectividade. Em geral, adota-se preferencialmente a GFEVD em relação à sua alternativa ortogonal, dado que os resultados recuperados são invariantes à ordenação das variáveis. Ademais, Wiesen *et al.* (2018) recomendam o uso da GFEVD na hipótese de não

haver um referencial teórico que seja capaz de identificar a estrutura de erro. A GFEVD, nesse sentido e no contexto da presente pesquisa, pode ser considerada como o efeito que um choque na ação j tem na ação i em termos de sua variância de erro de previsão. Sendo assim, ela pode ser definida da seguinte forma:

$$\theta_{ijt}(H) = \frac{(\Sigma_t)_{jj}^{-1} \sum_{h=0}^H ((\psi_h \Sigma)_{ijt})^2}{\sum_{h=0}^{H-1} (\psi_h \Sigma \psi_h')_{ii}} \quad 2)$$

$$\tilde{\theta}_{ijt}(H) = \frac{\theta_{ijt}(H)}{\sum_{k=1}^N \theta_{ikt}(H)} \quad 3)$$

onde $\tilde{\theta}_{ijt}(H)$ simboliza a contribuição da ação j para a variância do erro de previsão da ação i no horizonte H . Dado que a soma das linhas de $\tilde{\theta}_{ijt}(H)$ não são iguais a um, a normalização se faz necessária e isto resulta em $\tilde{\theta}_{ijt}$. Por intermédio dessa normalização alcançam-se as seguintes identidades: $\sum_{i=1}^N \tilde{\theta}_{ijt}(H) = 1$ e $\sum_{j=1}^N \sum_{i=1}^N \tilde{\theta}_{ijt}(H) = N$.

Agora, nesta etapa, todas as medidas de conectividade podem ser computadas. Inicia-se com a com a conectividade líquida em pares (*net pairwise connectedness*), a qual é calculada assim:

$$NPDC_{ijt}(H) = \tilde{\theta}_{ijt}(H) - \tilde{\theta}_{jit}(H) \quad 4)$$

Quando se tem $NPDC_{ijt}(H) > 0$, a ação j influenciará a ação i mais do que será influenciada por esta. Já quando $NPDC_{ijt}(H) < 0$, então a ação j será mais influenciada pela ação i do que o oposto.

A conectividade direcional total “para outros” (TO) quantifica o quanto um choque na ação i é transmitido para todas as outras ações j :

$$TO_{it}(H) = \sum_{i=1, i \neq j}^N \tilde{\theta}_{jit}(H) \quad 5)$$

A conectividade direcional total “de outros” (FROM) mede o quanto a ação i recebendo de choques de todas as outras ações j :

$$FROM_{it}(H) = \sum_{j=1, i \neq j}^N \tilde{\theta}_{ijt}(H) \quad 6)$$

A conectividade direcional total líquida, com isto, denota a diferença entre a conectividade direcional total “para outros” (TO) e a conectividade direcional total “de outros” (FROM). É, portanto, a influência que a ação i possui na rede analisada:

$$NET_{it}(H) = TO_{it}(H) - FROM_{it}(H) \quad 7)$$

Quando $NET_{it}(H) > 0$, então a ação i influenciará todas as outras mais do que será influenciada por elas. Contudo, quando $NET_{it}(H) < 0$, então a ação i será mais influenciada por todas as outras variáveis do que o oposto. Então, a ação i pode ser tida como uma ação transmissora ou receptora de choques, a depender do $NET_{it}(H)$.

Isto posto, o Índice de Conectividade Total (*Total Connectedness Index – TCI*) quantifica o grau de interconexão da rede, sendo calculado por:

$$TCI_t(H) = N^{-1} \sum_{i=1}^N TO_{it}(H) - N^{-1} \sum_{i=1}^N FROM_{it}(H) \quad 8)$$

Com isto, pode-se afirmar que esta métrica avalia o impacto médio que um choque em uma ação tem em todas as demais. Quanto maior ela for, maior será o risco de mercado e também maior será a força de integração entre os participantes deste mercado. O raciocínio recíproco também vale para este caso.

Após a avaliação da conectividade no domínio do tempo, passa-se a descrever a avaliação no domínio da frequência. Seguindo o método de decomposição espectral de Stiasny (1996), com o qual se pode explorar a relação de conectividade no domínio da frequência. Primeiramente, considere a função de resposta em frequência, $\psi(e^{-1\omega}) = \sum_{h=1}^{\infty} e^{-1i\omega} \psi_h$, onde $i = \sqrt{-1}$ e ω denota a frequência para continuar com a densidade espectral de x_t na frequência ω , a qual pode ser definida como uma transformação de Fourier do TVP-VMA(∞):

$$S_x(\omega) = \sum_{h=-\infty}^{\infty} E(x_t x'_{t-h}) e^{-1\omega h} = \psi(e^{-1\omega h}) \Sigma_t \psi'(e^{+1\omega h}) \quad 9)$$

A frequência GFEVD equivale à combinação da densidade espectral e GFEVD. Tal como foi feito na situação do domínio do tempo, é preciso normalizar a GFEVD em frequência, o que pode ser feito assim:

$$\theta_{ijt}(\omega) = \frac{(\Sigma_t)_{jj}^{-1} |\sum_{h=0}^{\infty} ((\psi_h(e^{-1\omega h}) \Sigma_t)_{ijt})|^2}{\sum_{h=0}^{\infty} (\psi(e^{-1\omega h}) \Sigma_t \psi'(e^{1\omega h}))_{ii}} \quad (10)$$

$$\tilde{\theta}_{ijt}(\omega) = \frac{\theta_{ijt}(\omega)}{\sum_{k=1}^N \theta_{ijt}(\omega)} \quad (11)$$

onde $\tilde{\theta}_{ijt}(\omega)$ representa a porção do espectro da ação i em uma ação j . Pode ser interpretada como um indicador dentro da frequência (*within-frequency indicator*).

Quando se analisa a conectividade em diferentes prazos, ao invés de em uma única frequência, agrega-se todas as frequências dentro de um intervalo específico, $d = (a, b): a, b \in (-\pi, \pi), a < b$:

$$\tilde{\theta}_{ijt}(d) = \int_a^b \tilde{\theta}_{ijt}(\omega) d\omega \quad (12)$$

Pode-se agora calcular as medidas de conectividade de Diebold e Yilmaz (2012, 2014), as quais podem levar a interpretações idênticas. Todavia, neste caso, elas remetem às medidas de conectividade de frequência, as quais informam acerca dos transbordamentos (*spillovers*) em uma determinada faixa de frequência d :

$$NPDC_{ijt}(d) = \tilde{\theta}_{ijt}(d) - \tilde{\theta}_{jit}(d) \quad (13)$$

$$TO_{it}(d) = \sum_{i=1, i \neq j}^N \tilde{\theta}_{jit}(d) \quad (14)$$

$$FROM_{it}(d) = \sum_{j=1, j \neq i}^N \tilde{\theta}_{ijt}(d) \quad (15)$$

$$NET_{it}(d) = TO_{it}(d) - FROM_{it}(d) \quad (16)$$

$$TCI_t(d) = N^{-1} \sum_{i=1}^N TO_{it}(d) - N^{-1} \sum_{i=1}^N FROM_{it}(d) \quad (17)$$

Nesse sentido, todas as medidas geram informações a respeito do alcance específico, porém não sobre o impacto geral. Com efeito, Baruník e Krehlík (2018) propuseram a ponderação de todas as medidas de contribuição de cada banda de frequência d em relação ao sistema geral por intermédio de $\Gamma(d) = \sum_{i,j=1}^N \tilde{\theta}_{ijt}(d)/N$.

$$\widetilde{NPDC}_{ijt}(d) = \Gamma(d)NPDC_{ijt}(d) \quad 18)$$

$$\widetilde{TO}_{it}(d) = \Gamma(d)TO_{it}(d) \quad 19)$$

$$\widetilde{FROM}_{it}(d) = \Gamma(d)FROM_{it}(d) \quad 20)$$

$$\widetilde{NET}_{it}(d) = \Gamma(d)NET_{it}(d) \quad 21)$$

$$\widetilde{TCI}_t(d) = \Gamma(d)TCI_t(d) \quad 22)$$

Finalmente, têm-se a relação entre as medidas no domínio do tempo de Diebold e Yilmaz (2012, 2014) com as medidas de conectividade no domínio da frequência de Baruník e Krehlík (2018):

$$NPDC_{ijt}(H) = \sum_d NPDC_{ijt}(d) \quad 23)$$

$$TO_{it}(H) = \sum_d TO_{it}(d) \quad 24)$$

$$FROM_{it}(H) = \sum_d FROM_{it}(d) \quad 25)$$

$$NET_{it}(H) = \sum_d NET_{it}(d) \quad 26)$$

$$TCI_{it}(H) = \sum_d TCI_{it}(d) \quad 27)$$

1.3.4 Estatísticas de redes complexas

Este trabalho utiliza redes direcionadas (digrafos, *digraphs* ou *directed graphs*) elaboradas a partir de métricas estatísticas de rede complexas (*network statistics*). Elas são analisadas ao nível dos agentes (usando medidas de centralidade, que são os

graus ponderados de entrada e saída). Também utilizamos uma rede com as classes de modularidade, isto é, uma análise de *clusters* envolvendo estatísticas de redes.

Em essência, redes são abstrações que possibilitam codificar relações entre pares de objetos. Barabási (2003) define rede complexa como um grafo que apresenta estrutura topográfica não usual formado por um conjunto de nódulos (vértices) interligados por meios de arestas. Por sua vez, define-se grafo como uma estrutura matemática na qual vértices (nós ou nodos) são usados para representar o objeto de interesse e as linhas (arestas) são usadas para ligar os vértices estabelecendo que entre os vértices conectados há alguma relação.

O estudo dos grafos é uma das áreas mais promissoras da matemática discreta e teve início em 1936 com Euler, mas só se desenvolveu a partir da segunda metade do século XIX quando Arthur Cayley solucionou problemas acerca de formulas de estrutura de compostos químicos.

Com o advento da tecnologia da informação e a popularização dos computadores, que permitiram a análise de quantidade significativa de dados, as pesquisas na área de redes alcançaram um novo patamar deixando de se concentrarem em pequenas redes e nas propriedades de vértices individuais ou arestas e passaram a focar em propriedades estatísticas de larga escala, assim se tornou comum estudos com milhões de vértices (Barabási, 2003).

A mudança de paradigma revelou diversas características que diferenciavam significativamente as redes observadas no mundo real das redes aleatórias, sendo que a topologia e evolução daquelas demonstraram propriedades organizacionais robustas e que diferem das redes aleatórias. Neste fato reside uma das origens do termo “redes complexas” (Barabási, 2003).

O grau de um nó é caracterizado pelo número de arestas conectadas a ele. Segundo Newman (2003a e 2003b) o grau de distribuição é dividido em grau de entrada e grau de saída em grafos direcionados, que representam respectivamente o número de citações recebidas por um nó e o número de citações executadas por um nó. O grau de entrada de um nó pode indicar sua importância e implicar na possibilidade de ser citado no futuro, contudo, existem algumas métricas que podem caracterizar essa importância de diferentes maneiras como a centralidade de autovetor.

A centralidade do grau (ou valência) é definida pela seguinte expressão:

$$k_i = \sum_{j=1}^n a_{ij}, \quad 0 < k_i < n \quad (1) \quad \text{e} \quad k_v = |N_v| \quad 0 < k_v < n \quad (28)$$

Onde a_{ij} é a entrada da i -ésima linha e j -ésima coluna da matriz de adjacência A e N_v é a vizinhança do agente (nó ou vértice) v .

Para redes direcionadas temos:

- k_i^+ = grau de entrada (número de agentes de entrada, isto é, número das arestas ou relações que começam no agente v).
- k_i^- = grau de saída (número de agentes de saída, isto é, número das arestas ou relações que terminam no agente v).

$$k_i^+ = \sum_{j=1}^n a_{ij} \quad (29)$$

$$k_i^- = \sum_{j=1}^n a_{ji} \quad (30)$$

A medida do grau em redes direcionadas é também conhecida como prestígio. É uma expressão muito usada em ARS (análise de redes sociais).

Existem dois tipos de prestígio: (i) o de suporte; e (ii) o de influência. O de suporte é o grau de entrada e o de influência é o grau de saída. Em redes pesadas (ou ponderadas) a força é equivalente ao grau. Ela é igual à soma dos pesos das arestas adjacentes a um dado agente (ou das relações vinculadas a este agente). Tal como em (31):

$$k_i^w = \sum_{j=1}^n a_{ij}^w \quad (31).$$

Os graus de entrada e de saída ponderados expressam o “peso” das arestas recebidas e enviadas por cada vértice, quando somados, esses graus fornecem a medida de grau ponderado (Gama, Carvalho *et al.*, 2015).

A otimização (classe) de modularidade é outro tipo de método utilizado para detectar comunidades em redes. A modularidade Q é uma função que avalia e mede a importância de uma dada partição da rede em comunidades. Esta função é utilizada para comparar a qualidade das partições e também como uma função objetivo em problemas de otimização. Segundo Newman (2006), a modularidade é representada pela diferença normalizada entre o número de arestas observadas no interior de cada grupo de nós da rede e o número de arestas que seria provável observarem no interior desse mesmo grupo numa rede equivalente onde as arestas são geradas aleatoriamente. A modularidade Q é calculada da seguinte forma:

$$Q = \frac{1}{2m} \sum_{ij} \left[A_{ij} \frac{k_i k_j}{2m} \right] \delta(c_i, c_j) \quad (32)$$

Onde m indica o número de arestas; k_i e k_j representam respectivamente o grau dos vértices i e j ; A_{ij} é a entrada da matriz adjacência que indica o número de ligações estabelecidas entre os vértices i e j ; $2m$ representa o número esperado de arestas que deveria existir entre o par de vértices (i, j) ; c_i e c_j denotam os grupos a que os vértices i e j pertencem; e δ representa o delta de Kronecker.

A modularidade Q pode assumir valores positivos e negativos. Se $Q > 0$, então existe a possibilidade de encontrar estrutura de comunidade em rede. Se Q for um número positivo e elevado, então a respectiva partição tem maior probabilidade de refletir a estrutura de comunidade verdadeira. De acordo com Clauset *et al.* (2004), uma modularidade que assuma valores superiores ou iguais a 0,3 é um bom indicador da existência de comunidade com significado na rede.

Por fim, Force Atlas e Force Atlas 2 são métodos de elaboração de grafos e redes direcionados pela força e são delineados baseados nas semelhanças e/ou diferenças dos dados. Os padrões podem ser ajustados para dar maior ênfase na independência entre vértices individuais ou para considerar a proximidade entre eles. O algoritmo do Force Atlas possui alternativas para força de repulsão e de atração. Já o Force Atlas 2 tem como vantagem o fato dele possuir maior controle sobre o resultado. No que se referem aos resultados das duas distribuições e dos respectivos layouts, os dois métodos diferem apenas no tocante à gravidade.

