

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

ELISAMA SILVA DE ALMEIDA

**ÍNDICES SETORIAIS DE CONFIANÇA DA INDÚSTRIA
BRASILEIRA: uma análise econométrica multivariada.**

RIO DE JANEIRO

2024

ELISAMA SILVA DE ALMEIDA

ÍNDICES SETORIAIS DE CONFIANÇA DA INDÚSTRIA
BRASILEIRA: uma análise econométrica multivariada.

Dissertação apresentada ao Programa de Pós-Graduação da Universidade Federal do Estado do Rio de Janeiro para a obtenção do título de Mestre em Ciências Econômicas.

Orientador: Prof. Dr. Marcelo Resende

RIO DE JANEIRO

2023

FICHA CATALOGRÁFICA

A447i Almeida, Elisama Silva de.

Índices setoriais de confiança da indústria brasileira: uma análise econométrica multivariada / Elisama Silva de Almeida. – 2024.

74 f.

Orientador: Marcelo Resende.

Dissertação (mestrado) – Universidade Federal do Rio de Janeiro, Instituto de Economia, Programa de Pós-Graduação em Economia da Indústria e da Tecnologia, 2024.

Bibliografia: f. 65 - 69.

Ficha catalográfica elaborada pela bibliotecária: Luiza Hiromi Arao CRB/7 – 6787

Biblioteca Eugênio Gudín/CCJE/UFRJ

FOLHA DE APROVAÇÃO

Elisama Silva de Almeida

ÍNDICES SETORIAIS DE CONFIANÇA DA INDÚSTRIA BRASILEIRA: uma análise econométrica multivariada.

Dissertação apresentada ao Programa de Pós-Graduação da Universidade Federal do Estado do Rio de Janeiro para a obtenção do título de Mestre em Ciências Econômicas.

Trabalho aprovado, Rio de Janeiro, Brasil, 07 de fevereiro de 2024:

Prof. Marcelo Resende
Universidade Federal do Rio de Janeiro (IE-UFRJ)

Prof. Romero Rocha
Universidade Federal do Rio de Janeiro (IE-UFRJ)

Dr. Douglas Silveira
Universidade de Alberta

DEDICATÓRIA

A Deus, que me sustentou até aqui .

A minha família, que sempre me apoiou incondicionalmente, especialmente minha mãe, Veracy.

A todos que me ajudaram a evoluir nessa jornada acadêmica.

AGRADECIMENTOS

A Deus, que sempre me deu saúde, força e coragem para continuar lutando em busca dos meus objetivos.

A minha mãe Maria Veracy, por estar sempre ao meu lado nos momentos bons e difíceis da minha vida, e nunca poupar esforço para me ajudar e orientar pelo caminho correto.

Ao meu pai Solon Brasilino (*In memoriam*), por ter me ajudado e ter sido um exemplo de força e coragem.

Ao meu irmão Elizeu, pela ajuda e incentivo que sempre me deu.

À minha cunhada Denise pelo apoio e meu sobrinho Eduardo, pelo carinho e por me ensinar tanto.

Aos meus gatos, Kim e Blake, por fazerem meu dia mais feliz.

Ao meu orientador Professor Marcelo Resende, pela paciência e boa vontade em me ajudar desde o início do mestrado. Sua ajuda foi fundamental.

Aos professores e doutores, membros da banca, pelo empenho e colaboração.

A todos os meus professores por terem passado conhecimentos que servirão como base para meu futuro profissional.

Aos meus colegas de turma, cujo apoio e incentivo foram fundamentais em um contexto pandêmico.

A todos os meus amigos, pela torcida e pelo companheirismo.

“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes”.
(Marthin Luther King)

RESUMO

ALMEIDA, Elisama Silva. **Índices setoriais de confiança da indústria brasileira**: uma análise econométrica multivariada. Rio de Janeiro, 2024. Dissertação (Mestrado em Economia da Indústria e da Tecnologia) - Instituto de Economia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2024.

Um elevado grau de comovimento setorial geralmente é interpretado como uma evidência de que choques econômicos globais afetam diretamente todos os setores. A literatura mostra que uma das formas de mensurar a confiança empresarial da economia é o indicador de confiança a partir de informações coletadas das expectativas dos empresários acerca das expectativas em relação às variáveis macroeconômicas, para alcançar esse objetivo utilizamos o Índice de Confiança do Empresário Industrial (ICEI) desenvolvido pelo Confederação Nacional da Indústria (CNI). Assim, esse trabalho consiste em aplicar uma estrutura multivariada Dynamic Conditional Correlation (DCC-GARCH) para avaliar as correlações das taxas de confiança dos setores industriais do Brasil. Para esse propósito, calculamos as correlações condicionais média com 27 setores industriais. A análise DCC-GARCH não é suficiente para avaliar as causas das correlações setoriais não constantes, por isso investigamos quais fatores comuns têm relevância no comportamento conjunto do índice de confiança nos setores industriais em um estudo de regressão, utilizando como variáveis independentes os ativos do IBOVESPA, o índice de IPCA, e o endividamento das famílias. Outra possível causa dos comovimentos pode ser devido a mudanças na variância dos fatores comuns, por isso uma análise das variâncias móveis (12 meses) da taxa de variação das variáveis independentes utilizadas na análise de regressão. Finalmente, com o intuito de abordar as possíveis mudanças na sensibilidade do índice de confiança dos setores industriais aos fatores comuns, é realizada uma análise de regressão móvel. Os resultados apontam que a comovimentação dos índices de confiança dos setores industriais não é constante ao longo do tempo. Dentre os fatores que causam tal comovimento, os resultados apontam que há uma força variável na propagação dos choques que pode explicar o comovimento dos Índices de confiança. Da mesma forma, ao longo do tempo há mudanças na sensibilidade dos setores aos fatores agregados que desempenham um papel no comovimento setorial.

Palavras chaves: Comovimento. Confiança. Correlação. DCC-GARCH.

ABSTRACT

ALMEIDA, Elisama Silva. **Sectoral Confidence Indices of the Brazilian Industry: A Multivariate Econometric Analysis**. Rio de Janeiro, 2024. Dissertation (Master's in Industrial and Technological Economics) - Institute of Economics, Federal University of Rio de Janeiro, Rio de Janeiro, 2024.

A high degree of sectoral co-movement is often interpreted as evidence that global economic shocks directly affect all sectors. The literature demonstrates that one way to measure the business confidence in the economy is through the confidence indicator based on information collected from entrepreneurs' expectations regarding macroeconomic variables. To achieve this goal, we use the Industrial Entrepreneur Confidence Index (ICEI) developed by the National Confederation of Industry (CNI). Thus, this study involves applying a multivariate Dynamic Conditional Correlation (DCC-GARCH) framework to assess the correlations of confidence rates in Brazil's industrial sectors. For this purpose, we calculate average conditional correlations using 27 industrial sectors. The DCC-GARCH analysis is not sufficient to assess the causes of non-constant sectoral correlations, so we investigate which common factors are relevant to the joint behavior of confidence indices in industrial sectors in a regression study. Independent variables include assets from IBOVESPA, the IPCA index, and household indebtedness. Another possible cause of co-movements may be changes in the variance of common factors, so we conduct an analysis of the moving variances (12 months) of the rate of change of independent variables used in the regression analysis. Finally, to address potential changes in the sensitivity of industrial sector confidence indices to common factors, a mobile regression analysis is conducted. The results indicate that the co-movement of confidence indices in industrial sectors is not constant over time. Among the factors causing such co-movement, the results suggest a variable force in shock propagation that can explain the co-movement of confidence indices. Similarly, over time, there are changes in the sectors' sensitivity to aggregate factors that play a role in sectoral co-movement.

Keywords: Comovement. Confidence. Correlation. DCC-GARCH.