1.4 Resultados

A dinâmica de conectividade em frequência foi medida com base na metodologia desenvolvida por Chatziantoniou (2021), Antonakakis *et al.* (2020), Baruník e Krehlík (2018), Koop e Korobilis (2014) e Diebold e Yilmaz (2012, 2014). Foram calculadas medidas de conectividade em curto, médio, longo e longuíssimo prazo por meio do pacote econométrico “*ConnectednessApproach*” do software estatístico livre R. Tais faixas de frequências foram escolhidas para possibilitarem um maior detalhamento do grau de integração das ações dos bancos que fazem parte desta análise. Além disso, a adequação desta metodologia para alcançar os objetivos deste trabalho é reforçada pelas próprias referências citadas dos autores desta metodologia.

1.4.1 Conectividade dinâmica média

Inicialmente, apresentamos as conectividades médias, as quais, por estarem em termos médios, ignoram os impactos dinâmicos de eventos específicos que ocorreram ao longo do período estudado. A Tabela 4 expõe os valores da conectividade média total considerando a amostra completa⁴.

Os elementos da diagonal principal da Tabela 4 referem-se a choques advindos da variação do retorno do próprio banco específico, enquanto que os elementos fora da diagonal principal representam a interação entre as volatilidades dos preços das ações bancárias em análise. Por exemplo, olhando para o elemento da diagonal principal da coluna BBAS3, observamos que 52.88% da conectividade da ação do banco do Brasil pode ser atribuída aos choques no preço da própria ação. Esse percentual de 52.88% é decomposto em 39.18% atribuído a choques de curto prazo, 6.83% a choques de médio prazo e o restante 6.87% a choques de longo e longuíssimo prazo. Já os 47.12% restante refere-se às conexões de volatilidade com todas as demais ações bancárias que compõem a rede complexa.

Observando agora o índice de conectividade total (TCI), percebemos que o valor médio de integração do mercado bancário brasileiro é de 25.74%. E que este valor se decompõe em 16,54% atribuído ao curto prazo (ver Tabela 6, no Anexo 1), 4.23% ao médio prazo (Tabela 7, também no Anexo 1) e o percentual restante de 4.97% é atribuído ao longo e longuíssimo prazos (Figura 6, na página 29). Portanto, isso implica que 25.74% da variância do erro de previsão nessa rede de bancos foram causadas pelas interações entre as volatilidades das próprias ações da rede. O valor restante de 74.26% pode ser atribuído a outros fatores capturados pelo componente idiossincrático de cada retorno das ações bancárias. Além disso, em nossa rede, é plausível supor que a conectividade média é afetada principalmente por *spillovers* de choques no curto prazo (conforme Tabelas 7 e 8, no Anexo 1).

Analisando na Tabela 4 os *spillovers* individuais de cada banco, notamos que a volatilidade do banco Bradesco (BBDC3) é, em média, a principal transmissora líquida de choques dentro da rede, com o índice de 9.65%. Em seguida, em ordem

⁴ As conectividades de curtíssimo prazo (1 a 5 dias úteis) estão dispostas na tabela 7 e as conectividades de curto prazo (entre 5 a 10 dias úteis), na tabela 8. Ambas, por razões de espaço, foram analisadas no Anexo 1 dessa tese. As tabelas de conectividades de longo (entre duas semanas e um mês) e as de longuíssimo prazo (acima de um mês) não geradas pelo pacote econométrico. Ainda assim, esses valores são apresentados na Figura 6.

decrecente, temos o Banco do Brasil (BBAS3), com 9.18%, e o Banco Itaú (ITUB3), com 5.04%.

Tabela 4. Índices das conectividades médias intra e entre ações dos bancos da B3

	BBAS3	BBDC3	BNBR 3	ITUB 3	ABCB4	SANB 3	BAZA3	BMEB3	BPAN4	PINE4	RPAD3	BMIN3	BRIV 3	BRSR3	FROM
BBAS 3	52.9	15.51	0.72	12.23	4.68	4.11	0.63	2.39	2.00	0.79	1.23	0.82	0.75	1.27	47.12
BBDC3	15.33	52.2	0.73	15.50	4.24	3.84	0.94	2.14	1.80	0.66	1.25	0.46	0.51	0.40	47.79
BNBR3	1.31	1.53	84.9	1.15	1.10	1.28	0.84	1.75	1.42	0.78	0.82	0.91	1.12	1.07	15.09
ITUB 3	12.54	16.17	0.62	54.2	5.14	3.58	0.63	1.92	2.13	0.39	1.06	0.39	0.61	0.62	45.79
ABCB4	6.47	5.78	1.01	6.11	67.8	2.58	0.80	2.20	2.12	0.76	1.89	0.82	0.97	0.76	32.25
SANB3	5.31	5.33	1.10	4.54	2.47	73.1	0.71	1.76	1.20	1.20	0.71	0.61	1.25	0.74	26.93
BAZA3	1.14	1.03	0.97	0.97	0.97	0.52	86.3	1.71	1.27	1.27	0.82	1.08	0.91	1.07	13.72
BMEB3	2.95	2.57	1.63	2.58	2.24	1.73	2.11	75.6	3.02	1.00	0.86	1.66	0.95	1.11	24.41
BPAN4	3.08	2.92	1.52	2.39	2.54	1.25	1.37	3.26	76.5	0.92	1.09	1.06	0.79	1.35	23.53
PINE4	1.18	1.02	0.71	0.59	0.94	1.51	0.82	1.00	0.99	83.2	0.62	1.83	1.60	3.95	16.76
RPAD3	2.38	2.40	1.01	2.01	2.35	1.10	1.01	1.48	1.36	0.69	81.9	0.60	0.97	0.72	18.07
BMIN3	1.06	0.93	0.70	0.75	0.64	0.52	1.06	1.38	0.83	1.36	0.56	87.1	1.59	1.50	12.89
BRIV3	1.93	1.40	0.98	1.07	1.34	2.04	1.12	1.58	0.96	1.63	0.74	1.19	82.7	1.33	17.30
BRSR3	1.63	0.86	1.18	0.96	0.93	1.04	0.85	1.01	1.55	4.86	0.66	1.96	1.18	81.3	18.68
TO	56.30	57.44	12.87	50.83	29.58	25.11	12.89	23.57	20.65	16.30	12.32	13.39	13.19	15.88	TCI
NET	9.18	9.65	-2.23	5.04	-2.67	-1.81	-0.84	-0.84	-2.88	-0.45	-5.74	0.51	-4.11	-2.80	25.74

Nota: Os resultados foram baseados em um TVP-VAR com lag de ordem um (BIC) e uma decomposição de variância de erro de previsão de 100 passos à frente.

Fonte: Cálculos do autor no RStudio.

Em relação às ações receptoras líquidas de volatilidade, a Tabela 4 evidencia que, em média, os ativos mais afetados pelas volatilidades dos outros são, em ordem decrescente: Alfa Holdings (RPAD3), com o índice de -5.74%; o banco Alfa Investimentos (BRIV3), com -4.11%, e o banco Pan (BPAN4), com -2.88%.

1.4.2 Redes complexas de conectividades dinâmicas totais

Com os dados da Tabela 4, foram estimadas as estatísticas da rede de transmissão de volatilidade no Gephi 0.9.2. Assim, nesta subseção, apresentamos as redes complexas das conectividades dinâmicas totais e as suas respectivas métricas estatísticas (graus ponderados de entrada, saída e total, além das classes de modularidade). Inicialmente, vamos analisar as classes de modularidade, utilizando para isto o algoritmo desenvolvido por Blondel, Guillaume, Lambiotte et al. (2008) e os parâmetros de resolução no software Gephi 0.9.7 elaborados por Lambiotte, Delvenne e Barahona (2009). Em seguida, analisamos os graus ponderados (de entrada, de saída e o total, que é a soma dos dois primeiros). Estes graus ajudam a compreender visual e estatisticamente os spillovers de volatilidade na rede descrita por meio do algoritmo de layout de Force Atlas 2.

Tabela 5. Estatísticas das redes complexas das conectividades dinâmicas totais

Códigos das ações	Grau ponderado de entrada	Grau ponderado de saída	Grau ponderado	Classes de modularidade	PageRanks
BBDC3	47.80	57.45	105.25	1	0.110549
BBAS3	47.13	56.31	103.44	1	0.111460
ITUB3	45.80	50.85	96.65	1	0.104998
ABCB4	32.27	29.58	61.85	1	0.083589
SANB3	26.93	25.10	52.03	1	0.071292
BMEB3	24.41	23.58	47.99	0	0.072974
BPAN4	23.54	20.65	44.19	0	0.069316
BRSR3	18.67	15.89	34.56	0	0.062303
PINE4	16.76	16.31	33.07	0	0.058385
BRIV3	17.31	13.20	30.51	0	0.055674
RPAD3	18.08	12.31	30.39	0	0.054545
BNBR3	15.08	12.88	27.96	0	0.050230
BAZA3	13.73	12.89	26.62	0	0.047934
BMIN3	12.88	13.39	26.27	0	0.046751

Fonte: Cálculos do autor no Gephi 0.9.7, com os dados da tabela 4 (exceto a diagonal principal, a última coluna e as duas últimas linhas).




Figura 2. Análise de clusters – classes de modularidade das volatilidades das ações da B3
 Fonte: Elaboração do autor no software livre Gephi 0.9.7.

Na Tabela 5, que exibe tais métricas estatísticas, podemos observar que a amostra com 14 ações de bancos se divide em dois agrupamentos (*clusters*). Eles estão denominados pelos algoritmos 0 e 1, que descrevem as respectivas classes de modularidade mencionadas. O grupo 1 reúne cinco das 14 ações da amostra: BBDC3, BBAS3, ITUB3, ABCB4 e SANB3. Estas ações são as que mais transmitem e recebem volatilidade para todas as outras e dessas outras. O grupo designado pela classe de modularidade zero, agrega as outras 9 ações, as quais transmitem e recebem menores graus de volatilidade. Na Figura 2, que descreve a divisão entre essas duas classes de modularidade, esse agrupamento principal está representado pela cor verde, sendo o segundo agrupamento com 9 ações representado pela cor bege/marrom.

Observe que o primeiro agrupamento, mesmo tendo apenas 5 ações e reunindo somente 35,71% do total de ações da amostra, agrega ações de bancos que representam 53,94% das disponibilidades, 57,18% das aplicações interfinanceiras, 42,03% das operações de crédito e 45,77% dos ativos totais do sistema bancário brasileiro. Portanto, com exceção de ABCB4, todas as ações do primeiro agrupamento representam bancos que, se adicionarmos a Caixa Econômica Federal à eles, representam 63,03% da oferta de crédito do país, conforme dados de balanço de dezembro de 2021⁵. Obviamente, tal concentração explica a significância da volatilidade mencionada.

Em relação aos três tipos de graus ponderados, a Tabela 5 e a Figura 3 mostram que as ações do agrupamento de classe de modularidade 1 (BBDC3, BBAS3, ITUB3, ABCB4 e SANB3), são também as que apresentam, em ordem decrescente, as maiores métricas de graus ponderados de entrada, saída e total (soma dos dois primeiros). Assim, essas ações são as que mais transmitem volatilidade para as outras (maiores graus de saída), as que mais recebem (maiores graus de entrada) e, somando as transmissões e recepções de volatilidade (grau ponderado total), são justamente elas as que geram maiores conectividades dinâmicas totais para a rede.

Assim, quanto maior for seu grau, mais uma ação recebe e transmite volatilidade para outras. Nesse sentido, pode-se dizer que o agrupamento principal (classe de modularidade 1) é justamente aquele que recebe e transmite mais volatilidade entre as ações que compõem. Com esses resultados, pode-se dizer que o objetivo de caracterizar a hierarquia de influência de transmissão de volatilidade entre os principais bancos que operam no Brasil, listados na B3, é alcançado. Isto é, os bancos com maior grau ponderado médio e também os que mais transmitem e recebem volatilidade são Bradesco, Banco do Brasil, Itaú/Unibanco e o Banco ABC Brasil. Por outro lado, os três bancos que menos influenciam em termos de transmissão e recebimentos são em ordem decrescente: o Banco do Nordeste (BNBR3), o Banco da Amazônia (BAZA3) e o Banco Mercantil de Investimentos (BMIN3).

⁵ Fonte: Estatísticas do Sistema Financeiro Nacional do Banco Central do Brasil (dados selecionados de instituições financeiras). Disponível em: <https://www3.bcb.gov.br/ifdata/>. Obs: a Caixa Econômica Federal, por ser uma instituição de forte cunho social e de apoio à habitação popular, não possui ações negociadas na B3.




Figura 3. Rede de graus ponderados das volatilidades das ações dos bancos da B3
 Fonte: Elaboração do autor no software livre Gephi 0.9.7.

Contudo, é importante ressaltar que o fato de um banco não ter muita influência na rede de transmissão de volatilidade não implica, de modo algum, que tal banco não seja importante ou que tenha atuação pouco expressiva no mercado financeiro. Exemplos deste é o Banco Pan (BPAN4), o qual figura na vigésima posição do ranking de maiores bancos por ativo total em 2020, do Anuário “Melhores e Maiores” da Revista Exame. E ainda temos como exemplos nesse ranking o Banco Alfa Holdings (RPAD3), que ocupa a 35ª posição; o Banco Mercantil do Brasil (BMEB3), que é o 48º

do ranking. Ressaltamos que esse ranking de maiores ativos totais possui 121 instituições financeiras bancárias.

Cabe agora mencionar por que a ação ABCB4 faz parte de um agrupamento principal tão seletivo, em termos de instituições financeiras com grande escala e participação de mercado. O Banco ABC Brasil S.A. é somente a 31ª instituição financeira do sistema financeiro nacional, pelo critério dos ativos totais. O ABC Brasil, antigo Banco ABC Roma, é um banco múltiplo, especializado na concessão de crédito e serviços para empresas de médio e grande porte. Opera com carteiras comerciais, de investimentos, financeira, crédito imobiliário e câmbio. Controlado pelo Arab Banking Corporation, conta ainda com uma agência nas Ilhas Cayman. Embora seja um banco múltiplo, ele especializou-se em operações que envolvam análise e assunção de riscos de crédito. Também atua com operações estruturadas, principalmente de mercado de capitais e objetivando o financiamento corporativo. Portanto, quando o mercado de crédito controlado pelos outros quatro bancos é afetado por fatores que aumentam a incerteza, as operações do ABC Brasil são rapidamente afetadas pela transmissão de volatilidade das ações dos outros bancos desse cluster que podemos chamar de agrupamento principal. A análise da persistência dos efeitos dessas transmissões ao longo do tempo é descrita nas tabelas do Anexo A deste trabalho, por razões de aproveitamento do espaço do texto.