LISTA DE FIGURAS

Figura 1: Pesos das opções de Respostas	43
Figura 2: Bloco de perguntas referentes ao ICEI.....	44
Figura 3: Correlação Condicional Média.....	53
Figura 4: Variância do Endividamento	57
Figura 5: Variância IBOV.....	58
Figura 6: Variância do IPCA.....	58
Figura 7: Variância do IBC-BR.....	59
Figura 8: Coeficiente do Endividamento	60
Figura 9: Coeficiente do IPCA.....	60
Figura 10: Coeficiente do preço de ações do Ibovespa	61
Figura 11: Coeficiente do IBC-BR.....	61

LISTA DE TABELAS

Tabela 1: Setores Escolhidos	45
Tabela 2: Estrutura da Classificação da CNAE 2.0	46
Tabela 3: Resultado das Correlações Dinâmicas dos Modelos Bivariados DCC- GARCH (1,1)	50
Tabela 4: Média das LV dos modelos simétricos e assimétricos	52
Tabela 5: Resultados FDCC estimados com variáveis econômicas	55
Tabela 6: Resultados FDCC estimados incluindo IBC-BR	56

LISTA DE ABREVIATURA E SIGLAS

DCC	Correlação Condicional Dinâmica
CSLL	Contribuição Social sobre o Lucro Líquido
CCC-GARCH	Correlação Condicional Constante
GARCC	Correlação Condicional Autorregressiva Generalizada
CNI	Confederação Nacional da Indústria
CNAE 2.0	Classificação Nacional de Atividades Econômicas
Eurostat	Escritório de Estatística da União Europeia
PEIC	Endividamento e Inadimplência do Consumidor
IBOV	Índice Ibovespa
IPCA	Índice Nacional de Preços ao Consumidor Amplo
IBGE	Instituto Brasileiro de Geografia e Estatística
ICC	Índice de Confiança do Consumidor
IIE	Índice de Incerteza Empresarial
IC-PMN	Índice de confiança do empresário de pequenos e médios negócios no Brasil
ICEI	Índice de Confiança do Empresário Industrial
IPA	Índice de Preços ao Produtor Amplo para bens industriais
INPC	Índice de Vendas do Setor Industrial, a taxa de câmbio efetiva real
DVEC	Modelo diagonal VEC
MGARCH	Modelo de heterocedasticidade condicional autorregressiva generalizada multivariada
FDCC	Modelo GARCH multivariado de Correlação Condicional Dinâmica Flexível
PCC	Pesquisas de Confiança do Consumidor
VAR	Vector Autoregressive

SUMÁRIO

1. INTRODUÇÃO	14
2. REVISÃO DA LITERATURA	16
2.1 CICLOS ECONÔMICOS	16
2.2 ÍNDICE DE CONFIANÇA	22
3. METODOLOGIA ECONOMÉTRICA	27
3.1 MODELO ECONOMÉTRICO.....	27
3.1.1 Modelos multivariados	27
3.1.2 Modelo DCC- GARCH	31
3.1.3 Extensões do modelo DCC-GARCH.....	36
3.2 BASE DE DADOS	41
3.2.1 Índice de Confiança do Empresário Industrial (ICEI).....	41
3.2.2 Variáveis econômicas	46
3.3 ESTIMAÇÃO	47
3.4 MÉTODO "MACGYVER".....	48
4. DISCUSSÃO DOS RESULTADOS	49
4.1 ASPECTOS ASSIMÉTRICOS	51
4.2 COMOVIMENTO DOS ÍNDICES DE CONFIANÇA.....	52
4.3 POSSÍVEIS FATORES QUE CAUSAM FLUTUAÇÕES NAS CORRELAÇÕES SETORIAIS.....	54
4.3.1 Alterações na magnitude dos choques comuns.....	54
4.3.2 Força variável da propagação de choques	57
4.3.3 Mudanças na sensibilidade dos setores a fatores comuns.....	59
5. CONSIDERAÇÕES FINAIS	62
BIBLIOGRAFIA	65
APÊNDICE	70

1. INTRODUÇÃO

A interligação entre os setores da economia, conhecida como comovimento setorial, desempenha um papel fundamental nos ciclos econômicos, onde um elevado grau de comovimento setorial geralmente é interpretado como uma evidência de que choques globais afetam diretamente todos os setores, além de transmitir choques que afetam tanto áreas específicas como a economia como um todo, devido às conexões entre esses setores. Nesse contexto, podemos afirmar que a volatilidade da economia não depende apenas da instabilidade em setores individuais, mas também das correlações entre os tais.

Desse modo, os choques setoriais desempenham um papel significativo no ciclo econômico de um país, e têm uma importância considerável na compreensão da dinâmica da economia. Esses choques referem-se a eventos ou mudanças que afetam um setor específico de maneira desproporcional, ou seja, um choque setorial pode se espalhar pela economia, afetando outros setores e criando uma série de efeitos em cascata, e conseqüentemente amplificar ou atenuar os ciclos econômicos. Conforme afirmam Long e Plosser (1987), mesmo que os choques aleatórios de produtividade sejam independentes entre os setores, as escolhas dos agentes causarão comovimento de atividade de diferentes setores.

Shea (2002) explica que o comovimento no curto prazo entre setores industriais de manufatura dos EUA, no período pós-guerra, pode ser explicado tanto por choques comuns quanto a complementaridades que propagam choques entre os setores. Tal autor conclui que as ligações de insumo-produção e os efeitos de contágio da atividade econômica local são importantes para a comovimentação, enquanto os efeitos de contágio da atividade econômica agregada não são significativos.

Assim, vivemos em um contexto de constantes mudanças no cenário econômico, onde os choques de oferta e demanda promovem aumentos na incerteza, e conseqüente afeta a confiança empresarial. Dessa forma, na literatura, foram propostas diversas abordagens para avaliar a incerteza, incluindo a análise da flutuação no mercado de ações, a avaliação da variação nas previsões de crescimento feitas por especialistas, a identificação de termos relacionados à "incerteza" em diversas fontes de mídia digital e a análise de pesquisas de opinião.

Uma forma de mensurar o ambiente econômico é através do indicador de confiança a partir de informações coletadas das expectativas dos empresários acerca das expectativas em relação às variáveis macroeconômicas e como tal cenário irá

impactar o faturamento de sua firma. Logo, torna-se pertinente realizar um estudo sobre o contágio nas volatilidades relacionadas à confiança empresarial nos setores industriais brasileiro, e analisar em que medida a volatilidade agregada depende das correlações entre tais setores, dado que há uma grande escassez de estudos referente aos setores industriais que exploram o comportamento da volatilidade na confiança empresarial de tais setores, bem como os fatores que os afetam. Portanto, esse trabalho se diferencia dos demais por estudar a volatilidade condicional dos Índices de Confiança dos setores industriais brasileiros.

Nesse sentido, com o intuito de contribuir para a exploração do tema em questão, consideramos pertinente realizar um estudo sobre comovimento setorial relacionadas à confiança empresarial nos setores industriais brasileiro, e analisar em que medida a volatilidade agregada depende das volatilidades individuais desses setores e/ou das correlações entre eles. Para alcançar esse fim, queremos aplicar uma estrutura multivariada DCC-GARCH para avaliar os aspectos assimétricos das volatilidades, bem como das correlações das taxas de confiança dos setores industriais do Brasil. Vale ressaltar que tal modelo se diferencia dos seus antecessores por considerar que a dinâmica do comovimento pode variar ao longo do ciclo econômico, uma vez que os setores podem se tornar mais correlacionados devido a ligações setoriais mais fortes ao longo dos anos. Por outro lado, também pode haver uma tendência de tempo negativa como resultado de uma menor magnitude de fatores comuns. Entretanto, conforme afirma Sandqvist (2017), a análise DCC-GARCH não é suficiente para avaliar as causas das correlações setoriais não constantes. Logo será feita uma análise sobre as causas de tal comovimento, que pode ser consequência dos efeitos diretos de fatores comuns e à transmissão de choques devido a ligações setoriais.

Os resultados apontam que a comovimentação dos índices de confiança dos setores industriais não é constante ao longo do tempo, e assim varia de forma significativa, sendo que em alguns períodos os setores se movem mais fortemente do que em outros momentos. Dentre os fatores que causam tal comovimento, os resultados apontam que há uma força variável na propagação dos choques que pode explicar o comovimento dos Índices de confiança. Da mesma forma, há mudanças na sensibilidade dos setores aos fatores agregados ao longo do tempo que desempenham um papel no comovimento setorial.

Para alcançar esse objetivo, na seção 2 iremos fazer uma revisão de literatura concernente aos ciclos econômicos e os índices de confiança. Na seção 3, falaremos sobre a metodologia empregada e finalmente na seção 4 iremos discutir os resultados alcançados.

2. REVISÃO DA LITERATURA

2.1 CICLOS ECONÔMICOS

Nessa seção iremos contextualizar o uso do modelo que será abordado na metodologia desse trabalho. Inicialmente, começaremos falando sobre os ciclos econômicos, que é o pano de fundo de toda a análise desse trabalho. O ciclo econômico pode ser caracterizado como as mudanças que ocorrem na economia ao longo do tempo, através de quatro ciclos principais: expansão, pico, contração e vale, assim, uma característica empírica dos ciclos econômicos é o comovimento entre uma ampla variedade de atividades econômicas, cuja interpretação é vista como uma perturbação agregada comum. Dessa forma, alguns economistas buscam examinar o comovimento, de determinadas variáveis econômicas, com o intuito de determinar até que ponto o mesmo pode ser caracterizado como resultado de um choque agregado comum, ou de um conjunto mais diversificado de distúrbios independentes, assim, o nível de comovimento pode ser calculado a partir das correlações médias, conforme será abordado mais à frente.

Desse modo, o termo "comovimento setorial" refere-se à tendência de diferentes setores da economia se comportarem de forma semelhante ou sincronizada ao longo de um ciclo econômico. Conforme mencionado anteriormente, um ciclo econômico é uma sequência periódica, e as diferentes indústrias e setores da economia podem responder de maneira similar às mudanças nas condições macroeconômicas, como variações no nível de atividade econômica, taxas de juros, política monetária e fiscal, consumo e investimento. Entretanto, vale destacar que o comovimento setorial não é uma regra absoluta, logo, há variações nas respostas de diferentes setores durante cada fase do ciclo econômico. Além disso, fatores específicos a cada indústria, como inovação tecnológica, mudanças regulatórias e tendências de consumo, também podem influenciar o desempenho de um setor em particular em relação ao ciclo econômico geral.

A dinâmica do comovimento pode mudar com o passar do tempo, uma vez que pode haver uma tendência temporal positiva ou negativa; positiva devido a conexões interindustriais mais fortes, e negativa devido a menor magnitude de fatores

comuns. Além disso, o nível do referido comovimento pode flutuar devido a reações assimétricas a choques favoráveis e desfavoráveis. Desse modo, conforme afirma Sandqvist (2017), pouco se sabe sobre os aspectos dinâmicos desse comovimento.

Plosser e Long (1987) publicaram um artigo intitulado "*Real Business Cycles*" (Ciclos Econômicos Reais, em tradução livre), que se tornou um marco importante no estudo dos ciclos econômicos. Nesse trabalho, eles propuseram uma teoria conhecida como a "teoria dos ciclos econômicos reais", cuja abordagem difere das teorias tradicionais de ciclos econômicos, que enfatizavam principalmente fatores monetários e demanda agregada. Em vez disso, tais autores argumentaram que as flutuações econômicas decorrem principalmente de choques reais, como mudanças na produtividade, tecnologia e choques no lado da oferta. Vale ressaltar que os comovimentos observados não determinam logicamente a presença de uma perturbação comum ou agregada, conforme destaca Long e Plosser (1987). Dessa forma, os citados autores estudaram o comovimento intersetorial na produção industrial mensal dos EUA e aplicam a análise fatorial para examinar a importância de choques agregados versus choques setoriais, e concluíram que mesmo que os choques aleatórios de produtividade sejam independentes entre os setores, as escolhas dos agentes causarão comovimento de atividade de diferentes setores.

Forni e Reichlin (1998) apresentaram uma abordagem inovadora para o estudo dos ciclos econômicos, usando técnicas de análise de fatores aplicadas a dados desagregados. A análise de ciclos econômicos é tradicionalmente realizada por meio de indicadores agregados, como o PIB, que fornecem uma visão geral da economia. No entanto, Forni e Reichlin (1998) propuseram uma abordagem que leva em conta as características específicas de diferentes setores ou componentes da economia. Eles buscaram identificar padrões cíclicos subjacentes em séries temporais desagregadas, permitindo uma análise mais detalhada das dinâmicas econômicas.

Conforme mencionado anteriormente, os ciclos econômicos são as flutuações periódicas na atividade econômica de uma economia, que envolvem fases de expansão, pico, contração e vale. Nesse contexto, Christiano e Fitzgerald (1998) buscaram uma forma de extrair o componente cíclico das séries temporais econômicas para melhor compreensão do comportamento desses ciclos. Desse modo, em 1998, os economistas Lawrence J. Christiano e Terry J. Fitzgerald publicaram um artigo intitulado "*The Band Pass Filter*", no qual apresentaram uma abordagem para identificar os ciclos econômicos por meio de um filtro. O filtro em

questão é usado para decompor séries temporais econômicas em diferentes componentes, permitindo isolar o comportamento cíclico em determinados intervalos de frequência, e assim é possível reter apenas as flutuações que ocorrem em uma determinada faixa de frequência, descartando tanto as flutuações de alta frequência (ruído) quanto as de baixa frequência (tendências de longo prazo). Dessa forma, o filtro ajuda a destacar as oscilações que correspondem ao comportamento cíclico das séries econômicas. A abordagem de Christiano e Fitzgerald (1998) tornou-se uma ferramenta importante para economistas e pesquisadores interessados em estudar e analisar os ciclos econômicos e sua relação com outras variáveis macroeconômicas, e continua sendo aplicada em diversas áreas da economia, como a política monetária, a previsão econômica e a análise de ciclos de negócios, ajudando a aprimorar a compreensão dos movimentos econômicos e as implicações de políticas econômicas em diferentes estágios do ciclo.

Hornstein (2000) explica que o comovimento pode ser observado em uma ampla variedade de medidas de atividade, como produção, valor agregado, emprego, serviços de capital ou insumos intermediários. Desse modo, o autor conjectura que perturbações agregadas às quais todos os setores da economia respondem da mesma forma explicam o ciclo econômico, e aponta para a política monetária, como uma das principais fontes do ciclo econômico, por afetar todos os setores da economia. No entanto, nessa análise não está claro que todas as indústrias de uma economia responderão da mesma maneira a uma perturbação agregada.

Em seu trabalho Shea (2002) explora as razões por trás da tendência de diferentes setores econômicos a se movimentarem juntos (comovimento) no curto prazo. Ele argumenta que essa comovimentação pode ser atribuída a duas principais fontes: choques comuns que afetam múltiplos setores e a presença de relações complementares que propagam impactos de choques de um setor para outro. O estudo concentra-se na indústria de manufatura dos Estados Unidos no período pós-guerra e examina a relevância de três fatores: as interconexões insumo-produto entre os setores, os efeitos de contágio da atividade econômica agregada e os efeitos de contágio da atividade econômica em nível local. A pesquisa revela que as interconexões insumo-produto e os contágios locais desempenham um papel significativo na comovimentação entre os setores da manufatura. Em contraste, os efeitos de contágio da atividade econômica agregada não são considerados um fator relevante. Além disso, o estudo destaca a importância dos contágios locais,

demonstrando que eles podem explicar uma parcela substancial, que varia entre 15% e 36%, da volatilidade do emprego na indústria de manufatura. Isso indica que os choques locais têm um impacto considerável na dinâmica do emprego nesse setor.

DiCecio (2009) investiga como diferentes setores da economia se movem juntos durante o ciclo econômico a partir das correlações contemporâneas, de avanço e defasagem entre os dados econômicos de diversos setores. Uma das principais questões tratadas no estudo é se os setores da economia tendem a se mover em conjunto durante o ciclo econômico ou se suas dinâmicas são mais independentes. Para isso, o autor analisa dados setoriais e busca identificar se os choques econômicos afetam todos os setores de forma semelhante ou se existem diferenças significativas em suas respostas. Os resultados do estudo fornecem *insights* importantes para entender a interconexão entre os setores econômicos e como eles reagem a choques econômicos.

Os estudos até aqui retratados abordam sobre o desempenho setorial, todavia as medições de comovimento entre os setores econômicos são relativamente escassas e um tanto limitadas aos setores industriais, provavelmente pela escassez de técnicas para medir tal comovimento. Nesse contexto, Cassou e Vázquez (2014) buscaram investigar correlações contemporâneas, bem como correlações de avanço e defasagem entre dados econômicos para uma variedade de horizontes de previsão. Para os autores a abordagem de avanço/defasagem fornece uma visão mais abrangente das dinâmicas econômicas que geram os dados e permite investigar quais variáveis lideram ou seguem outras, e se o padrão de avanço ou atraso é de curto ou longo prazo. Essa técnica é aplicada a dados mensais de emprego em nível setorial para os Estados Unidos e mostra que, entre os dez setores industriais, seis tendem a liderar os outros quatro. Esses seis setores têm correlações altas, o que indica que os choques estruturais que geram os movimentos dos dados são em sua maioria comuns. Entre as quatro indústrias que ficam para trás, algumas têm atrasos maiores do que outras e algumas têm baixas correlações com as indústrias líderes. A conclusão desse estudo é que essas baixas correlações podem indicar que essas indústrias são parcialmente influenciadas por choques estruturais além daqueles que geram os seis setores líderes, mas também podem indicar que os setores defasados apresentam um mecanismo de transmissão de choques diferente.