1.4.3 Conectividades dinâmicas totais

Considerando a Figura 4, que retrata a evolução da conectividade dinâmica total (TCI), visualizamos pela cor preta a evolução geral (TCI), a qual é decomposta em: (i) curto prazo (até uma semana), período descrito pela cor rosa; (ii) médio prazo (entre uma e duas semanas), período descrito pela cor verde; (iii) longo prazo (entre duas semanas e um mês), representado pela cor azul escuro; e (iv) longuíssimo prazo (acima de um mês), descrito pela cor azul marinho. Quando houver uma expansão da conectividade, teremos maiores níveis de transmissão de volatilidade e, ao fim e ao cabo, maiores riscos de contágio entre as ações da rede complexa. Também significa que os preços das ações oscilaram mais e de forma conjunta.




Figura 4. Conectividade dinâmica total e no curto, médio, longo e longuíssimo prazo.

Fonte: Elaboração do autor no RStudio.

A dinâmica geral do TCI variou, no período considerado, em um intervalo de 20% a mais de 50%. O maior pico coincidiu justamente no início do ano de 2020, durante o início da pandemia de COVID 19. Ressaltamos também que a conectividade manteve-se elevada durante todo o período de pandemia, resultado que corrobora os estudos já citados que analisaram o impacto da pandemia sobre a transmissão de volatilidade dos mercados acionários: Azimli (2020), Al-Awadhi, Alsaifi et al. (2020) e Cheng et al. (2022), sobretudo os dois últimos trabalhos.

No entanto, houve também um pico de menor magnitude entre os anos de 2014 e 2016. Nesse período, tivemos os últimos anos do período de Dilma Rousseff (2011-2016), nos quais ocorreu uma das mais resistentes recessões da história econômica brasileira (alta da inflação, dos juros, do câmbio e disparada do desemprego). Tal crise, agravada pela ação da Lava Jato no escândalo de corrupção do chamado “Petrolão”, culminou em 31 de agosto de 2016 com um processo de impeachment.

Após o impeachment, já no governo Temer (meados de 2016 até final de 2018) foi aprovada a reforma trabalhista e o teto dos gastos, mas no dia 17 de maio de 2017 - com a divulgação de gravações envolvendo conversas entre o empresário Joesley Batista (que tentava reduzir sua pena com uma delação premiada) e o presidente Michel Temer - a B3 sofreu forte impacto, com queda de -8,8% em um dia. Foi a maior queda desde outubro de 2008, um dos piores dias do período da crise financeira global.

Após tal evento crítico, notamos uma rápida queda das transmissões de volatilidade e um repique das mesmas às vésperas da eleição presidencial de 2018, na qual foi eleito o atual presidente da República do Brasil, Jair Bolsonaro.

Examinamos também a evolução dinâmica em frequência. Isto nos ajudou a descobrir qual a faixa de frequência foi predominante nos *spillovers* de volatilidade entre e intra ações dos bancos brasileiros. Assim, de acordo com a Figura 6, nosso mercado de ações bancárias exibiu uma forte conectividade de curto prazo. Examinando ainda essa conectividade de curto prazo, descobrimos que os ecos de choques passados (aqueles que ocorreram dentro de uma janela temporal de 6 a 100 dias atrás) não foram intensos o suficiente para superar a influência das transmissões de volatilidade associadas aos acontecimentos atuais. Além disso, essa predominância da conectividade de curto prazo permite supor que o único evento que pode ser chamado de quebra estrutural foi justamente a pandemia de COVID 19. Apenas ela foi capaz de gerar uma predominância da conectividade de longo ou longuíssimo prazo. A pandemia foi o único evento que levou a conectividade de médio, longo e longuíssimo prazo a subir para quase 10%. Trata-se de uma evidência que mostra que a crise sanitária ainda não teve seus efeitos completamente absorvidos pelas decisões dos acionistas dos bancos que atuam na B3.

Para explorar ainda mais a amostra, identificamos quais ações bancárias impulsionaram, de forma mais significativa, as transmissões dos choques dentro da rede. Para isto, avaliamos cada nível de frequência com base na análise da dinâmica de conectividade líquida. Ela nos ajudou a distinguir as ações transmissoras de choques das receptoras em cada faixa de frequência.

1.4.4 Conexão dinâmica direcional total líquida

A Figura 5 ilustra a evolução da conectividade direcional total líquida tanto em termos gerais (cor preta) como dentro das faixas de frequência de curto prazo (cor rosa), médio prazo (cor verde), longo prazo (cor azul escuro) e longuíssimo prazo (cor azul claro). Neste tipo de ilustração o banco que tiver a área sombreada na parte positiva do gráfico é considerado transmissor líquido de choques de preços. Diferentemente, o banco que tiver a área sombreada na parte negativa é considerado um receptor líquido de choques. Além disso, qualquer banco pode ser considerado, ao longo do tempo, tanto um transmissor líquido como um receptor líquido.




Figura 5. Conectividades dinâmicas direcionais líquidas no curto, médio, longo e longuíssimo prazo.
Fonte: Elaboração do autor no RStudio.

Assim, observando a Figura 5 e considerando inicialmente o “BBAS3”, percebemos que o banco do Brasil é predominantemente um transmissor líquido persistente de choques de volatilidade de preços na rede de bancos do mercado acionário brasileiro. Este papel de transmissor tem força principalmente no curto prazo, revelando a capacidade do banco de processar as informações relevantes de forma rápida. Além disso, percebemos que houve um aumento do nível de transmissão a partir do ano de 2016, quando ocorreu a destituição da presidente Dilma Rousseff, até o período da pandemia de COVID reduzindo somente no início de 2022. Complementarmente, durante o período de meados de 2013 até o final de 2015, o “BBAS3” assumiu também o papel de receptor líquido de choques em longo prazo. Isto reflete o papel da turbulência política deste período, a qual foi iniciada com as manifestações populares de 2013, que deixaram os participantes do mercado inseguros quanto à estabilidade política e institucional do país.

Em relação ao “BBDC3”, o papel assumido é de completo transmissor líquido de choques preços com picos de transmissão em vários momentos e com o maior nível durante o período da pandemia de COVID. A força da transmissão se dá

predominantemente no curto prazo. No entanto, durante o período da pandemia, o gráfico revela que há um aumento dos choques de longo prazo, isto é, o banco Bradesco ainda não conseguiu processar adequadamente as consequências da pandemia para o mercado bancário e, portanto, apresentou um medo maior durante este período.

O banco do Nordeste do Brasil, “BNBR3”, apresentou uma evolução direcional líquida variada, revelando-se como um fraco transmissor líquido de choques em longuíssimo prazo e um receptor moderado de choques no curto prazo, principalmente durante a pandemia de COVID.

Já o banco Itaú, “ITUB3”, teve um papel semelhante ao do “BBAS3” e do “BBDC3”, isto é, de transmissor líquido persistente de choques de volatilidade de preços predominantemente no curto prazo. No entanto, os resultados revelam que a pandemia de COVID teve um impacto menor quando comparado aos impactos da pandemia no “BBAS3” e no “BBDC3”. Além disso, o Itaú foi um receptor líquido de choques entre os anos de 2009 e 2010, período que a nível global pode ter ecos da grande crise financeira global do *subprime* de 2007 e 2008, além de que a nível nacional foi o período da eleição presidencial de 2010. Por fim, é importante ressaltarmos que os bancos “BBAS3”, “BBDC3” e “ITUB3” são os bancos comerciais mais populares e tradicionais do Brasil.

Observando a evolução direcional líquida do banco ABC Mercantil, “ABCB4”, tal banco teve um papel de receptor líquido de choques durante quase todo o período do estudo, mostrando-se um transmissor líquido apenas no início da pandemia de COVID, porém voltando rapidamente para a condição de receptor. A força de sua conexão se dá predominantemente no curto prazo. Este é o primeiro banco que revela um comportamento completamente diferente dos anteriores analisados.

A evolução do banco Santander, “SANB3”, mostrou que tal banco teve um papel de receptor líquido na maior parte do período analisado, apresentando o perfil de transmissor líquido, com predominância no curto prazo, durante o ano de 2013 e também durante o período de pandemia, porém na pandemia prevaleceu a transmissão de longuíssimo prazo. É importante ressaltar que apesar do “SANB3” ser um dos bancos mais conhecidos do Brasil, seu perfil de conectividade direcional líquida difere substancialmente dos bancos “BBAS3”, “BBDC3” e “ITUB3”, principalmente em magnitude.

Considerando a evolução de conectividade direcional líquida do banco da Amazônia, “BAZA3”, podemos perceber dois movimentos interessantes. Primeiro, entre o ano de 2013 até o início do ano de 2014 o “BAZA3” teve um papel de transmissor líquido de choques predominantemente de longuíssimo prazo. Segundo, os dois primeiros anos do segundo mandato da presidente Dilma Roussef foram os períodos de maior força receptiva de choques por parte do “BAZA3”, isto é, foram os anos em que o banco mais recebeu choques líquidos do mercado. Adicionalmente, o “BAZA3” foi um recepto líquido de choques durante o período de pandemia de COVID-19, principalmente no curto prazo. Porém, a magnitude dessa conexão no período pandêmico foi baixa se comparado aos efeitos nos bancos mais populares. O banco da Amazônia é uma sociedade anônima de economia mista, em que o acionista majoritário é o governo federal brasileiro, talvez isso explique o porquê dos eventos políticos afetarem mais fortemente a sua dinâmica de volatilidade de preços. Além disso, o “BAZA3” tem agências em toda a região norte do país, uma no Estado de São Paulo e outra em Brasília, isto é, não abrange todo o território nacional.

O banco Mercantil do Brasil, “BMEB3”, apresenta um perfil evolutivo variado com predominância do perfil receptor no curto prazo. O “BMEB3” teve um rápido papel de transmissor durante o ano de 2013. Também teve um pico receptivo durante o ano de 2016. Por fim, a pandemia de COVID-19 não teve um impacto relevante nas expectativas dos investidores deste banco. Pelo perfil de conectividade apresentado, este banco confirmar a viabilidade de diversificação de investimentos no mercado bancário nacional.

O banco PAN, “BPAN4”, durante o ano de 2009 até 2011 teve um perfil de transmissor líquido principalmente no curto prazo, com pico em 2010. Outro pico aconteceu em 2013, porém receptivo com predominância de choques no longuíssimo prazo. A partir do ano de 2015 o perfil de conectividade líquida do “BPAN4” foi predominantemente de receptor líquido com o maior pico ocorrendo durante a pandemia de COVID-19, especificamente no curto prazo. Este perfil de transmissão líquida é completamente diferente dos perfis dos bancos mais populares do Brasil.

O banco PINE, “PINE4”, também teve um perfil evolutivo de transmissão líquida variante ao longo do tempo. Os picos de transmissor líquido ocorreram entre os anos de 2009 e 2010, entre meados de 2015 até meados de 2016 e entre 2019 até o primeiro bimestre de 2020. Já os picos receptivos entre meados de 2014 até meados de 2015 e, em magnitude menor, durante o período de pandemia de COVID-19.

A Holding financeira Alfa, “RPAD3”, teve um perfil de receptivo líquido de choques em todo o período, com o maior pico acontecendo durante o período pandêmico, entre 2020 até o início de 2022, com predominância dos choques em longuíssimo prazo. O segundo maior pico receptivo do “RPAD3” foi durante meados de 2017 até a metade do ano de 2018, período este que marca a véspera das eleições presidenciais de 2018.

Em relação à evolução de transmissão líquida do Banco Mercantil de Investimentos, “BMIN3”, houve três momentos de picos receptivos: o ano de 2009 até o ano de 2011, o ano de 2014 até o início de 2015 e finalmente, o ano de 2020 até o ano de 2022. Essa recepção líquida de choques se deu no curto prazo. Diferentemente, durante o período que vai de meados de 2015 até o final de 2017, o “BMIN3” foi um transmissor líquido de choque de volatilidade de preços com predominância de transmissão no longuíssimo prazo. Este é mais um perfil que revela a possibilidade de diversificação de investimentos em ações de bancos no Brasil.

O banco Alfa de Investimentos, “BRIV3”, teve uma conectividade de choques líquida mais parecida com a trajetória de alguns dos bancos já analisados. O período da pandemia de COVID foi o que mais afetou conectividade direcional líquida do “BRIV3”, tanto em termos de curto prazo quanto em termos de longuíssimo prazo. Isto talvez seja porque as consequências da pandemia para o mercado bancário não foram totalmente captadas, portanto, tais consequências demandam tempo para serem totalmente compreendidas. O período de meados de 2013 até meados de 2014, também foi um período de recebimento de volatilidade por parte do “BRIV3”.

Por fim, o banco Banrisul, “BRSR3”, na maior parte do período de estudo desempenhou um papel de receptor líquido de choques com predominância do curto prazo. Vários foram os picos receptivos, o mais persistente ocorreu durante o ano de 2020, isto é, no período pandêmico. No entanto, a partir do ano de 2021 há uma mudança para o perfil de transmissor, porém em uma magnitude menor. É interessante também observar que entre o ano de 2014 até o ano de 2015, o “BRSR3” foi um transmissor líquido com predominância de longuíssimo prazo. Isto claramente evidencia o efeito da turbulência política vigente naquele período.

No Quadro 1 foi resumida a análise dos gráficos da Figura 5, destacando os motivos que levaram cada ação dos bancos a receberem ou transmitirem, ao longo do tempo, as volatilidades, destacando as conexões de curto, médio, longo e longuíssimo prazo.

A análise do Quadro 1 não dá conta de todas as outras considerações que poderiam ser feitas se fossem analisados mais profundamente os balanços de cada banco. Porém, tal análise transcende o escopo desse trabalho, mas deixamos como sugestão para trabalhos futuros, sobretudo relacionados à dinâmica de competição e regulação bancárias, o estudo dos fatores que afetaram os desempenhos dos bancos desta amostra.