Desse modo, estudar o comportamento dinâmico de variáveis setoriais pode ser fundamental para responder questões sobre flutuações cíclicas. Embora exista

técnicas econométricas importantes para analisar séries temporais, quando temos um amplo número de setores modelos como *Vector Autoregressive* (VAR) não são apropriados para tal propósito, devido a necessidade de estimar muitos parâmetros. E foi nesse contexto, surgiu a necessidade de novos métodos que permitem a redução do espaço de parâmetros.

Assim, em busca de superar o problema de alta parametrização Bollerslev (1990) propõe um modelo multivariado de séries temporais com variâncias e covariâncias condicionais variáveis no tempo, mas correlações condicionais constantes. O autor propõe uma parametrização que represente uma grande diminuição na complexidade computacional, supondo que a matriz de covariância que varia no tempo seja positivamente definida. Vale destacar que, desde o início dos anos 80, quando os primeiros modelos de volatilidade foram formulados, tem tido muitos esforços para estimar modelos multivariados. Um dos primeiros modelos GARCH multivariados foi proposto por Bollerslev, Engle e Wooldridge (1988) como uma generalização direta do modelo GARCH univariado, o modelo VEC. As especificações desses modelos foram desenvolvidas ao longo dos últimos anos com uma série de artigos pesquisados por Bollerslev, Engle e Nelson (1994), por Bauwens, Laurent e Rombouts (2006) e Silvennoinen e Terasvirta (2008). Uma conclusão geral dessa análise é que é difícil estimar modelos GARCH multivariados com mais 6 séries de retorno porque as especificações são muito complicadas.

Engle (2002) propôs uma nova classe de estimador que preserva a facilidade de estimativa do modelo de correlação constante de Bollerslev (1990), mas permite que as correlações mudem ao longo do tempo. Esses estimadores de correlação condicional dinâmica (DCC) têm a flexibilidade do GARCH univariado, mas não a complexidade do GARCH multivariado convencional, e assim apresenta vantagens computacionais sobre os modelos GARCH multivariados, uma vez que, o número de parâmetros a serem estimados no processo de correlação é independente do número de séries a serem correlacionadas. Assim, matrizes de correlação potencialmente muito grandes podem ser estimadas. Assim, ao considerar a volatilidade variável no tempo é possível distinguir se as correlações mais altas são devidas a uma volatilidade mais alta ou a um comovimento mais forte das variáveis.

É importante mencionar que este trabalho se baseia na metodologia empregada por Sandqvist (2017) em seu estudo sobre comovimento setorial entre os setores de manufatura nos Estados Unidos e na Alemanha. Tal estudo emprega uma

estrutura multivariada DCC-GARCH, introduzida por Engle e Sheppard (2001) e Engle (2002), para estudar as correlações variáveis no tempo das taxas de crescimento da produção industrial entre os setores de manufatura nos Estados Unidos e na Alemanha. Os resultados apontam que a variância do crescimento da produção industrial nos setores de manufatura nos Estados Unidos tende a ser assimétrica, ou seja, a maioria das indústrias reage de forma mais intensa a choques desfavoráveis do que favoráveis. No entanto, há evidências limitadas de assimetrias nas correlações, o que mostra que a maioria dos pares de setores reagem de forma semelhante a choques comuns, independentemente do sinal dos choques. A autora também mostra que as correlações parecem ter aumentado consideravelmente durante algumas desacelerações econômicas, especialmente durante a recessão em 2007–2009, mas também há períodos recessivos nos quais o comovimento quase não muda, o que indica que as contrações tendem a ser mais sincronizadas do que as expansões no setor manufatureiro. No geral, o padrão das flutuações e o nível de correlação condicional média são bastante semelhantes tanto nos Estados Unidos quanto na Alemanha.

Sandqvist (2017) também faz uma análise de regressão econométrica com o intuito de examinar quais fatores agregados são relevantes para o comovimento setorial, cujos resultados indicam que, nos Estados Unidos, o índice do mercado de ações e a confiança empresarial estão relacionados ao comovimento setorial. Especialmente em tempos de pessimismo, as decisões de produção setorial são mais semelhantes do que em períodos de altas expectativas. A volatilidade do mercado de ações também desempenha um papel, implicando maiores correlações em momentos de alta volatilidade. No entanto, para a Alemanha, apenas a volatilidade do mercado de ações mostrou ter um impacto significativo nas correlações setoriais

Os modelos de Engle (2002) e Bollerslev (1990) conseguiram superar o problema de alta parametrização ao optar por uma estrutura de modelo mais simples, cujas interdependências entre variâncias e entre correlações deixam de ser uma questão relevante. Portanto, nesse trabalho iremos focar no modelo DCC-GARCH, de Engle (2002), por considerar mudança na correlação ao longo do tempo, embora haja a necessidade de estimar tais correlações, uma vez que não são passíveis de serem observadas.

2.2 ÍNDICE DE CONFIANÇA

Sabemos que a confiança empresarial possui um papel importante nas escolhas dos agentes econômicos, e por isso no contexto acadêmico esse tema tem sido alvo de discussão, uma vez que, tal tema no contexto econômico remete em como os fatores psicológicos podem ter influência nas decisões dos agentes, e é nesse pilar que as pesquisas sobre confiança se desenvolvem.

Bovi (2009) corrobora ao mencionar que existem várias razões para abordar os dados de Pesquisas de Confiança do Consumidor (PCC), à luz da psicologia cognitiva, uma vez que, vieses psicológicos permanentes e generalizados afetam tanto a probabilidade subjetiva de eventos econômicos futuros quanto a sua interpretação retrospectiva. Eles podem dar origem a uma lacuna sistemática entre julgamentos excessivamente críticos e expectativas excessivamente otimistas - o "erro de previsão". Quando as coisas ficam ruins, a psicologia sugere que as pessoas tendem a se tornar particularmente otimistas, amplificando o erro de previsão.

Desse modo, o mesmo autor faz uma tentativa de realizar análises empíricas das diferenças entre as expectativas ex ante e as percepções ex post sobre as condições econômicas gerais. Essas previsões não são baseadas em estatística ou fato, e as lacunas entre julgamentos e expectativas podem ser bem interpretadas por meio de argumentos psicológicos, sendo possível que sejam respostas tendenciosas.

Resende e Zeidan (2015), inspirados em Bovi (2009), investigaram possíveis vieses psicológicos em relação às expectativas dos representantes das empresas. O objetivo dos autores é avaliar a presença de vieses psicológicos nas expectativas das empresas sobre as condições econômicas gerais e a condição da empresa, avaliando as discrepâncias entre as avaliações ex-post e as expectativas ex-ante. As evidências, no caso das percepções das condições econômicas gerais, indicam a presença de vieses psicológicos importantes nas expectativas dos representantes das empresas, mesmo quando eles têm o incentivo de coletar informações custosas.

Existe um efeito causal entre a confiança do consumidor e das empresas, e as flutuações no nível de atividade econômica, que se configuram em uma variedade de modelos dinâmicos de equilíbrio geral que incorporam a opinião dos agentes econômicos, e conseqüentemente, um declínio na confiança do consumidor ou da empresa pode causar um declínio na produção, *ceteris paribus*. Potter (1999) sugere que as assimetrias do ciclo econômico encontradas nos dados dos EUA do pós-guerra são inconsistentes com as tendências da economia durante a Grande Depressão, e

isso se deve ao papel que a política do governo desempenhou em influenciar a confiança. O autor argumenta que a inércia da política governamental durante a Grande Depressão gerou uma queda na confiança, enquanto o sucesso da política de estabilização do pós-guerra levou a um aumento confiança, ou seja, para o autor seria essa a explicação para as assimetrias encontradas no ciclo dos últimos anos.

Nesse sentido, o poder preditivo dos indicadores de confiança é examinado amplamente na literatura a fim de investigar se eles são capazes de prever desacelerações econômicas, ou seja, a confiança pode ter um papel preditivo para a economia de modo a antecipar recessões. Batchelor e Dua (1998) viram que os economistas não foram capazes de prever a recessão americana de 1991, utilizando variáveis macroeconômicas padrão em seus modelos, como o gasto com consumo e o PIB, e por isso tais autores decidiram investigar o papel da confiança do consumidor nesse contexto e de eu forma os indicadores de confiança teriam melhorado as previsões econômicas anteriores. Seus resultados mostram que a incorporação de informações sobre a confiança do consumidor teria melhorado as previsões ao antecipar a recessão de 1991 nos Estados Unidos, por outro lado, os autores não são tão otimistas sobre o valor mais geral dos indicadores de confiança do consumidor na previsão da atividade do ciclo de negócios, uma vez que, os indicadores de confiança do consumidor não teriam previsto com precisão outros episódios significativos do ciclo econômico.

Vale ressaltar que inúmeros estudos são mistos e inconclusivos ao explorar a importância do Índice de Confiança do Consumidor (ICC) na previsão dos gastos com consumo privado, assim, enquanto alguns estudos apontam que a confiança dos consumidores na economia contribui significativamente para a previsão dos gastos dos consumidores, outros estudos apresentam evidências de que o ICC pode melhorar a previsão de consumo a curto prazo em uma extensão limitada, ou é completamente ineficaz na explicação dos padrões de consumo futuros, conforme afirma Paradiso et al (2014). Esses achados corroboram com a abordagem de viés psicológico de Bovi (2009).

Conforme foi mencionado anteriormente, existe uma quantidade substancial de pesquisas acadêmicas focadas em descobrir se o sentimento do consumidor e do empresário possui ou não algum poder preditivo em relação ao crescimento dos gastos de consumo das famílias ou no investimento por parte das empresas. Por exemplo, Gausden (2016) afirma que é possível concluir que o acesso a dados sobre

a medida agregada de confiança do consumidor da UE poderia melhorar as previsões do crescimento das despesas das famílias do Reino Unido no intervalo, 2008-2013. Da mesma forma, Taylor e McNabb (2007) examinam se os indicadores de confiança do consumidor e das empresas podem prever os movimentos do PIB ao longo do ciclo de negócios para quatro economias europeias, e os resultados mostram que os indicadores de confiança do consumidor e do empresário são pró-cíclicos e geralmente desempenham um papel significativo na previsão de desacelerações.

Sob a ótica do Índice de Confiança Empresarial, é possível relacioná-lo com o comportamento de variáveis macroeconômicas, conforme afirma Bezerra (2017), que propõe a criação do Índice de Incerteza Empresarial (IIE) para o Brasil, com microdados das Sondagens Empresariais, calculadas pelo FGV/IBRE. Utilizando a metodologia de Vetores Autorregressivos (VAR), tal autor apresenta resultados que mostram que a incerteza influencia no comportamento do Índice de Atividade Econômica, Produção Física da Indústria e na Taxa de Desemprego. Del Rio (2005) corrobora ao evidenciar a natureza exógena da confiança bem como a sua influência significativa na evolução de uma das principais variáveis macroeconômicas, o nível de desemprego.

Da mesma forma, Massenot e Pettinicchi (2018) apresentam novas evidências sobre o processo de formação de expectativas das empresas, que entra no índice de confiança econômica, tornando-se um importante determinante de suas decisões de emprego e investimento, onde as empresas podem se tornar pessimistas durante uma crise, atrasando assim a recuperação. Desse modo, as empresas parecem ser excessivamente otimistas antes das recessões e excessivamente pessimistas durante as recessões. Ao analisar os dados individuais, os autores afirmam que os erros de expectativa são, de fato, positivamente correlacionados com a atividade empresarial passada. Isso confirma que as empresas extrapolam demais sua experiência e comete erros de previsão. Os resultados sugerem que as empresas estão excepcionalmente otimistas pouco antes de uma desaceleração e excepcionalmente pessimistas antes de uma recuperação. Isso implica que as empresas parecem não antecipar as próximas reversões e que os ciclos podem ser amplificados se as expectativas forem seguidas por mudanças no investimento ou no emprego. Bachmann (2015) corrobora ao mostrar que as empresas sistematicamente superestimam ou subestimam sua produção futura um quarto à frente, e esses vieses de expectativa levam a má alocação de fatores, que causam perdas de bem-estar

que, na pior das hipóteses, são comparáveis às estimativas convencionais dos custos de bem-estar das flutuações dos ciclos econômicos.

Vale mencionar que é possível relacionar medidas de confiança do consumidor e do investido com o retorno de ações, conforme fez Lemmon (2016) e Ciner (2014). Desse modo, com o intuito de relacionar a confiança do investidor e o prêmio das ações, Lemmon (2016) conclui que a confiança do investidor (medido com base na confiança do consumidor) prevê os retornos de ações pequenas e ações com baixa propriedade institucional de forma consistente. Já Ciner (2014) examinou o impacto das medidas de confiança do consumidor nos retornos futuros do índice de ações, e mostra que existe uma relação variável no tempo entre a confiança do consumidor e os retornos das ações. Níveis mais elevados de confiança do consumidor implicam maiores retornos no curto prazo, mas retornos negativos no médio prazo. No entanto, este efeito só é observado para o índice de pequenas empresas. Além disso, há evidências nesse estudo que sugerem que a confiança do consumidor é significativamente afetada pelos retornos das ações em causalidade reversa.

Coibion et al. (2018) realizaram uma pesquisa sobre as crenças macroeconômicas das empresas na Nova Zelândia, e perceberam que há uma dispersão generalizada nas crenças das empresas sobre as condições macroeconômicas passadas e futuras, especialmente em relação a inflação, pois as crenças médias sobre a inflação recente e passada tem sido muito mais altas do que as de analistas profissionais. Grande parte da dispersão nas crenças pode ser explicada pelos incentivos das empresas para coletar e processar informações, ou seja, motivos racionais de desatenção. Usando métodos experimentais, os autores descobriram que as empresas atualizam suas crenças de maneira bayesiana quando são apresentadas a novas informações sobre a economia. Os autores encontraram evidências sistemáticas de que a qualidade das informações das empresas sobre as condições macroeconômicas reflete em parte seus incentivos para rastrear e processar essas informações.

Júnior et al. (2009) analisam os resultados do índice de confiança do empresário de pequenos e médios negócios no Brasil (IC-PMN) concernente ao último trimestre de 2008 e no primeiro e segundo trimestre de 2009. No último trimestre de 2008, o índice em questão conseguiu captar adequadamente o impacto da crise econômica global, já no primeiro semestre de 2009 houve uma queda significativa no

índice. Já no segundo trimestre de 2009 o resultado mostrou uma recuperação da confiança do empresariado, reflexo da atenuação do impacto da crise. Os autores também fazem análise dos gráficos da evolução do PIB, produção industrial e consumo, o que indica que o IC-PMN apresenta uma relação com essas variáveis macroeconômicas e que há uma evidência que o índice antecede movimentos do PIB e é coincidente com movimentos do consumo e produção industrial.

Hofmann (2012) tem como sua meta principal a análise do comportamento dos níveis de confiança manifestados por consumidores e empresários da indústria brasileira em relação às flutuações de um conjunto específico de indicadores situacionais. Esses indicadores refletem as condições do cenário empresarial no qual ambos os grupos estão inseridos. Para atingir esse objetivo, são levados em conta, no que diz respeito à conduta do Índice de Confiança do Consumidor (ICC), a trajetória dos indicadores de emprego, renda e inflação. Já no contexto do Índice de Confiança do Empresário Industrial (ICEI), são considerados o Índice de Preços ao Produtor Amplo para bens industriais (IPA origem - produtos industriais), o Índice de Vendas do Setor Industrial, a taxa de câmbio efetiva real (INPC-exportações de produtos manufaturados) e a Contribuição Social sobre o Lucro Líquido (CSLL), sendo um substituto para a avaliação do lucro empresarial. Com relação ao comportamento do ICC, o autor verificou que as flutuações nos indicadores de preços parecem exercer mais influência na confiança dos consumidores do que as variáveis de renda e emprego. No que diz respeito ao ICEI, o movimento de crescimento constante do IPA, mantido ao longo de toda a duração observada, esteve ligado à queda contínua na confiança por parte dos empresários, por outro lado, não se verificou uma associação clara com as outras variáveis consideradas na avaliação do ICEI.

Não obstante, pode haver situações em que não é mais possível formar expectativas sobre eventos futuros, e tal contexto é conhecido como incerteza Knightiana. Nesse sentido, Dibiasi e Iselin (2021) propõem um método para medir diretamente a incerteza Knightiana, que se baseia em dados em nível de empresa e mede a parcela dessas que não formalizaram as expectativas sobre sua demanda futura. Os autores criaram um indicador de Incerteza Knightiana para a Suíça com o intuito de identificar momentos de alta incerteza. Desse modo, a fim de avaliar sua relevância para a economia real, os autores examinaram o efeito de um choque de incerteza Knightiano no investimento e concluíram que um choque de um desvio padrão leva a uma redução negativa e persistente do investimento.