Ações	Transmissão de volatilidade	Motivos	Recepção de volatilidade	Motivos
BBAS3 (Banco do Brasil ON)	Intensa no curto prazo (sobretudo a partir de 2016). Fraca no médio prazo. Razoável no longo e longuíssimo prazos após 2020.	Manifestações políticas de 2013, intervenções e erros de gestão no governo Dilma Rousseff	Intensa no curto prazo. Há um “vale” de 2013 até o final de 2015.	Manifestações políticas de 2013, intervenções e erros de gestão no governo Dilma Rousseff
BBDC3 (Bradesco ON)	Intensa no curto prazo. Razoável no médio prazo. Aumenta em todos os prazos a partir de 2020.	A pandemia explica o aumento dos efeitos de longo prazo. Os picos de curto prazo referem-se às crises políticas e econômico-financeiras.	Fraca receptora de choques de volatilidade.	Trata-se de uma ação muito resiliente de um dos bancos com maior grau de solidez e solvência do mundo (pelos critérios do Acordo de Basileia).
BNBR3 (Banco do NE do Brasil ON)	Fraca (curto, médio e longo prazos). Razoável no longuíssimo prazo.	É um banco regional de desenvolvimento. Suas oscilações respondem às políticas de desenvolvimento sobretudo do Estado do Ceará.	Razoável e passa a ser intensa durante a pandemia de Covid-19.	Têm suas operações fortemente atreladas à indústria e ao comércio, setores muito afetados no período da crise sanitária.
ITUB3 (Itaú-Unibanco ON)	Picos intensos de curto prazo. Fraca no médio prazo. Fraca no longo e longuíssimo prazos.	Menos afetada pela pandemia do que BBDC3 e BBAS3.	Três picos breves de recepção: 2010, 2013, 2014 e 2022.	Crise da dívida da Zona do Euro (2010); Redução dos juros do Banco do Brasil (2013 e 2014) e elevação da inadimplência (2022)
SANB3 (Santander ON)	Picos em 2013 e em 2022. Concentrados no curto prazo.	Tal como ITUB3, foi menos afetada pela pandemia do que BBDC3 e BBAS3. Os picos devem-se ao choque da queda dos juros praticados pelo Banco Brasil (por ordem da presidente Dilma	Intensa no curto prazo em quase todos os períodos (à exceção dos picos relatados, em que foi transmissora de volatilidade).	A necessidade de competir com os outros três grandes bancos faz com que a estratégia de expansão do Santander seja mais agressiva. Por isso, suas ações são mais permeáveis às oscilações das outras.

		Rousseff).		
ABCB4 (ABC Brasil PN)	Muito fraca em todos os prazos (curto, médio, longo e longuíssimo). Menos em 2020 (pico de transmissão)	É um banco de investimentos controlado por capitais da Líbia e do Kuwait. Foi afetado por pouco tempo pela pandemia, mas o impacto foi forte.	Forte no curto e no médio prazos a partir de 2013.	Capital concentrado no crédito a empresas de médio e grande porte. Antes de 2013, a economia brasileira crescia e a carteira de investimentos desse banco refletia isso. Após este ano, a ação passou a receber mais volatilidade.
BAZA3 (Banco da Amazônia ON)	Picos concentrados em julho de 2013 e em agosto de 2016. Fraca nos demais períodos.	Manifestações políticas de julho de 2013. Gravações de Joesley Batista envolvendo o presidente Michel Temer (agosto de 2016)	Fraca até 2013. Forte (no longo prazo) de 2014 até meados de 2016 (antes do mês de agosto). Forte no curto prazo de 2018 em diante.	É um banco de desenvolvimento controlado pelo governo federal. Foi pouco afetado pela pandemia e respondeu mais às oscilações do PIB e às crises políticas.
RPAD3 (Alfa Holdings ON)	Fraca em todos os períodos e prazos.	Banco de investimento com gestão conservadora e carteira diversificada. Atua com crédito a pessoas físicas e jurídicas. A série histórica de volatilidade de suas ações é baixa.	Fraca até 2013. Picos em julho de 2013, outubro de 2015, período eleitoral de 2018 e em março de 2020 (pandemia).	Efeitos de curto prazo: Julho de 2013 (manifestações políticas contrárias ao PT); outubro de 2015 (aceitação do processo de impeachment da presidente Dilma Rousseff); período eleitoral (atentado ao então candidato Jair Bolsonaro). Efeito em 2020: pandemia.
PINE4 (Banco Pine PN)	Picos intensos de transmissão de volatilidade de curto prazo em julho de 2013, 2015-2016. No início da pandemia registrou pico de volatilidade de longuíssimo prazo e de curto prazo.	Banco voltado para o <i>corporate finance</i> . Atuação muito diversificada (energia, construção civil, metalurgia, energia, agronegócio etc.). Foi afetado pela forte recessão de 2015-2016 e pelas crises políticas já citadas.	Ações com histórico de volatilidade alta, de curto prazo, desde 2017.	A pandemia fez as ações do banco receber muita volatilidade de curto prazo, em 2020, e de longuíssimo prazo, em 2021 e 2022.
BRIV3 (Banco Alfa de Investimentos)	Fraca em quase todos os períodos e prazos. Exceto o pico (volatilidade de	Banco de investimentos do grupo Alfa. Atua também com	Um enorme e crescente “vale” de 2018 a 2021, com pequena	No terceiro trimestre de 2018 o banco registrou lucro líquido de R\$

	longuíssimo prazo) de outubro de 2015.	repasse de linhas de crédito do BNDES. Com a aceitação do impeachment da presidente Dilma pelo Congresso (out/2015), as operações do banco geraram volatilidade, pois aumentou a probabilidade de o BNDES ser cobrado para devolver recursos à União.	recuperação em 2022.	7,401 milhões, com queda de 45,1% ante o mesmo período de 2017. Depois disso, suas operações ativas de longo prazo e sua lucratividade foi afetada, o que fez com que suas ações oscilassem muito, apesar da valorização de 67,4% em 2019. Mas no triênio 2020-2021-2022, as oscilações foram de 3,83%, -17,87% e -26,30%, respectivamente.
BPAN4 (Banco Pan PN)	Fortes picos em 2009-2010 (curto, médio e longuíssimo prazos); em 2014 (curto e longuíssimo prazos) e no último trimestre de 2019 (curto e longuíssimo prazos).	Alta da inadimplência de 2009-2010. Queda nas disponibilidades, forte aumento no passivo exigível de longo prazo e em algumas modalidades de concessão de crédito no 4º trim/2019.	Muitos “vales”: de 2011 a meados de 2014; de 2015 a meados de 2018 e o maior deles em 2020.	2011 a meados de 2014: período de prejuízos e lucros trimestrais baixos. 2015 a meados de 2018: idem, porém com fraca recuperação em relação ao período mencionado. Em 2020: efeito da pandemia.
BMEB3 (Banco Mercantil do Brasil ON)	Picos intensos em 2009-2010; 2013-2014 e maio de 2017.	O banco foi afetado pela elevação da inadimplência de 2009-2010. Prejuízos trimestrais no período 2013-2014. Delação de Joesley Batista envolvendo o presidente Michel Temer, em maio de 2017.	Muitas recepções. Mas destacamos 3 “vales” importantes: 2012; um grande no final de 2015 e 2016 e outro menor em 2020. Todos eles foram de curto e longuíssimo prazos.	Lucros trimestrais baixos em 2012. Queda abrupta nos lucros do último trimestre de 2015 e 2016 com lucros trimestrais muito abaixo das médias dos demonstrativos anteriores. Em 2020, pandemia.
BRSR3 (Banrisul ON)	Um único grande pico referente ao ano de 2014. Transmissão de volatilidade concentrada no longuíssimo prazo.	Este pico foi devido à queda de 62% do lucro do Banrisul no 1º trim/2014 em comparação com o 1º trim/2013. , em razão dos pagamentos do plano de aposentadoria	Muitos “vales”. A maioria concentrados no período 2015-2020 (curto e longuíssimo prazos);	O Banrisul sofreu forte volatilidade no período mencionado em razão da grave crise de contas públicas do Estado do RS. É um banco estadual e que também foi afetado pela pandemia.

		incentivada e das mudanças no plano de previdência da Fundação Banrisul de Seguridade Social (FBSS). As despesas, com isto, aumentaram em R\$ 98,1 milhões.		
BMIN3 (Banco Mercantil de Investimentos ON)	Fortes picos do segundo semestre de 2013 até 2017. Concentração de volatilidade de longo prazo transmitida nesse período.	O Banco registrou prejuízo de R\$ 80 milhões no 3º trim/2013. Depois disso, só no 2º trim/2016, quando registrou um lucro de R\$ 3,8 bilhões, o banco superou o patamar de lucro do 2º trim/2012, quando alcançou R\$ 2,07 bilhões. Portanto, os picos referem-se a um período longo de lucros abaixo do normal.	“Vales” de recepção de volatilidade em em 2009-2010; 2014 e 2018-2021. Todos concentrados no curto prazo.	Operações de curto prazo afetadas pela inadimplência em 2009-2010. Em 2014 o banco registrou lucros trimestrais abaixo dos níveis de 2011-2012.

Quadro 1 – Fatores que afetaram as conectividades dinâmicas direcionais líquidas

Fontes: estimativas do autor no RStudio, Informações e dados do Fundamentus⁶, relatório de balanços dos bancos analisados, Yahoo Finanças⁷ e Valor Econômico⁸ (várias edições).

1.5 Considerações finais

Este artigo utilizou duas metodologias para analisar dois objetivos gerais: avaliar a extensão da integração do mercado de ações bancárias no Brasil e identificar o potencial de risco de contágio dentro desta rede de ações bancárias. A primeira metodologia utilizada foi a de conectividade dinâmica no domínio da frequência baseada em um modelo TVP-VAR desenvolvida por Chatziantoniou et al. (2021), combinando os trabalhos de Antonakakis *et al.* (2020) e de Baruník e Krehlík (2018). A segunda foi utilizada para descrever as redes complexas dessas transmissões (*spillovers*) de volatilidade e estimar suas métricas estatísticas (*network science*). Aquela primeira metodologia de conectividade baseia-se numa abordagem de vetores

⁶ <https://www.fundamentus.com.br/>

⁷ <https://br.financas.yahoo.com/>

⁸ <https://valor.globo.com>

autoregressivos de parâmetros variáveis no tempo e possui algumas vantagens em relação às outras abordagens alternativas tais como: robustez a valores discrepantes dos dados, independência da escolha arbitrária do tamanho da janela móvel de estimativas e não perda de observações.

A análise despertou outras questões que foram respondidas no trabalho: o quão conectado está o mercado de ações de bancos no Brasil? Há possibilidades de diversificação em uma carteira composta somente de ações desses bancos? Quais são os bancos que possuem o maior potencial de transmissão de choques de preços para o restante da rede de bancos que operam no Brasil? Em qual frequência a conectividade de transmissão é mais forte? As ações dos bancos brasileiros são conhecidas por sua alta resiliência à choques econômicos, financeiros, políticos etc., mas, ainda assim, a pandemia de COVID-19 afetou em que medida as ações dos bancos brasileiros? As ações desses bancos respondem de forma homogênea aos mesmos eventos políticos e econômicos?

As conclusões indicam uma dinâmica de integração evolutiva influenciada por eventos políticos, sociais e econômicos, principalmente pela pandemia de COVID-19. Esta dinâmica geral variou em magnitude de 20% a mais de 50%. O maior pico coincidiu com o início do ano de 2020. As conexões (transmissões e recepções) concentraram-se mais no curto prazo, ainda que tenham ocorrido, em algumas ações bancárias, fortes transmissões de longuíssimos prazos, sobretudo após 2020, durante a pandemia de Covid-19. Quando as conexões de curto prazo predominam, isso revela que as informações relevantes dos cenários econômicos estão foram processadas de forma rápida pelos bancos no Brasil.

Em relação à conectividade líquida direcional, os maiores transmissores líquidos de choques foram o Banco do Brasil (BBAS3), o Bradesco (BBDC3) e o Itaú-Unibanco (ITUB3) com predominância de transmissões no curto prazo. Todos os outros bancos na análise foram transmissores líquidos em algum momento, porém sem consistência ao longo do tempo. Já os maiores receptores líquidos de choques foram o Banco Pan (BPAN4), o Santander (SANB3) e a holding financeira Alfa Holding (RPAD3).

Os ativos analisados não responderam de forma homogênea aos choques, embora quase todos tenham sido afetados pela pandemia da Covid-19. Alguns apresentaram recuperação rápida, outros não. Em geral, os bancos que já possuíam boa liquidez, estavam poucos alavancados e apresentaram lucratividade alta, reagiram

mais rapidamente. Felizmente, a maioria reagiu bem, o que revela a solidez de nosso setor bancário.

O comportamento dinâmico da conectividade líquida revela que há possibilidade para a diversificação de risco em uma carteira hipotética só com ações de bancos. Isso ocorre porque há diferentes padrões de respostas aos mesmos eventos.

Este trabalho busca preencher uma lacuna na literatura de econometria financeira em língua portuguesa, dado que não há nenhuma análise similar envolvendo ações bancárias brasileiras com o uso desta metodologia.

Além disso, sugerimos mais pesquisas, envolvendo outros setores do mercado acionário brasileiro, com o foco na captura do nível de integração entre a volatilidade de suas ações, visto que tais estudos contribuirão para melhores decisões de investimento de seus participantes e para a maior eficiência das transações envolvendo ativos de renda variável.

Finalmente, esperamos que os resultados dessa tese possam ser úteis para formuladores da regulação financeira, investidores em ações de bancos, para gestores de fundos de investimento, consultores de investimento, analistas do setor bancário e pesquisadores em Economia Monetária e Finanças.

Referências

- Ahmad, W., Kutun, Ali M., Chahal, R.J.K. and Kattumuri, R. (2021). "COVID-19 Pandemic and firm-level dynamics in the USA, UK, Europe, and Japan". **Review of Financial Analysis**, 78(101888). <https://doi.org/10.1016/j.irfa.2021.101888>.
- Al-Wadhi, A. M., Asaifi, K., Al-Wadhi, A. et al. (2020). "Death and contagious infectious diseases: Impact of the COVID-19 virus on stock market returns". **Journal of Behavioral and Experimental Finance**, 27(100326), 1-5. <https://doi.org/10.1016/j.jbef.2020.100326>
- Alizadeh, S.; Brandt, M. and Diebold, F. (2002). "Range-based estimation of stochastic volatility models". **Journal of Finance**, 57(3), 1047-1091. <https://doi.org/10.1111/1540-6261.00454>
- Anscombe, F. J. and Glynn, W. J. 1983. "Distribution of the Kurtosis Statistic B2 for Normal Samples". **Biometrika** 70, 227-34. <https://doi.org/10.2307/2335960>
- Antonakakis, N., Chatziantoniou, I. and Gabauer, D. (2020). "Refined measures of dynamic connectedness based on time-varying parameter vector autoregressions". **Journal of Risk and Financial Management**. 1-23. <https://doi.org/10.3390/jrfm13040084>

Barabási, A. L. (2014). *Linked: How Everything Is Connected to Everything Else and What It Means for Business, Science, and Everyday Life*. New York: Basic Books, 2014.