3. METODOLOGIA ECONOMÉTRICA

3.1 MODELO ECONOMÉTRICO

O modelo escolhido para estimar a correlação condicional dos Índices de Confiança do Empresário Industrial (ICEI) é o modelo de Correlação Condicional Dinâmica (DCC-GARCH) de Engle (2002). Trata-se de um modelo introduzido por Engle (2002) que propõe estimadores de correlação condicional dinâmica (DCC) que possuem a flexibilidade do GARCH univariado, mas não a complexidade do GARCH multivariado convencional. Esses modelos, que parametrizam diretamente as correlações condicionais, são naturalmente estimados em duas etapas uma série de estimativas GARCH univariadas e a estimativa de correlação. Para o autor, esses métodos apresentam vantagens computacionais claras sobre os modelos GARCH multivariados, uma vez que o número de parâmetros a serem estimados no processo de correlação é independente do número de séries a serem correlacionadas.

Desse modo, com o intuito de contextualizar as características do modelo escolhido, justificando, portanto, sua escolha, iremos iniciar essa seção apresentando os modelos GARCH multivariados. Nas seções seguintes iremos abordar o modelo DCC-GARCH e alguns de seus desdobramentos e extensões.

3.1.1 Modelos multivariados

Vamos partir de um processo estocástico vetorial $\{y_t\}$ de dimensão $N \times 1$ e I_{t-1} é gerado pela informação passada até o tempo $t-1$. Além disso, temos um vetor θ finito de parâmetros:

$$y_t = \mu_t(\theta) + \varepsilon_t \quad (1)$$

Onde $\mu_t(\theta)$ é a média condicional do vetor e

$$\varepsilon_t = H_t^{1/2}(\theta)z_t \quad (2)$$

Onde $H_t^{1/2}$ é uma matriz definida positiva $N \times N$. Além disso, seja z_t um vetor aleatório $N \times 1$:

$$E(z_t) = 0 \quad (3)$$

$$Var(z_t) = I_n \quad (4)$$

onde I_n é a matriz identidade de ordem N . Assim, calculamos a matriz de variância condicional de y_t :

$$\begin{aligned} Var(y_t|I_{t-1}) &= Var_{t-1}(y_t) = Var_{t-1}(\varepsilon_t) \quad (5) \\ &= H_t^{1/2}Var_{t-1}(z_t)\left(H_t^{1/2}\right) \end{aligned}$$

$$= H_t$$

Desse modo, temos que $H_t^{1/2}$ é qualquer matriz NxN positiva definida de forma que H_t é a matriz de variância condicional de y_t , ou seja, $H_t^{1/2}$ pode ser obtido pela fatoração de Cholesky de H_t .

Segundo Ghalanos (2022) a literatura sobre as diferentes especificações de H_t pode ser amplamente dividida em extensões multivariadas diretas, modelos fatoriais e modelos de correlação condicional. O *trade-off* entre a parametrização e a dimensionalidade do modelo se aplica nesse contexto, pois obter uma dinâmica mais rica se dá ao custo de aumentar o tamanho do parâmetro, o que torna inviável modelar qualquer coisa além de alguns ativos.

Vale mencionar que os modelos VEC (Vector Error Correction) são frequentemente usados para analisar séries temporais não estacionárias, e os modelos BEKK (Baba, Engle, Kraft e Kroner) são usados na modelagem de volatilidade condicional em séries temporais financeiras. Já os modelos fatoriais são utilizados para descompor a variação conjunta de um conjunto de séries temporais em fatores comuns e idiossincráticos. Desse modo, Bauwens et al (2006) faz uma revisão das diferentes especificações do H_t que podem diferir em vários aspectos. Esses autores dividem em três abordagens, não mutuamente exclusivas, a construção de modelos GARCH multivariados; (i) generalizações diretas do modelo GARCH univariado de Bollerslev (1986); (ii) combinações lineares de modelos GARCH univariados; (iii) combinações não lineares de modelos GARCH univariados. Os modelos VEC, BEKK e fatoriais estão na primeira categoria. Bollerslev et al (1988) propôs uma formulação geral de H_t para os Modelos VEC e BEKK.

Um problema apontado pelos mesmos autores consiste no fato de que quando consideramos modelos GARCH multivariados, como extensões diretas do modelo GARCH univariado, o número de parâmetros aumenta rapidamente. Além disso, uma vez que H_t é uma matriz de variância, a definição positiva precisa ser garantida.

Desse modo, o modelo VEC (1,1) pode ser definido da seguinte forma:

$$h_t = c + A\eta_{t-1} + Gh_{t-1} \quad (6)$$

Onde

$$h_t = VEC(H_t) \quad (7)$$

$$\eta_t = VEC(\varepsilon_t \varepsilon_t^T) \quad (8)$$

Onde, $VEC(\cdot)$ denota o operador que empilha a porção triangular inferior de uma matriz $N \times N$ como um vetor $N(N+1)/2 \times 1$. A e G são matrizes quadradas de parâmetros de ordem $(N+1)N/2$ e c é um vetor de parâmetros $(N+1)N/2 \times 1$.

Bauwens et al (2006) mostram que o número de parâmetros desse modelo é $N(N+1)(N(N+1)+1)/2$, assim, se temos $N=3$ então o número de parâmetros a ser estimado é igual a 78, ou seja, ocorre uma super parametrização onde o modelo só se torna viável no caso bivariado. Assim, no modelo VEC geral, cada elemento de H_t é uma função linear dos erros quadrados defasados e produtos cruzados de erros e valores defasados dos elementos de H_t .

Com o intuito de superar esse problema, Bollerslev et al (1988) sugerem algumas suposições simplificadoras. Desse modo, a proposta seria um modelo diagonal VEC (DVEC), onde teremos as matrizes A e G como diagonais, e cada elemento h_{ijt} depende apenas de sua própria defasagem e do valor anterior de $\varepsilon_{it}\varepsilon_{jt}$. Desse modo, temos uma redução no número de parâmetros para $N(N+5)/2$. Apesar dessa hipótese de diagonalização, o problema de alta parametrização ainda permanece em sistemas de grande escala, tornando-se, portanto, difíceis de serem estimados. Além disso, conforme mostra Bauwens et al (2006), é difícil garantir a positividade de H_t na representação VEC sem impor fortes restrições aos parâmetros.

Engle e Kroner (1995) propõem uma nova parametrização para H_t de forma a garantir sua positividade, ou seja, o modelo em questão é o BEKK, como veremos a seguir.

O modelo BEKK(1,1,K) é definido como:

$$H_t = C^{*T} C^* + \sum_{k=1}^k A_k^{*T} \varepsilon_{t-1} \varepsilon_{t-1}^T A_k^* + \sum_{k=1}^k G_k^{*T} H_{t-1} G_k^* \quad (9)$$

aqui C^* , A_k^* e G_k^* são matrizes $N \times N$, mas C^* é triangular superior. O modelo BEKK é um caso especial do modelo VEC. Para um modelo BEKK(1,1,1), o número de parâmetros no modelo seria $N(5N+1)/2$, o que seria um modelo com 24 parâmetros. Uma alternativa para reduzir esse número é impor um modelo BEKK diagonal, e, conseqüentemente, para reduzir a generalidade. Todavia, permanece a dificuldade em estimar um modelo VEC ou mesmo BEKK devido seu alto número de parâmetros desconhecidos, mesmo após a imposição de diversas restrições. Desse modo, em termos práticos, fica inviável usar esses modelos quando o número de séries é maior que 3 ou 4. Os modelos fatoriais e ortogonais superam esse problema

de parametrização ao impor uma estrutura dinâmica comum a todos os elementos de H_t .

Orskaug (2009) corrobora ao afirmar que existem muitas especificações possíveis de H_t , uma vez que os parâmetros nas matrizes de covariância condicional aumentam muito rapidamente à medida que a dimensão aumenta. Desse modo, como H_t é dependente do tempo t , é necessário invertê-lo em cada iteração, o que torna o cálculo exigente, a menos que o número de parâmetros seja pequeno. Essa é a principal dificuldade na estimação dos modelos e, portanto, é importante no processo de construção dos modelos MGARCH, ter como objetivo torná-los parcimoniosos o suficiente, sem perder a flexibilidade. Da mesma forma, é essencial garantir que a matriz de covariância condicional seja definida positiva.

As diferentes especificações dos modelos MGARCH podem ser divididas em quatro categorias:

I. **Modelos da matriz de covariância condicional:** nesta classe a matrizes condicional de covariância, H_t , são modelados diretamente. Esta classe inclui o VEC e Modelos BEKK. Esses modelos estavam entre os primeiros modelos MGARCH paramétricos.

II. **Modelos fatoriais:** a ideia de modelos fatoriais vem da teoria econômica. Nesta classe as matrizes de covariância condicional são motivadas pela parcimônia. Supõe-se que o processo at seja gerado por um (pequeno) número de fatores heterocedástico não observados, portanto, esses modelos são chamados de modelos de fatores. Esses fatores podem ser estudados e pode-se supor que algumas características dos dados são capturadas, semelhante à análise de componentes principais. Essa abordagem tem a vantagem de reduzir a dimensionalidade do problema quando o número de fatores relativos à dimensão do vetor de retorno em é pequeno.

III. **Modelos de variâncias condicionais e correlações:** os modelos desta classe são construídos sobre a ideia de modelar as variâncias e correlações condicionais em vez da modelagem direta da matriz de covariância condicional. Um modelo específico desta classe é o DCC- GARCH.

IV. **Abordagens não paramétricas e semiparamétricas:** os modelos desta classe formam uma alternativa à estimação paramétrica da estrutura de covariância condicional. A vantagem desses modelos é que eles não impõem uma estrutura particular (que pode ser especificado incorretamente) nos dados.

Como o DCC-GARCH pertence à classe dos modelos de variâncias condicionais e correlações, vamos dar ênfase para essa classe. Os modelos nesta classe são construídos com a ideia de modelar as variâncias e correlações condicionais em vez de modelar diretamente a matriz de covariância condicional. Desse modo, a matriz de covariância condicional pode ser decomposta em desvios padrão condicionais e uma matriz de correlação como:

$$H_t = D_t R_t D_t \quad (10)$$

onde $D_t = \text{diag}(h_{1t}^{1/2}, \dots, h_{nt}^{1/2})$ é o desvio padrão condicional, e R_t é a matriz de correlação. Os modelos da matriz de correlação podem ser constantes ou variável no tempo.

3.1.2 Modelo DCC- GARCH

Como veremos mais à frente, várias generalizações e estudos teóricos do modelo de Engle (2002) foram desenvolvidos. Esses trabalhos focam tanto no desenvolvimento de novas parametrizações quanto em seu uso em aplicações empíricas, demonstrando uma alta capacidade de adaptação a problemas práticos. Com o intuito de dar visão geral da generalização do modelo de Engle (2002), iremos iniciar falando do modelo *Constant Conditional Correlation* (CCC-GARCH) de Bollerslev (1990), por ser o ponto de partida para a análise de modelos de correlação dinâmica. A matriz de correlação condicional é invariante no tempo, ou seja, $R_t = R$. Portanto:

$$H_t = D_t R D_t \quad (11)$$

A matriz de correlação, $R = [\rho_{ij}]$, é positiva definida com $\rho_{ij} = 1$, $i = 1, \dots, n$. Os elementos fora da diagonal da matriz de covariância condicional, H_t , são dados por:

$$[H_t]_{ij} = h_{it}^{1/2} h_{jt}^{1/2} \rho_{ij}, \quad i \neq j \quad (12)$$

O processo $\{\alpha_{it}\}$ é modelado como GARCH univariado. Portanto, as variâncias condicionais podem ser escritas em uma forma vetorial:

$$h_t = c + \sum_{j=1}^q A_j \alpha_{t-j}^{(2)} + \sum_{j=1}^p B_j h_{t-j} \quad (13)$$

onde c é $n \times 1$ vetor, A_j e B_j são matrizes diagonais $n \times n$, e $\alpha_{t-j}^{(2)} = \alpha_{t-j} \odot \alpha_{t-j}$ é o produto de elemento por elemento. Isso garante que seja definida positiva quando os elementos c , A_j e B_j são positivos, já que R é definido positivo.

Embora a estimação de modelos nesta classe seja computacionalmente atraente por representar uma correlação de matriz constante, não é possível supor que as correlações não são estáveis por longos períodos. Desse modo, por ser muito restritivo em alguns casos, o CCC-GARCH pode ser generalizado ao assumir que a matriz de correlação varia com o tempo. Logo, Engle (2002) introduziu uma dinâmica nas correlações para superar a limitação encontrada em tal modelo.

Engle (2002) apresenta uma nova classe de estimadores GARCH multivariados que, conforme afirmamos, podem ser melhor vistos como uma generalização do estimador de Correlação Condicional Constante (CCC-GARCH). Quando a matriz de correlação, R_t , é variável no tempo, H_t é positivamente definido se R_t for positivamente definida em cada ponto no tempo e as variâncias condicionais, h_{it} , $i = 1, \dots, n$ forem bem definidas. Comparado ao modelo CCC-GARCH, a vantagem da estimativa numericamente simples é perdida, pois a matriz de correlação deve ser invertida para cada tempo, t , durante cada iteração. Sandqvist (2017) afirma que as expressões para h são tipicamente pensadas como modelos GARCH univariados; entretanto, esses modelos certamente poderiam incluir funções de outras variáveis do sistema como variáveis predeterminadas ou exógenas. Uma estimativa simples de R é a matriz de correlação incondicional dos resíduos padronizados. Desse modo, o modelo de correlação dinâmica difere apenas em permitir que R seja variável no tempo:

$$H_t = D_t R_t D_t \quad (14)$$

A matriz de covariância, H_t , pode ser decomposta em desvios padrão condicionais, D_t , e uma matriz de correlação, R_t . Logo, o modelo DCC-GARCH, tanto D_t quanto R_t são projetados para serem variáveis no tempo. Assim, supondo que tenhamos retornos, α_t , de n ativos com valor esperado 0 e matriz de covariância H_t . Então o modelo GARCH de Correlação Condicional Dinâmica (DCC- GARCH) é definido como:

$$r_t = \mu_t + \alpha_t \quad (15)$$

$$\alpha_t = H_t^{1/2} z_t \quad (16)$$

$$H_t = D_t R_t D_t \quad (17)$$

Onde, r_t é um vetor de log $n \times 1$ com retornos de n ativos no tempo t , α_t é um vetor de retornos $n \times 1$ corrigidos pela média de n variáveis no tempo t , ou seja, $E(\alpha_t) = 0$ e $COV(\alpha_t) = H_t$. μ_t é um vetor $n \times 1$ do valor esperado da condicional r_t . H_t é uma

matriz $n \times n$ de variâncias condicionais de α_t no tempo t . $H_t^{1/2}$ pode ser obtido por uma fatoração de Cholesky de H_t . D_t é uma matriz diagonal $n \times n$ de desvios padrão condicionais de α_t no tempo t . R_t é uma matriz $n \times n$ de correlação condicional no tempo t . z_t é um vetor $n \times 1$ de erros independentes e identicamente distribuídas tal que $E(z_t) = 0$ e $COV(z_t z_t^T) = I$. μ_t pode ser modelado como um vetor constante ou um modelo de série temporal. Como no caso univariado, α_t não é correlacionado no tempo.

Os elementos na matriz diagonal D_t são desvios padrão de modelos GARCH univariados

$$D_t = \begin{bmatrix} \sqrt{h_{1t}} & 0 & \dots & 0 \\ 0 & \sqrt{h_{2t}} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \sqrt{h_{nt}} \end{bmatrix}$$

Onde,

$$h_{it} = \alpha_{i0} + \sum_{q=1}^{Q_i} \alpha_{iq} a_{i,t-q}^2 + \sum_{j=1}^{P_i} \beta_{ip} h_{i,t-p} \quad (18)$$

R_t é a matriz de correlação condicional dos erros padronizados ϵ_t , ou seja:

$$\epsilon_t = D_t^{-1} a_t \sim N(0, R_t) \quad (19)$$

Como R_t é uma matriz de correlação, então ela é simétrica.

$$R_t = \begin{bmatrix} 1 & \rho_{12,t} & \rho_{13,t} & \dots & \rho_{1n,t} \\ \rho_{12,t} & 1 & \rho_{23,t} & \dots & \rho_{2n,t} \\ \rho_{13,t} & \rho_{23,t} & 1 & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \rho_{n-1,n,t} \\ \rho_{1n,t} & \rho_{2n,t} & \dots & \rho_{n-1,n,t} & 1 \end{bmatrix}$$

Os elementos de $H_t = D_t R_t D_t$ é:

$$[H_t]_{ij} = \sqrt{h_{it} h_{jt}} \rho_{ij} \quad (20)$$

Onde $\rho_{ii} = 1$

Orskaug (2009) afirma que para especificar uma forma de R_t , dois requisitos devem ser considerados:

1. H_t tem que ser definida positiva por ser uma matriz de covariância, para isso R_t também deve ser positivamente definida (D_t é positivamente definida, pois todos os elementos diagonais são positivos).