Baruník, J. and Krehlík, T. (2018). “Measuring the frequency dynamics of financial connectedness and systemic risk”. **Journal of Financial Econometrics**, 16(2), 271-296.

<https://doi.org/10.1093/jfinec/nby001>

Bash, A. and Alsaif, K. (2019). “Fear from uncertainty: an event study of Khashoggi and stock market returns”. **Journal of Behavior and Experimental Finance**. 23, 54-58.

<https://doi.org/10.1016/j.jbef.2019.05.004>

Blondel, V. D.; Guillaume, J. L.; Lambiotte, R. et al. (2008). “Fast unfolding of communities in large networks”. **Journal of Statistical Mechanics: Theory and Experiment**, (10), P1000.

Caldeira, J. F., Moura, G. V. e Santos, A. A. P. (2015) Previsões macroeconômicas baseadas em modelos TVP-VAR: Evidências Para o Brasil. **Revista Brasileira de Economia**, 69 (4) • Oct-December. <https://doi.org/10.5935/0034-7140.20150019>

Chatziantoniou, I., Gabauer, D., Gupta, R. (2021). “Integration and risk transmission in the market for crude oil: A time-varying parameter frequency connectedness approach”. **University of Pretoria. Working Paper 47**.

https://www.up.ac.za/media/shared/61/WP/wp_2021_47.zp209709.pdf

Cheng, T., Liu, J., Yao, W. et al. (2022). “The impact of COVID-19 pandemic on the volatility connectedness network of global stock market”. **Pacific-Basin Finance Journal**, 71(101678), 1-22. <https://doi.org/10.1016/j.pacfin.2021.101678>

D’Agostino, R. B. (1970). “Transformation to Normality of the null distribution of g_1 ”. **Biometrika**, 57(3), 679-681.

<https://doi.org/10.1093/biomet/57.3.679>

Dangol, J. (2008). “Unanticipated political events and stock returns: an event study”. **Economic Review**, 20, 86-110.

https://www.nrb.org.np/contents/uploads/2021/09/vol20_art7.pdf

De Souza, S.R.S, Tabak, B.M, Silva, T.C., Guerra, S.M. 2015. Insolvency and contagion in the Brazilian interbank market. **Physica A**, 431, 140-151.

<http://dx.doi.org/10.1016/j.physa.2015.03.005>

De Souza, S.R.S. 2016. Capital requirements, liquidity and financial stability: The case of Brazil. **Journal of Financial Stability**, 25, 179-192.

<https://doi.org/10.1016/j.jfs.2015.10.001>

Demirer, M., Diebold, F. X., Liu, L. and Yilmaz, K. (2018). “Estimating global bank network connectedness”. **Journal of Applied Econometrics**. 33(1), 1-15.

<https://doi.org/10.1002/jae.2585>

- Diebold, F. X and Yilmaz, K. (2009). "Measuring financial asset return and volatility spillovers with application to global equity markets". **The Economic Journal**, 119, 158-171.
<https://doi.org/10.1111/j.1468-0297.2008.02208.x>
- Diebold, F. X and Yilmaz, K. (2012). "Better to give than to receive: Predictive directional measurement of volatility spillovers". **International Journal of Forecasting**, 28(1), 57-66. <https://doi.org/10.1016/j.ijforecast.2011.02.006>
- Diebold, F. Z and Yilmaz, K. (2014). "On the network topology of variance decompositions: Measuring the connectedness of financial firms". **Journal of Econometrics**, 182(1), 119-134. <https://doi.org/10.1016/j.jeconom.2014.04.012>
- Diebold, F. X. and Yilmaz, K. (2016). "Trans-atlantic equity volatility connectedness: U.S. and European Financial Institutions, 2004-2014". **Journal of Financial Econometrics**. 14(1), 81-127.
<https://doi.org/10.1093/jfinec/nbv021>
- Elliott, G., Rothenberg, T. J. and Stock, J. H. (1996). "Efficient test for an autoregressive unit root". **Econometrica**, 64(4), 813-836.
<https://doi.org/10.2307/2171846>
- Engelhardt, N., Krause, M., Neukirchen, D. et al. (2021). "Trust and stock market volatility during the COVID-19 crisis". **Finance Research Letters**, 38(101873).
<https://doi.org/10.1016/j.frl.2020.101873>
- Ferguson, N. (2009). **The ascent of money: a financial history of the world**. New York: Penguin Books.
- Fisher, Thomas J., Gallagher, Colin M. 2012. New weighted portmanteau statistics for time series goodness of fit testing. **Journal of the American Statistical Association**, 107(498), 777-787.
<https://doi.org/10.1080/01621459.2012.688465>
- Garman, M.B. and Klass, M.J. (1980). "On the estimation of security price volatilities from historical data". **Journal of Financial Economics**, 119, 457-471.
<https://www.jstor.org/stable/2352358>
- He, Y., Nielsson, U. and Wang, Y. (2017). "Hurting without hitting: the economic cost of political tension". **Journal of International Financial Markets, Institutions & Money**, 51, 106-124. <https://doi.org/10.1016/j.intfin.2017.08.011>
- Hernandez, J.A., Kang, S.H., Shahzad, S. 2020. Spillovers and diversification potencial of bank equity from developed and emerging America. *North America Journal of Economics and Finance*, 54(101219). <https://doi.org/10.1016/j.najef.2020.101219>
- Izzeldin, M., Muradoglu, Y. G., Pappas, V. et al. (2021). "The Impact the COVID-19 on G7 stock market volatility: Evidence from a ST-HAR model". **International Review of Financial analysis**, 74(101671). <https://doi.org/10.1016/j.irfa.2021.101671>

- Jarque, C. M. and Bera, A. K. (1980). "Efficient test for normality, homocedasticity and serial independence of regression residuals", **Economics Letters**, 6(3), 255-259.
[https://doi.org/10.1016/0165-1765\(80\)90024-5](https://doi.org/10.1016/0165-1765(80)90024-5)
- Kendall, M. G. (1938). "A new measure of rank correlation". **Biometrika**. 30 (1-2): 81-93. <https://doi.org/10.1093/biomet/30.1-2.81>
- Kindleberger, C. P. and Aliber, R. Z. (2015). **Manias, panic and crashes: a history of financial crises**. 7th ed. London: Palgrave McMillan.
- Koop, G; Pesaran, M. H and Potter, S. M. (1996). "Impulse response analysis in nonlinear multivariate models". **Journal of Econometrics**, 74, 119 – 147.
[https://doi.org/10.1016/0304-4076\(95\)01753-4](https://doi.org/10.1016/0304-4076(95)01753-4)
- Koop, G. and Korobilis, D. (2014). "A new index of financial conditions". **European Economic Review**, 72, 101-116.
<https://doi.org/10.1016/j.euroecorev.2014.07.002>
- Krugman, P., editor. (2000). **Currency crises**. Chicago: University Chicago Press.
- Lambiotte, R.; Delvenne, J. C. and Barahona, M. (2009). Laplacian Dynamics and Multiscale Modular Structure in Networks. <https://arxiv.org/pdf/0812.1770.pdf>
- Pesaran, M. H and Shin, Y. (1998). "Generalized impulse response analysis in linear multivariate models". **Economic Letters**, 58(1), 17-29.
[https://doi.org/10.1016/S0165-1765\(97\)00214-0](https://doi.org/10.1016/S0165-1765(97)00214-0)
- Silva, T.C., Alexandre, M. S, Tabak, B.M. 2018. Bank lending and systemic risk: a financial-real sector network approach with feedback. **Journal of Financial Stability**, 38, 98-118. <https://doi.org/10.1016/j.jfs.2017.08.006>
- Simon, N., Friedman, J., Hastie, T. and Tibshirani, R. (2013). "A sparse group lasso". **Journal of Computational and Graphical Statistics**, 22(2), 231-245.
<https://doi.org/10.1080/10618600.2012.681250>
- Stiassny, A. (1996). "A spectral decomposition for structural VAR models". **Empirical Economics**, 21(4), 535-555. <https://doi.org/10.1007/BF01180700>
- Wiesen, T. F., Beaumont, P. M., Norbin, S. C. and Srivastava, A. (2018). "Are generalized spillover indice overstating connectedness?". **Economics Letters**, 173, 131-134.
<https://doi.org/10.1016/j.econlet.2018.10.007>
- Zach, T. (2003). "Political events and the stock market: evidence from Israel". **International Journal of Business**, 8(3), 243-266.
<http://dx.doi.org/10.2139/ssrn.420242>

Anexos

ANEXO A – Resultados da persistência dos efeitos dos spillovers de volatilidade ao longo do tempo.

Em relação às faixas de frequência, que revelam a persistência dos efeitos das transmissões de volatilidade ao longo do tempo, as Tabelas 7 e 8 evidenciam que as conexões de volatilidade maiores, ao longo do tempo, permaneceram sendo os do grupo 1 (classe de modularidade 1). Descrevemos esse grupo estatisticamente na tabela 5 e graficamente na rede complexa da figura 4. Os maiores índices líquidos de transmissão na faixa de curtíssimo prazo (em no máximo 7 dias úteis) são - em ordem decrescente – os das ações BBAS3 (5.66%), BBDC3 (5.11%) e ITUB3 (3.82%). Isto revela que as negociações com as ações desses bancos ocorrem de forma mais intensa, respondendo mais rapidamente aos fluxos de informações que afetam o mercado bancário (notícias econômicas, financeiras, legais, políticas etc.). Consequentemente, essas ações estabelecem conectividades mais fortes no curtíssimo prazo.

Os maiores receptores líquidos, isto é, os que absorvem mais os choques de curtíssimo prazo são: RPAD3 (-2.82%), SANB3 (2.16%) e ABCB4 (-1.78%). Os motivos referentes à alta receptividade de *spillovers* da ação ABCB4 foram descritos na subseção 3.1.1.

Portanto, ainda que os resultados ilustrados nas Tabelas 7 e 8 contribuam para a análise da conectividade média da rede, eles não permitem enxergar os impactos de eventos específicos que ocorreram durante o período em análise.

Nesse sentido, para que a análise seja completa, devemos levar em conta as medidas dinâmicas de conectividade. Elas permitem detalhar a evolução dinâmica dos *spillovers* na rede, a qual permite capturar desvios da conectividade média que podem ter sido influenciados por eventos ou choques específicos de natureza política, econômica, financeira, social, legal etc. Isso foi feito na subseção 3.2.1 e os resultados foram descritos na figura 7 e na Tabela 6 deste trabalho.

Tabela 7. Conectividades médias de 5 dias úteis intra e entre ações dos bancos da B3

	BBAS3	BBDC3	BNBR3	ITUB3	ABCB4	SANB3	BAZA3	BMEB3	BPAN4	PINE4	RPAD3	BMIN3	BRIV3	BRSR3	FROM
BBAS3	39.18	11.27	0.38	8.78	3.36	2.77	0.35	1.29	1.08	0.53	0.67	0.45	0.42	0.73	32.09
BBDC3	11.22	40.22	0.44	11.75	3.20	2.82	0.63	1.30	1.13	0.52	0.76	0.31	0.33	0.26	34.69
BNBR3	0.71	0.79	64.44	0.61	0.70	0.73	0.54	1.00	0.81	0.48	0.49	0.48	0.64	0.67	8.67
ITUB3	8.78	11.84	0.37	41.37	3.52	2.45	0.47	1.12	1.26	0.31	0.57	0.30	0.42	0.39	31.80
ABCB4	4.45	4.09	0.62	4.25	52.43	1.82	0.53	1.30	1.51	0.54	1.18	0.48	0.64	0.44	21.86
SANB3	3.66	3.86	0.67	3.27	1.76	54.12	0.45	1.10	0.82	0.91	0.45	0.36	0.73	0.46	18.50
BAZA3	0.77	0.73	0.56	0.68	0.71	0.39	64.61	0.82	0.77	0.94	0.64	0.62	0.68	0.73	9.03
BMEB3	2.00	1.62	0.92	1.59	1.38	0.97	0.92	51.29	1.43	0.57	0.49	0.67	0.45	0.41	13.41
BPAN4	1.64	1.59	0.74	1.38	1.72	0.74	0.68	1.51	52.73	0.52	0.68	0.42	0.45	0.72	12.79
PINE4	0.80	0.70	0.49	0.44	0.61	1.07	0.54	0.66	0.58	62.93	0.43	0.80	1.13	2.53	10.78
RPAD3	1.25	1.38	0.61	1.09	1.36	0.57	0.63	0.79	0.75	0.47	59.78	0.40	0.56	0.51	10.36
BMIN3	0.67	0.60	0.38	0.55	0.42	0.35	0.63	0.67	0.41	0.77	0.36	64.09	1.10	0.71	7.63
BRIV3	0.96	0.79	0.54	0.63	0.73	1.00	0.77	0.77	0.56	1.14	0.38	0.56	61.50	0.64	9.48
BRSR3	0.85	0.52	0.74	0.60	0.61	0.66	0.50	0.44	0.83	2.89	0.46	0.84	0.62	59.04	10.55
TO	37.75	39.80	7.44	35.62	20.08	16.34	7.64	12.78	11.96	10.59	7.54	6.68	8.18	9.21	TCI
NET	5.66	5.11	-1.22	3.82	-1.78	-2.16	-1.39	-0.63	-0.82	-0.18	-2.82	-0.95	-1.30	-1.34	16.54

Fonte: Cálculos do autor no RStudio.

Tabela 8. Conectividades de 5 a 10 dias úteis intra e entre ações dos bancos da B3

	BBAS3	BBDC3	BNBR3	ITUB3	ABCB4	SANB3	BAZA3	BMEB3	BPAN4	PINE4	RPAD3	BMIN3	BRIV3	BRSR3	FROM
BBAS3	6.83	2.08	0.15	1.70	0.64	0.63	0.12	0.47	0.42	0.12	0.25	0.16	0.15	0.25	7.13
BBDC3	2.04	6.12	0.13	1.89	0.51	0.49	0.15	0.38	0.31	0.07	0.23	0.07	0.08	0.06	6.42
BNBR3	0.26	0.32	10.34	0.24	0.18	0.24	0.14	0.32	0.27	0.14	0.15	0.18	0.21	0.17	2.81
ITUB3	1.84	2.15	0.11	6.56	0.79	0.54	0.08	0.36	0.41	0.04	0.23	0.04	0.09	0.11	6.79
ABCB4	0.99	0.83	0.17	0.90	7.82	0.37	.12	0.40	0.29	0.10	0.34	0.14	0.15	0.14	4.94
SANB3	0.79	0.72	0.20	0.63	0.35	9.56	0.12	0.29	0.19	0.15	0.12	0.11	0.24	0.12	4.02
BAZA3	0.17	0.14	0.19	0.14	0.12	0.06	10.88	0.34	0.22	0.16	0.09	0.19	0.11	0.15	2.09
BMEB3	0.42	0.43	0.31	0.46	0.39	0.34	0.47	11.61	0.69	0.20	0.17	0.39	0.20	0.25	4.72
BPAN4	0.65	0.61	0.34	0.47	0.39	0.24	0.28	0.74	11.58	0.17	0.19	0.25	0.15	0.28	4.77
PINE4	0.18	0.16	0.10	0.07	0.16	0.22	0.14	0.15	0.19	10.34	0.09	0.43	0.22	0.67	2.78
RPAD3	0.51	0.46	0.18	0.42	0.46	0.23	0.18	0.31	0.28	0.11	11.18	0.10	0.18	0.10	3.53
BMIN3	0.17	0.15	0.14	0.09	0.10	0.08	0.18	0.27	0.17	0.25	0.09	11.26	0.21	0.30	2.21
BRIV3	0.43	0.27	0.19	0.20	0.26	0.45	0.16	0.33	0.18	0.23	0.15	0.25	10.63	0.27	3.37
BRSR3	0.35	0.16	0.19	0.17	0.15	0.18	0.15	0.21	0.33	0.95	0.10	0.45	0.24	10.90	3.63
TO	8.81	8.49	2.39	7.39	4.50	4.08	2.28	4.58	3.94	2.70	2.21	2.76	2.22	2.86	TCI
NET	1.68	2.07	-0.41	0.60	-0.44	0.06	0.19	-0.14	-0.83	-0.08	-1.32	0.55	-1.14	-0.78	4.23

Fonte: Cálculos do autor no RStudio

Página deixada em branco de forma intencional.

2 CONEXÕES DE VOLATILIDADE ENTRE OS PRINCIPAIS BANCOS NO BRASIL EM TEMPOS NORMAIS DE MERCADO: UMA ABORDAGEM NO DOMÍNIO DA FREQUÊNCIA

2.1 Introdução

A literatura destaca a importância de estudos envolvendo a medição de conexões de volatilidade afirmando que a volatilidade é uma variável-chave que influencia o comportamento dos investidores e *traders* e que é transmitida pelas conexões das quais fazem parte. Portanto, tal como as volatilidades são, as transmissões de volatilidade também podem ser uma *proxy* muito útil para mensurar o grau de aversão ao risco entre os participantes do mercado. Além disso, os estudos envolvendo esse tema buscam identificar a variação, o caminho, o nível, os padrões e os agrupamentos dessas transmissões dentro de mercados específicos, entre mercados correlatos ou mesmo em uma abrangência mais global. A literatura também destaca que estudos envolvendo volatilidades tem uma importância especial devido na análise de crises financeiras (Diebold & Yilmaz, 2016; Demirer et al., 2018). Nesse sentido, ela produz informações úteis a investidores (institucionais ou não), *traders*, *hedgers*, consultores, gestores, *policy makers* e demais participantes do mercado de capitais.

Especificamente, a Grande Crise Financeira Global de 2008 mostrou que o mercado bancário tem um forte potencial de desencadear problemas para a economia real dos países. Aumentos de níveis de incerteza podem gerar pânico no mercado, ocasionando a queda dos investimentos, interrupções de fornecimento de crédito e a corrida dos credores aos bancos. Assim, estudos voltados para as conexões de volatilidade entre bancos são úteis para prevenir ou diagnosticar crises ou, no caso de elas terem se instalado, calibrar as medidas que a minimizem ou as dissipem. Análises de conectividade entre ações ajudam na identificação dos ativos (ações de bancos, no nosso caso) que impactam mais no processo de alastramento dos choques causados por aumentos repentinos e fortes no nível de incerteza.

Tendo isto em mente, Diebold e Yilmaz (2009, 2012, 2014) desenvolveram uma metodologia - baseada nas decomposições de variância de um vetor autorregressivo - que mede e monitora os transbordamentos (*spillovers*) de retornos ou de volatilidades desses retornos entre ativos de naturezas semelhantes ou diferentes, carteiras de ativos ou entre mercado de ativos. Recentemente, Baruník e Krehlík (2018)

contribuíram para o melhoramento dessa metodologia. Propuseram uma nova estrutura capaz medir as conectividades que surgem devido às respostas de frequências heterogêneas aos choques no sistema econômico. Esses dois últimos autores argumentaram que, para entender as fontes das conectividades, é importante entender a dinâmica de frequência delas. Isto porque os preços dos ativos são impulsionados pelo crescimento de variáveis econômicas (consumo, expectativa de lucros, melhoras no ambiente econômico etc.). Estes fatores possuem diferentes componentes cíclicos e, portanto, naturalmente geram choques com respostas de frequências heterogêneas. Tais respostas provocam várias fontes de risco sistêmico, os quais se distribuem por prazos diferentes.

O mais recente trabalho nessa linha metodológica que trata de medição de conectividade de volatilidades em mercado de ações de bancos é o trabalho de Demirer et al. (2018). Os referidos autores utilizaram uma amostra de 96 bancos de 29 economias entre desenvolvidas e emergentes. O período de estudo foi de 12 de setembro de 2003 a 7 de fevereiro de 2014. Contudo, os únicos bancos brasileiros incluídos na análise foram o Itaú e o Bradesco.

Todavia, para além do mercado de ações bancárias, existem na literatura vários outros trabalhos que envolvem a medição de conexões de volatilidade. A diversidade de objetivos vai desde medição de conectividade da rede global de crédito soberano até a medição de *spillovers* de retorno e volatilidade entre os mercados de ações da Ásia oriental (Bostanci & Yilmaz, 2020; Cotter et al., 2017; Demirer et al., 2018; Diebold & Yilmaz, 2015; Diebold & Yilmaz, 2014; Korobilis & Yilmaz, 2018; Uluceviz & Yilmaz, 2021; Uluceviz & Yilmaz, 2020). Contudo, nenhum trabalho tratou de medir a transmissão de volatilidade das ações dos bancos que operam no Brasil com a metodologia desenvolvida por Baruník e Krehlík (2018).

Neste sentido, o presente artigo tem o seguinte objetivo geral: analisar a conectividade financeira entre os principais bancos que operam no Brasil por meio do efeito da transmissão de volatilidade dos preços das ações desses bancos considerando diferentes níveis de frequência. Este objetivo geral se desdobra em três específicos: i) verificar a dinâmica geral de influência de transmissão e de recebimento de choques entre esses bancos; ii) identificar quais os bancos que apresentam o maior potencial de afetar o restante da rede de bancos; e iii) identificar quais foram os eventos que influenciaram a dinâmica de conectividade entre as ações desses bancos no período analisado.

Para isso, adotamos a técnica econométrica de medição de conectividade proposto por Diebold e Yilmaz (2012) e estendida por Baruník e Klehlík (2018). Com essa técnica, estimamos a dinâmica de frequência dessas conexões.

Utilizamos dados de séries temporais das volatilidades dos retornos dos preços diários das ações de 12 bancos listados na Bolsa de Valores de São Paulo, B3. Coletamos esses dados do website Yahoo Finanças, inicialmente na forma de séries temporais das cotações de fechamento diárias das ações desses bancos, com as quais elaboramos as séries dos retornos e das volatilidades desses retornos.

No intuito de contribuir para a literatura de conectividade financeira no contexto brasileiro, acreditamos ter fornecido resultados empíricos que podem ser úteis para informar aos investidores e interessados no mercado bancário as conexões de volatilidade das ações dos principais bancos brasileiros, estimando também o quão interligadas estão essas ações, bem como quais os níveis de influência que cada uma delas exerce no mercado brasileiro de ações bancárias. A influência que cada oscilação de ação bancária exerce no mercado também explicita quais delas tendem a gerar maiores transmissões de volatilidade dentro desse mercado, no caso da ocorrência de uma crise financeira ou econômica no país. Além disso, os resultados deste artigo podem ser bastante proveitosos para análises relacionadas ao gerenciamento de riscos de carteira de ativos e de ações bancárias no Brasil. Assim sendo, suas conclusões podem ser aproveitadas tanto por investidores institucionais (como fundos de pensão ou seguradoras), quanto por investidores individuais e até mesmo *traders* e *hedgers*.

Por fim, pelo período analisado, é razoável supor que o mercado bancário brasileiro operou em condições normais de mercado e que os únicos eventos críticos exógenos potenciais capazes de impactar a sua dinâmica foram: a destituição, no ano de 2016, do cargo da Presidente do Brasil naquele ano, Dilma Rousseff; a reforma trabalhista, isto é, a Lei Nº 13.467 de 2017 e as eleições de âmbito federal, no fim do ano de 2018, para os cargos de Presidente da República, Deputados Federais e Senadores.

2.2 Revisão de literatura

Baruník e Krehlík (2018) investigaram a conectividade intra-mercado do setor financeiro dos EUA em termos de conectividade de volatilidade em diferentes frequências. Os autores utilizaram como amostra as 11 principais empresas financeiras que representam o setor financeiro dos EUA: Well Fargo Co. (WFC), U.S Bancorp

(USB), Morgan Stanley (MS), J.P Morgan (JPM), Goldman Sachs (GS), Citibank (C), Bank New York Mellon (BK), Bank of American (BAC), American Express (AXP), American International Group (AIG) e PNC Group (PNC). O período de análise foi de 2000 a 2016. Eles concluíram que a conectividade geral do mercado estudado caiu em tempos considerados como calmos, visto que em períodos normais os choques de incerteza são menores, o que implica em um mercado menos conectado. Contudo, no período da crise financeira das hipotecas *subprime*, em 2008, bem como no período da crise da dívida europeia de 2011, a conectividade atingiu picos de transmissão de volatilidade. Além disso, os efeitos dessas crises persistiram por períodos duradouros. Isto elevou muito a conectividade de longo prazo entre as instituições financeiras analisadas. Segundo os autores, uma alta conectividade de longo prazo significa que há uma alta incerteza geral sobre o sistema financeiro durante o período analisado, em conjunto com uma alta incerteza sobre a situação econômica dos países afetados.

Korobilis e Yilmaz (2018) por meio de um índice de conectividade - nos moldes do Índice de Diebold e Yilmaz e baseado em um modelo bayesiano de vetores autorregressivos de parâmetros variáveis no tempo (TVP-VAR) - estimaram a conectividade de volatilidade entre as ações de 35 instituições financeiras dos Estados Unidos da América e da Europa. O período amostral considerado foi de 02 de janeiro de 2004 a 22 de julho de 2016, com 3235 observações diárias. Segundo os autores, o índice de conectividade utilizado na pesquisa capturou os pontos de virada abrupta melhor do que a dos índices de versões anteriores, que baseavam-se em janelas deslizantes. Portanto, esse índice baseado em TVP-VAR capturou de forma mais precisa e pontual a intensidade dos choques de eventos econômicos, políticos e outros que afetaram os mercados financeiros dos EUA e da Europa. Os pesquisadores também afirmaram que o novo índice desenvolvido apresentou um melhor desempenho na previsão de eventos sistêmicos nos setores financeiros dos EUA e da Europa.

Silva *et al.* (2018) analisaram, por meio de uma abordagem de redes com efeitos de *feedback*, como se deu o processo de contágio entre os choques no setor real e financeiro na economia brasileira. Os autores utilizaram dados trimestrais de empréstimos interbancários e entre os bancos e empresas. Esses dados foram coletados de uma base de dados exclusiva do Banco Central do Brasil. O período estudado foi de março de 2012 a julho de 2015. Concluíram que os bancos estatais foram os que tiveram maiores potenciais de recepção de choques vindos de qualquer

setor da economia brasileira. Verificaram também que houve fortes efeitos de integração entre as instituições analisadas. Essa integração pode tanto atenuar ou amplificar os choques gerados no setor real da economia. Além disso, para esses pesquisadores a interconectividade entre os agentes econômicos por meio de uma abordagem multiníveis é importante para a estimativa do risco sistêmico.

Liow (2015) caracterizou e mensurou os *spillovers* de volatilidade entre mercados de países emergentes durante o período da Crise Financeira Global de 2007-2009 e durante a crise das dívidas soberanas dos países da Zona do Euro, iniciada no outono de 2009 por causa do aumento do risco de não pagamento da dívida grega. O autor utilizou o índice de transbordamento de volatilidade de Diebold e Yilmaz, baseando-se em um modelo VAR generalizado. Seu trabalho concentrou-se nos *spillovers* de volatilidade nos dois períodos das crises citadas, com dois focos principais: (i) a verificação de quão sensíveis foram os mercados emergentes aos choques causados por crises; e (ii) no diagnóstico de quais foram os ativos mais suscetíveis a essas crises. Os dados utilizados foram de imóveis públicos, patrimônio geral, moeda e retornos dos títulos dos países emergentes. O período analisado foi de 13 de janeiro de 1999 a 26 de março de 2014. Seus resultados mostraram que a crise financeira global de 2007-2009 e a crise da dívida europeia impactaram fortemente os mercados emergentes. Os efeitos de tais crises afetaram a interdependência das volatilidades e a dinâmica de transbordamento, pois houve diferentes direções e padrões de co-movimentos dessas volatilidades. Além disso, a crise financeira global do *subprime* teve um impacto maior sobre os emergentes do que a crise europeia.

O trabalho de Demirer *et al.* (2018) é o trabalho de maior abrangência em termos amostrais, quando o assunto é transmissão de volatilidade de retornos dos bancos. Neste trabalho há uma amostra de 96 bancos de 29 economias desenvolvidas e emergentes. O período de estudo foi de 12 de setembro de 2003 a 7 de fevereiro de 2014. Seus resultados mais interessantes são: i) existe um forte agrupamento de transmissão dentro de cada país (intra-países) e que esse agrupamento interno difere de país para país; ii) há também um denso agrupamento de transmissão interpaaíses, porém esses agrupamentos são regionais. Os autores mostraram que os maiores *clusters* foram, em ordem decrescente, o anglo/europeu, o americano/canadense e o japonês.

2.3 Dados e metodologia

2.3.1 Dados

Utilizamos as séries temporais dos retornos das cotações diárias de fechamento das ações de 12 bancos (ver Tabela 2.1, na subseção 2.4) listados na bolsa de valores oficial do Brasil, B3 (Brasil, Bolsa, Balcão), bem como as séries das volatilidades desses retornos. O período da análise foi do dia 01 de fevereiro de 2016 a 17 de março de 2020. O período estudado mostrou-se conveniente, pois permitiu a inclusão de um dos principais bancos do mercado bancário brasileiro, o BTG Pactual, recentemente listado na B3, uma vez que o banco BTG Pactual só possui cotações na B3 a partir do dia 01/02/2016. O conjunto completo de dados tem 10.980 observações diárias de volatilidade dos retornos das ações dos bancos em análise.

Coletamos a amostra no website do Yahoo Finanças. Inicialmente, recolhemos as séries temporais das cotações diárias de fechamento das ações desses bancos. Em seguida, calculamos as séries dos retornos e das volatilidades.

Calculamos as séries diárias de volatilidade dos retornos das séries de ações dos 12 bancos com base em intervalos, seguindo os procedimentos de Demirer *et. al* (2018) e Garman e Klass (1980), que fizeram o cálculo assim:

$$\tilde{\sigma}_{it}^2 = 0.511(H_{it} - L_{it})^2 - 0.019[(C_{it} - O_{it})(H_{it} - L_{it} - 2O_{it}) - 2(H_{it} - O_{it})(L_{it} - O_{it})] - 0.383(C_{it} - O_{it})^2$$

onde H_{it} é o registro do preço máximo diário da ação do banco i no dia t ; L_{it} é o registro do preço mínimo diário da ação do banco i no dia t ; O_{it} é o registro do preço diário inicial da ação do banco i no dia t ; e C_{it} é o registro do preço diário de fechamento da ação do banco i no dia t .

As cotações diárias de fechamento das referidas ações foram ajustadas para a distribuição de proventos (dividendos e juros sobre o capital próprio) e desdobramentos. De acordo com Alizadeh, Brandt e Diebold (2002), essa forma de calcular a volatilidade é robusta a certas formas de ruído de microestrutura de mercado, além de ser quase tão eficiente quanto à volatilidade realizada com base em dados *intraday* de alta frequência.

2.3.2 Conectividade de Diebold e Yilmaz

O índice que escolhemos para medir os graus de conectividade é um índice de *spillover* de volatilidade, que foi inicialmente desenvolvido e utilizado por Diebold e Yilmaz (2009) e posteriormente aperfeiçoados pelos mesmos autores em trabalhos distintos (Diebold e Yilmaz, 2012 e 2014).

Em Diebold e Yilmaz (2009) os *spillovers* de volatilidade foram calculados com base no processo de decomposição de variância associado a um VAR simples, o qual precisa ter seus erros ortogonalizados pelo processo de decomposição de Cholesky para isolar os choques e identificar a participação de cada um desses choques nos erros de previsão. No entanto, o uso da decomposição de Cholesky depende da ordem das variáveis no sistema VAR. Então, qualquer medida criada usando esse esquema de identificação de choques também será dependente dessa ordenação. Visando eliminar esse problema, os mesmos Diebold e Yilmaz (2012) propuseram a utilização de estrutura VAR generalizada. Essa estrutura, além de eliminar a dependência da escolha da ordem das variáveis, também permite a mensuração de *spillovers* direcionais. Isto ocorreu porque, nesta última versão, os autores utilizaram a estrutura de identificação KPPS de Koop, Pesaran e Potter (1996) e Pesaran e Shin (1980). Ela trouxe a vantagem de impor uma suposição adicional de normalidade dos choques.

Assim, considere uma covariância estacionária de n variáveis VAR (p), $x_t = \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t$, onde $\varepsilon \sim (0, \Sigma)$ é um vetor de erros independentes e identicamente distribuídos. A representação de média móvel é $x_t = \sum_{i=0}^{\infty} A_i \varepsilon_{t-i}$ onde as matrizes de coeficientes $N \times N$ A_i obedecem à recursão $A_i = \phi_1 A_{i-1} + \phi_2 A_{i-2} + \dots + \phi_p A_{i-p}$, com A_0 sendo uma matriz de identidade $N \times N$ e com $A_i = 0$ para $i < 0$. Os coeficientes de médias móveis (ou transformações como funções de impulso resposta, ou ainda a decomposição de variância) são as chaves para entender a dinâmica do sistema. Os autores utilizaram as decomposições de variância, o que os permitiu analisar as variações de erro de previsão de cada variável desmembrando-as em partes que são atribuíveis aos vários choques do sistema. As decomposições de variância os permitiram avaliar a fração da variância de erro H passos à frente na previsão x_i que é devida aos choques para x_j , $\forall j \neq i$, para cada i .

2.3.3 Parcelas da variância

Definindo agora as partes da variância como as frações das variações de erro de previsão H passos à frente na previsão x_i que são causadas por choques em x_i , para $i = 1, 2, \dots, N$, e as partes de variância cruzada, ou *spillovers*, como as frações das variações de erro de previsão H passos à frente na previsão x_i causadas por choques em x_j para $i, j = 1, 2, \dots, N$, de modo que $i \neq j$.

Denotando as decomposições de variância de erro de previsão H passos à frente por $\theta_{ij}^g(H)$, para $H = 1, 2, \dots$ tem-se:

$$\theta_{ij}^g(H) = \frac{\sigma_{jj}^{-1} \sum_{h=0}^{H-1} (e_i' A_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} (e_i' A_h \Sigma A_h' e_i)} \quad (1)$$

Onde Σ é a matriz de variância para o vetor de erro ε , σ_{jj} é o desvio padrão do termo de erro para a j th-ésima equação, e e_i é o vetor de seleção, com um como o i -ésimo elemento e zeros de outra forma. Como observado anteriormente, a soma dos elementos em cada linha da variância da tabela de decomposição não é igual a 1: $\sum_{j=1}^N \theta_{ij}^g(H) \neq 1$. Para usar a informação disponível na variância da matriz de decomposição no cálculo do índice de *spillover*, normalizam-se cada entrada da matriz de decomposição de variância pela soma das linhas como:

$$\vartheta_{ij}^g(H) = \frac{\theta_{ij}^g(H)}{\sum_{j=1}^N \theta_{ij}^g(H)} \quad (2)$$

Note que, por construção, $\sum_{j=1}^N \vartheta_{ij}^g(H) = 1$ e $\sum_{i,j=1}^N \vartheta_{ij}^g(H) = N$.

2.3.4 Spillovers totais

Usando as contribuições de volatilidade da decomposição da variância KPPS, podemos construir o índice de reversão da volatilidade total:

$$S^g(H) = \frac{\sum_{i,j=0}^N \vartheta_{ij}^g(H)}{\sum_{i,j=1}^N \vartheta_{ij}^g(H)} 100 = \frac{\sum_{i,j=1}^N \vartheta_{ij}^g(H)}{N} 100 \quad (3)$$

Este é o análogo KPPS da medida baseada na fatoração de Cholesky usada por Diebold e Yilmaz (2009). O índice de *spillover* total mede a contribuição de *spillovers* de

choques de volatilidade entre classes de ativos para a variância de erro de previsão total.

2.3.5 Spillovers direcionais

Embora seja suficiente estudar o índice de *spillover* de volatilidade total para compreender quanto dos choques à volatilidade se espalha através das principais classes de ativos, a abordagem VAR generalizada nos permite aprender sobre a direção dos *spillovers* de volatilidade em grandes classes de ativos.

À medida que as respostas de impulso generalizadas e as decomposições de variância são invariantes para a ordenação de variáveis, calculam-se os *spillovers* direcionais usando os elementos normalizados da matriz de decomposição de variância generalizada. Medindo os *spillovers* de volatilidade direcional recebidos pelo banco i de todos os outros bancos j como:

$$S_{i.}^g(H) = \frac{\sum_{j=1, j \neq i}^N \vartheta_{ij}^g(H)}{\sum_{i,j=1}^N \vartheta_{ij}^g(H)} 100 = \frac{\sum_{j=1, j \neq i}^N \vartheta_{ij}^g(H)}{N} 100 \quad (4)$$

De forma semelhante, medindo os *spillovers* de volatilidade direcional transmitidos pelo banco i para todos os outros bancos j como:

$$S_{.i}^g(H) = \frac{\sum_{j=1, j \neq i}^N \vartheta_{ji}^g(H)}{\sum_{i,j=1}^N \vartheta_{ij}^g(H)} 100 = \frac{\sum_{j=1, j \neq i}^N \vartheta_{ji}^g(H)}{N} 100 \quad (5)$$

Pode-se pensar no conjunto de *spillovers* direcionais como proporcionando uma decomposição dos *spillovers* totais para aqueles provenientes de (ou para) uma fonte particular.

2.3.6 Spillovers líquidos

Obtém-se o *spillover* líquido de volatilidade do banco i para todos os outros bancos j como

$$S_i^g(H) = S_{i.}^g(H) - S_{.i}^g(H) \quad (6)$$

O *spillover* líquido de volatilidade é simplesmente a diferença entre os choques de volatilidade brutos transmitidos para todos os outros bancos, e os choques brutos de volatilidade recebidos de todos os outros bancos.

2.3.7 Spillovers líquidos em pares

O *spillover* líquido de volatilidade em (6) fornece informações resumidas sobre o quanto cada banco contribui para a volatilidade em outros bancos, em termos líquidos. Também é interessante examinar os *spillovers* líquidos de volatilidade em pares, que são definidos como:

$$S_{ij}^g(H) = \left(\frac{\vartheta_{ji}^g(H)}{\sum_{i,k=1}^N \vartheta_{ik}^g(H)} - \frac{\vartheta_{ij}^g(H)}{\sum_{j,k=1}^N \vartheta_{jk}^g(H)} \right) 100 = \left(\frac{\vartheta_{ji}^g(H) - \vartheta_{ij}^g(H)}{N} \right) 100 \quad (7)$$

O *spillover* líquido de volatilidade em pares entre os bancos i e j é simplesmente a diferença entre os choques brutos de volatilidade transmitidos do banco i ao banco j e os choques brutos transmitidos de j para i .

2.3.8 Conectividade no domínio de frequência de Baruník e Krehlík

De acordo com Baruník e Krehlík (2018) medir a conectividade entre variáveis pelo processo de decomposição de variância do erro de previsão generalizada (*GFEVD* – *Generalized Forecast Error Variance Decomposition*) é de suma importância. Porém, para definir medidas dependentes da frequência é preciso considerar sua contrapartida espectral. Assim, sabendo que a medida de conexão é baseada nas funções de resposta ao impulso, Ψ_j , definidas no domínio do tempo, considere uma função de resposta em frequência, $\Psi(e^{-i\omega}) = \sum_h e^{-i\omega h} \Psi_h$, que pode ser simplesmente obtida a partir da transformação de Fourier dos coeficientes Ψ , com $i = \sqrt{-1}$. Uma densidade espectral de x_t na frequência ω pode então ser definida como uma transformação de Fourier da série filtrada $MA(\infty)$ como

$$S_x(\omega) = \sum_{h=-\infty}^{\infty} E(x_t x'_{t-h}) e^{-i\omega h} = \Psi(e^{-i\omega}) \Sigma \Psi'(e^{+i\omega}) \quad (8)$$

O espectro de potência $S_x(\omega)$ como a variação de x_t é distribuída pelos componentes de frequência ω . Utilizando a representação espectral para covariância, isto é, $E(x_t x'_{t-h}) = \int_{-\pi}^{\pi} S_x(\omega) d\omega$, defini-se as contrapartes no domínio da frequência de decomposição de variância como:

Definição: O espectro de causalidade generalizada sobre as frequências $\omega \in (-\pi, \pi)$ é definido como

$$(f(\omega))_{j,k} \equiv \frac{\sigma_{kk}^{-1} |(\Psi(e^{-i\omega})\Sigma)_{j,k}|^2_{j,k}}{(\Psi(e^{-i\omega})\Sigma\Psi'(e^{+i\omega}))_{j,j}} \quad (9)$$

Onde $\Psi(e^{-i\omega}) = \sum_h e^{-i\omega h} \Psi_h$ é uma transformação de Fourier da resposta ao impulso Ψ .

De acordo com Baruník e Krehlík (2018) para obter uma decomposição natural no formato GFEVD original em frequências, pode-se simplesmente ponderar o $(f(\omega))_{j,k}$ pela participação de frequência da variável j . Além disso, a função de ponderação pode ser definida como

$$\Gamma_j(\omega) = \frac{(\Psi(e^{-i\omega})\Sigma\Psi'(e^{+i\omega}))_{j,j}}{\frac{1}{2\pi} \int_{-\pi}^{\pi} (\Psi(e^{-i\lambda})\Sigma\Psi'(e^{+i\lambda}))_{j,j} d\lambda} \quad (10)$$

que representa a potência da j -ésima variável em uma determinada frequência, que soma as frequências a um valor constante de 2π . Note que, embora a transformação de Fourier da resposta ao impulso seja geralmente uma quantidade de valor complexo, o espectro de causalidade generalizada é o módulo ao quadrado dos números complexos, produzindo, portanto uma quantidade real.

A proposição a seguir formaliza a discussão e é fundamental para o desenvolvimento das medidas de conexão no domínio da frequência, além de definir a decomposição no formato GFEVD no domínio da frequência.

Proposição: Suponha que x_t seja estacionário de sentido amplo com

$$\sigma_{kk}^{-1} \sum_{h=0}^{\infty} |(\Psi_h \Sigma)_{j,k}| < +\infty, \quad \forall_{j,k}.$$

Então,

$$(\theta_{\infty})_{j,k} = \frac{1}{2\pi} \int_{-\pi}^{\pi} \Gamma_j(\omega) (f(\omega))_{j,k} d\omega \quad (11)$$

Prova: Ver apêndice de Baruník e Krehlík (2018).

O processo GFEVD quando $H \rightarrow \infty$ pode então ser visto como a média ponderada do espectro de causação generalizada $(f(\omega))_{j,k}$, que fornece a força do relacionamento em uma determinada frequência ponderada pela potência das séries em determinada frequência.

De maneira formal, tem-se uma faixa de frequência $d = (a, b): a, b \in (-\pi, \pi), a < b$. A FEVD generalizada em alguma faixa de frequência d é definida como:

$$(\theta_d)_{j,k} = \frac{1}{2\pi} \int_d \Gamma(\omega) (f(\omega))_{j,k} d\omega \quad (12)$$

Com isso, devido ao relacionamento introduzido ser uma identidade e a integral ser um operador linear, a soma dos intervalos disjuntos que cobrem todo o intervalo $(-\pi, \pi)$ recuperará a GFEVD original. A observação a seguir formaliza o fato.

Agora formalmente define-se a GFEVD em escala na banda de frequência $d = (a, b): a, b \in (-\pi, \pi), a < b$ como

$$(\tilde{\theta}_d)_{j,k} = \frac{(\theta_d)_{j,k}}{\sum_k (\theta_\infty)_{j,k}} \quad (13)$$

Nesse contexto, a conexão de frequência (*frequency connectedness*) na faixa/banda de frequência d é então definida como:

$$C_d^F = 100 * \left(\frac{\sum (\tilde{\theta}_d)_{j,k}}{\sum (\tilde{\theta}_\infty)_{j,k}} - \frac{Tr\{\tilde{\theta}_d\}}{\sum (\tilde{\theta}_\infty)_{j,k}} \right) \quad (14)$$

A conexão C_d^F decompõe a conexão original em partes distintas que, em suma, fornece a medida de conexão original C_∞ .

Já a conexão interna (*within connectedness*) na faixa/banda de frequência d é definida como:

$$C_d^W = 100 * \left(1 - \frac{Tr\{\tilde{\theta}_d\}}{\sum (\tilde{\theta}_d)_{j,k}} \right) \quad (15)$$

A conexão C_d^W fornece o efeito de conexão que ocorre dentro da faixa/banda de frequência e é ponderada exclusivamente pela potência da série na faixa de frequência especificada.

2.4 Resultados

A Tabela 2.1 fornece os códigos das ações dos bancos incluídos na amostra. São 12 bancos listados na B3 entre os quais estão os principais bancos do país atualmente: Itaú-Unibanco, Bradesco, Santander, Banco do Brasil e BTG Pactual.

Tabela 2.1 - Nomes e Códigos dos bancos

BBAS3	Banco do Brasil
BBDC3	Banco Bradesco
BNBR3	Banco do Nordeste
BPAC3	Banco BTG Pactual
ITUB3	Banco Itaú-Unibanco
ABCB4	Banco ABC Brasil
SANB3	Banco Santander
BMEB3	Banco Mercantil do Brasil
BPAN4	Banco Pan
PINE4	Banco Pine
RPAD3	Alfa Holdings
IDVL3	Banco Indusval

Fonte: elaborada pelo autor.

Iniciando a análise evolutiva da conectividade total decomposta em frequências é possível mostrar em detalhes a dinâmica de conectividade. Todas as medidas de conectividade foram calculadas com base em um vetor autorregressivo de quatro defasagens dentro de um horizonte de previsão de 100 dias. O período abrangido por este trabalho contém ocorrências de eventos relevantes com potencial de afetar as expectativas dos investidores e dos demais agentes da economia. Neste período, no ano de 2016 ocorreu a destituição da então presidente da república Dilma Rousseff. Além disso, no ano de 2017 ocorreu a aprovação da Lei nº 13.467 de 2017, também chamada de reforma trabalhista, e no ano de 2018 ocorreu nova eleição para o cargo de presidente da república do Brasil. Estes acontecimentos políticos tiveram impactos na conectividade dentro de diferentes frequências.

Na Figura 2.1 tem-se a conectividade na frequência de curtíssimo prazo, isto é, de 1 a 5 dias. Neste nível de frequência de conectividade já é possível ver que a troca de presidente ocorrida em meados do ano de 2016 e também a eleição presidencial de 2018 afetaram as transmissões de volatilidade no mercado de ações dos bancos no

Brasil. O maior pico de variação chegou a ultrapassar 80% no período que coincide com o mês das eleições no Brasil, isto é, em outubro de 2018. Assim sendo, o mercado chegou a ficar altamente conectado neste período de curtíssimo prazo. No entanto, a maior parte do período analisado parece ter sido percebida pelos agentes econômicos como tempos normais de mercado, com conexões oscilando de 20% a quase 40%, nesta frequência.




Figura 2.1. Spillovers totais no curtíssimo prazo (de 1 a 5 dias)
Fonte: elaborada pelo autor no RStudio.

Na Figura 2.2, tem-se a conectividade no período entre 5 e 10 dias (curto prazo). Esta faixa de frequência não apresentou resultados de conexão expressivos como mostra o gráfico da figura.




Figura 2.2. Spillovers totais no curto prazo (de 5 a 10 dias).
Fonte: elaborada pelo autor no RStudio.

Semelhantemente, na Figura 2.3 tem-se a representação da conectividade na faixa de frequência de 10 a 20 dias (a qual definimos como curto/médio prazo), onde verificamos a frequência com o menor nível de conexão entre as ações dos bancos analisados.




Figura 2.3. Spillovers totais no médio prazo(de 10 a 20 dias)
Fonte: elaborada pelo autor no RStudio.

Por fim, tem-se a Figura 2.4, onde encontramos a dinâmica da conectividade total acima de um mês de duração (as quais chamaram de médio prazo). Tal figura mostra que há informações que são devidamente processadas pelos bancos em períodos superiores a um mês, por isso ocorre a volta da conectividade aos níveis próximos de 20%.

Portanto, o que se pode concluir da conectividade total dinâmica analisada em períodos normais de mercado, com momentos pontuais de maior incerteza, é que as oscilações de ânimo presentes nas decisões dos operadores do mercado de ações bancárias no Brasil são transmitidas aos preços inicialmente dentro de uma semana. Posteriormente, há um período de um mês em que a conexão é reduzida a níveis abaixo dos 5% (período esse em que os agentes econômicos envolvidos estudam as informações que possam ter repercussões mais duradouras para o mercado). Finalmente, há um novo aumento da conectividade após um mês da ocorrência dos eventos que os agentes consideram como mais impactantes.




Figura 2.4. Spillovers totais no longo prazo (de 20 a mais dias)
 Fonte: elaborada pelo autor no RStudio.

Observando agora a conectividade direcional líquida em frequências, a Figura 2.5 ilustra a conectividade no curto prazo e revela que o banco do Brasil (BBAS3), o Itaú Unibanco (ITUB3), o banco Bradesco (BBDC3), o banco ABC Brasil (ABCB4) e o banco do Nordeste (BNBR3) foram os principais transmissores líquidos de volatilidade neste nível de frequência. O Itaú Unibanco (ITUB3) foi o maior transmissor líquido. No entanto, a figura também evidencia que nos períodos que coincidem com a destituição da ex-presidente Dilma e com aprovação da reforma trabalhista, bem como no período de eleições e no primeiro ano pós-eleições, todos esses transmissores tornaram-se altamente receptores por um breve instante de tempo. Isso nos permite supor que esses eventos foram inicialmente considerados relevantes, porém rapidamente as expectativas negativas quanto ao futuro do mercado foram minimizadas.




Figura 2.5. Spillovers líquidos no curtíssimo prazo
Fonte: elaborada pelo autor no RStudio.

Outros resultados relevantes são ilustrados nas Figuras 2.6, 2.7 e 2.8. Elas revelam que a conectividade direcional líquida no componente de baixa frequência (que neste trabalho corresponde ao período de 20 a mais dias), foi a única frequência com conexão em nível relevante depois da faixa de frequência de 1 a 5 dias.

Assim, como se pode ver, os maiores transmissores líquidos de volatilidades continuam sendo BBAS3, ITUB3, BBDC3 e o ABCB4. Tal evidência atesta o potencial da volatilidade das ações desses bancos afetarem sistemática e intensamente o mercado de ações bancárias. Sobretudo porque os choques nos preços das ações de tais bancos parecem que persistem por mais tempo e forma mais robusta do que os choques dos demais bancos.




Figura 2.6. Spillovers líquidos no curto prazo
 Fonte: elaborada pelo autor no RStudio.




Figura 2.6. Spillovers líquidos no médio prazo
 Fonte: elaborada pelo autor no RStudio.




Figura 2.8. Spillovers líquidos no longo prazo
 Fonte: elaborada pelo autor no RStudio.

Alguns fatos que corroboram as conclusões anteriores podem ser exemplificados. Pois os demais bancos, principalmente o banco Santander (SANB3), apresentaram o perfil de receptores líquidos de choques na maior parte do período da baixa frequência. O banco do Nordeste (BNBR3) tornou-se um transmissor líquido de choques a partir de meados de 2019 (onde apresentou seu pico de transmissão de volatilidade), até o início de 2020. E o banco BTG Pactual (BPAC3), a partir do início de 2019, começou a apresentar uma tendência crescente ao perfil de transmissor líquido de volatilidade em frequências mais baixas, isto é, em um prazo mais longo.

2.5 Considerações finais

Um dos objetivos principais deste artigo foi contribuir para a disseminação no Brasil de uma nova metodologia econométrica que permite medir e monitorar conexões de volatilidade entre ativos de vários mercados e variáveis econômicas também diversas.

Mais especificamente, tratamos de medir a conectividade financeira entre os preços das ações dos principais bancos que operam no Brasil sob um determinado cenário específico. Ao contrário do primeiro artigo desta tese, neste aqui as condições de mercado no período analisado neste estudo, de 01/02/2016 a 17/03/2020, podem ser consideradas como normais, isto é, com poucos eventos capazes de afetar significativamente o grau de conectividade entre as ações do mercado bancário brasileiro. De fato, eventos como a perda do cargo de Presidente da República, as mudanças nas leis trabalhistas e as eleições federais do ano de 2018 podem desencadear maior grau de aversão ao risco e impactar as expectativas dos investidores. Isto, por sua vez, traduz-se em choques nas cotações de fechamento dessas ações, aumentando suas volatilidades e as transmissões delas, as quais podem apresentar diferentes graus de intensidade e níveis de persistência ao longo do tempo.

Nesse sentido, chegamos a resultados que mostram que na frequência de 1 a 5 dias (a qual definimos como curtíssimo prazo), os principais transmissores líquidos de choques foram o Banco do Brasil (BBAS3), o Itaú Unibanco (ITUB3), o Bradesco (BBDC3), o banco ABC Brasil (ABCB4) e o Banco do Nordeste (BNBR3).

Nos períodos de 5 a 10 dias (curtíssimo/curto prazo) e de 10 a 20 dias (curto/médio prazo) não tivemos transmissões líquidas relevantes. Já a faixa de frequência que representa o prazo mais longo da análise, isto é, de 20 a mais dias (médio/longo prazo), apresentou novamente o Banco do Brasil, o Itaú Unibanco, o Bradesco e o ABC Brasil como os principais transmissores líquidos de choques de volatilidade.

Esses resultados demonstram que tais bancos são os que possuem o maior potencial de afetar sistematicamente o mercado de ações bancárias brasileiro, uma vez que os choques nos preços das ações de tais bancos persistem por mais tempo e com maior intensidade do que os choques das ações dos demais bancos.

Incluir ações de bancos em uma carteira de investimentos é uma prática muito comum dos gestores de fundos de investimento em ações, de fundos de pensão, de seguradores e outros investidores institucionais. Ações de bancos são consideradas como de menor volatilidade e de maior resiliência às crises motivadas pelo aumento da aversão ao risco dos agentes do mercado de capitais. Assim, naturalmente, esse trabalho poderá ser útil para a tomada de decisões desses investidores, seja em

processos de avaliação de compra e venda desses ativos, seja nas decisões de gerenciamento do risco de carteiras de ações.

Porém, não apenas eles poderão tirar proveito das conclusões aqui apresentadas, dado que as mesmas podem interessar também aos formuladores de política monetária que estiverem interessados no diagnóstico e prevenção dos efeitos de aumentos repentinos no transbordamento de volatilidade desses ativos em momentos críticos. Portanto, acreditamos que esta tese pode ser de utilidade para o processo de tomada de decisões desses *policy-makers*.

Referências

- Alizadeh, S.; Brandt, M. & Diebold, Francis. (2002). Range-based estimation of stochastic volatility models. **Journal of Finance**, 57(3), 1047-1091.
<https://doi.org/10.1111/1540-6261.00454>
- Baruník, J. & Krehlík, T. (2018). Measuring the frequency dynamics of financial connectedness and systemic risk. **Journal of Financial Econometrics**, 16(2), 271-296.
<https://doi.org/10.1093/jfinec/nby001>
- Bostanci, G. & Yilmaz, Kamil. (2020). “How connected is the global sovereign credit risk network”. **Journal of Banking and Finance**, 113.
<https://doi.org/10.1016/j.jbankfin.2020.105761>
- BRASIL. Lei Nº 13.467/2017. Diário Oficial da União, 14 de Julho de 2017.
http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2017/lei/l13467.htm
- Demirer, M., Diebold, F. X. , Liu, L. & Yilmaz, K. (2018). Estimating global bank network connectedness. **Journal of Applied Econometrics**. 33(1), 1-15.
<https://doi.org/10.1002/jae.2585>
- Diebold, F. X; Yilmaz, K. (2009). Measuring financial asset return and volatility spillovers with application to global equity markets. **The Economic Journal**, 119, 158-171.
<https://doi.org/10.1111/j.1468-0297.2008.02208.x>
- Diebold, F. X; Yilmaz, K. (2012). Better to give than to receive: Predictive directional measurement of volatility spillovers. **International Journal of Forecasting**, 28(1), 57-66.
<https://doi.org/10.1016/j.ijforecast.2011.02.006>
- Diebold, F. Z; Yilmaz, K. (2014). On the network topology of variance decompositions: Measuring the connectedness of financial firms. **Journal of Econometrics**, 182(1), 119-134. <https://doi.org/10.1016/j.jeconom.2014.04.012>
- Garman, M.B.; Klass, M.J. (1980). On the estimation of security price volatilities from historical data. **Journal of Financial Economics**, 119, 457-471.
<https://www.jstor.org/stable/2352358>

- Koop, G; Pesaran, M. H; Potter, S. M. (1996). Impulse response analysis in nonlinear multivariate models. **Journal of Econometrics**, 74, 119 – 147.
[https://doi.org/10.1016/0304-4076\(95\)01753-4](https://doi.org/10.1016/0304-4076(95)01753-4)
- Liow, Kim H. (2015). Conditional Volatility Spillovers Effects Across Emerging Financial Markets. **Asia-Pacific Journal of Financial Studies**, 44, 215- 245.
<https://doi.org/10.1111/ajfs.12087>
- Korobilis, D. & Yilmaz, K. (2018). Measuring dynamic connectedness with large Bayesian VAR models. **Koç University-TUSIAD Economic Research Forum**, Working Paper n° 1802.
<https://www.econstor.eu/bitstream/10419/202976/1/1011071614.pdf>
- Pesaran, M. H & Shin, Y. (1998). Generalized impulse response analysis in linear multivariate models. **Economic Letters**, 58(1), 17-29.
[https://doi.org/10.1016/S0165-1765\(97\)00214-0](https://doi.org/10.1016/S0165-1765(97)00214-0)
- Silva, T.C., Alexandre, M. S, Tabak, B.M. (2018). Bank lending and systemic risk: a financial-real sector network approach with feedback. **Journal of Financial Stability**, 38, 98-118. <https://doi.org/10.1016/j.jfs.2017.08.006>
- Uluceviz, E. & Yilmaz, K. (2021). “Measuring real-financial connectedness in the U.S. economy”. **The North American Journal of Economics and Finance**, 58.
<https://doi.org/10.1016/j.najef.2021.101554>
- Uluceviz, E. & Yilmaz, K. (2020). Real-financial connectedness in the Swiss economy. **Swiss Journal of Economics and Statistics**, 156(1).
<https://doi.org/10.1186/s41937-019-0049-z>