2. Por definição, Todos os elementos na matriz de correlação R_t devem ser iguais ou menores que um.

Para garantir esses dois requisitos no modelo DCC-GARCH, R_t é decomposto em:

$$R_t = Q_t^{*-1} Q_T Q_t^{*-1} \quad (21)$$

$$Q_t = (1 - a - b) \bar{Q} + a \epsilon_{t-1} \epsilon_{t-1}^T + b Q_{t-1} \quad (22)$$

Onde $\bar{Q} = cov[\epsilon_t \epsilon_t^T] = E[\epsilon_t \epsilon_t^T]$ é a matriz de covariância incondicional dos erros padronizados ϵ_t . \bar{Q} pode ser estimado como:

$$\bar{Q} = \frac{1}{T} \sum_{t=1}^T \epsilon_t \epsilon_t^T \quad (23)$$

Os parâmetros **a** e **b** são escalares, e Q_t^* é uma matriz diagonal com a raiz quadrada dos elementos diagonais de Q_t na diagonal:

$$Q_t^* = \begin{bmatrix} \sqrt{q_{11t}} & 0 & \cdots & 0 \\ 0 & \sqrt{q_{22t}} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sqrt{q_{nnt}} \end{bmatrix}$$

Q_t^* redimensiona os elementos em Q_t para garantir o segundo requisito; $|\rho_{ij}| = \left| \frac{q_{ijt}}{\sqrt{q_{iit}q_{jjt}}} \right| \leq 1$. Além disso, Q_t deve ser positivamente definida para garantir que R_t seja positivamente definida.

São impostas algumas condições aos parâmetros **a** e **b** para garantir que H_t seja definido positivo. Além das condições para o modelo GARCH univariado garantir variâncias incondicionais positivas os escalares **a** e **b** devem satisfazer:

$$a \geq 0, \quad b \geq 0, \quad a + b < 1$$

Além disso, para garantir que H_t seja positivamente definido, o valor inicial de Q_t (Q_0), tem que ser positivamente definido. Desse modo, a estrutura de correlação pode ser estendida ao modelo geral DCC(M,N)-GARCH:

$$Q_t = (1 - \sum_{m=1}^M a_m - \sum_{n=1}^N b_n) \bar{Q}_t + \sum_{m=1}^M a_m a_{t-1} a_{t-1}^T - \sum_{n=1}^N b_n Q_{t-1} \quad (24)$$

Vale ressaltar que o parâmetro **a** captura o efeito de novos impactos no processo de correlação, enquanto **b** é o parâmetro de suavização, desse modo, quanto mais próxima a soma de **a** e **b** estiver da unidade, mais forte será a persistência das correlações variantes no tempo.

Tse e Tsui (2001) fazem uma proposta muito semelhante ao modelo de Engle (2002), onde a única diferença está no termo $\epsilon_{t-1} \epsilon_{t-1}^T$ que é substituído por uma estimativa de correlação de curto prazo $m^{-1} \sum_j^m \epsilon_{t-j} \epsilon_{t-j}^T$, onde $m \geq K$. Os autores

propõem um novo modelo de heterocedasticidade condicional autorregressiva generalizada multivariada (MGARCH) com correlações variáveis no tempo, e adotam a representação VEC com base nas variâncias condicionais e nas correlações condicionais. Tal modelo busca reter a intuição e a interpretação do modelo GARCH univariado e ao mesmo tempo satisfazer a condição de positivamente definida dos modelos CCC-GARCH de Bollerslev (1990) e DCC-GARCH de Engle (2002).

Vale abrir um parêntese em relação ao modelo de Tse e Tsui (2002), no sentido de ressaltar seu caráter parcimonioso, uma vez que requer apenas dois parâmetros para introduzir dinâmica nas correlações, todavia, não há interdependência entre as variâncias, entre as correlações e entre as variâncias e as correlações. Além disso a dinâmica é constante em todas as correlações. Se passar o modelo DCC para modelos GARCH multivariados padrões, então podemos resolver o problema de não interdependência entre variâncias e covariâncias. Entretanto, como foi dito anteriormente, em sistemas com mais de 4 ou 5 variáveis os modelos BEKK e VEC apresentam sérios problemas de otimização que levam a estimativas de parâmetros instáveis e inconsistentes. Sandqvist (2017) corrobora ao explicar que no processo de estimar diretamente a matriz de covariância condicional o modelo BEKK, assim como o VEC, encontra dificuldade em estimar o número de parâmetros e a interpretação dos parâmetros não é direta, além disso, as aplicações empíricas são bastante restritas a sistemas de pequena dimensão.

Engle e Sheppard (2001) também empregam uma estrutura multivariada para o DCC-GARCH. O Dynamic Conditional Correlation Multivariate GARCH (DCC-MVGARCH) é uma extensão do modelo GARCH multivariado convencional e pode ser usado para modelar e prever a volatilidade condicional e a correlação condicional entre múltiplas séries temporais financeiras. DCC-MVGARCH introduz a dinâmica da correlação condicional, e é composto por duas etapas principais: a modelagem da volatilidade condicional das séries individuais usando GARCH e a modelagem da correlação condicional entre as séries usando um processo dinâmico separado.

Em relação a constância em todas as correlações, Engle (2002) sugeriu o seguinte DCC Generalizado, com o intuito de resolver a restrição de dinâmica igual para todas as correlações:

$$Q_t = S \circ (u' - A - B) + A \circ \epsilon_{t-1} \epsilon_{t-1}^T + B \circ Q_{t-1} \quad (25)$$

$$P_t = Q_t^{*-1} Q_t Q_t^{*-1} \quad (26)$$

Onde $\bar{P} = E[\epsilon_t \epsilon_t^T]$ e A e B são escalares onde $A + B < 1$, e $Q_t^* = [q_{iit}^*] = [\sqrt{q_{iit}}]$ é uma matriz diagonal com a raiz quadrada do i-ésimo elemento diagonal de Q_t em sua i-ésima posição diagonal. Enquanto Q_t for positivamente definida, Q_t^* garante que P_t é uma matriz de correlação com 1 na diagonal e todos os outros elementos menores que 1 em valor absoluto.

Segundo Billio e o Caporin (2008), essa forma de representar resolveu o problema de constância em todas as correlações, entretanto, leva a um aumento no número de parâmetros o que torna o modelo empiricamente pouco atraente. Já Bauwens et al. (2006) afirma que os modelos DCC podem ser estimados consistentemente em duas etapas (como veremos a frente), o que torna o modelo viável quando n é alto. Todavia, quando o n é grande há o problema de tratar a dinâmica da matriz de correlação condicional. Nesse sentido, diversas variantes do modelo DCC são propostas na literatura, como veremos na próxima seção.

3.1.3 Extensões do modelo DCC-GARCH

Para Cappiello et al (2006) o modelo descrito pelas equações (25) e (26) não permitem que notícias específicas de ativos e parâmetros de suavização ou assimetrias seja considerada. Desse modo, tais autores fornecem uma extensão diferente do modelo DCC introduzindo assimetria na dinâmica de correlação e traduzindo o modelo em uma forma quadrática:

$$Q_t = (S - A^T S A - B^T S B - G^T \bar{F} G) + A^T \epsilon_{t-1} \epsilon_{t-1}^T A + B^T Q_{t-1} B + G^T \xi_{t-1} \xi_{t-1}^T G \quad (27)$$

Onde $\xi_t = I(\xi_t < 0) \cdot \xi_t$, A, B e G são matrizes de parâmetros diagonais, S é continua sendo a matriz de covariância dos resíduos padronizados e \bar{F} é a matriz de covariância de ξ_t . A definição positiva é obtida restringindo a matriz $\bar{Q}_t - A' \bar{Q}_t A - B' \bar{Q}_t B - G' \bar{F} G$ para ser positivamente positiva. Apesar de tal modelo adicionar flexibilidade ao modelo de Engle (2002), o número de parâmetros aumenta com a dimensão do sistema, e a restrição matricial necessária para tornar o modelo positivamente definido torna a estimação bastante complexa. A equação (27) também pode ser reescrita como:

$$Q_t = (1 - \alpha - \beta)S + \alpha \epsilon_{t-1} \epsilon_{t-1}^T + \beta Q_{t-1} + \gamma \xi_{t-1} \xi_{t-1}^T \quad (28)$$

Neste modelo, o parâmetro γ mede o efeito assimétrico. Um valor positivo de γ indica que as correlações aumentam mais em resposta a choques negativos do que a choques positivos.

Franses and Hafner (2009) sugeriu uma outra generalização do Modelo de Correlação Condicional Dinâmica (DCC) de Engle (2002). Os autores propõem um modelo que permite a sensibilidade de correlação específicas de determinada variável, o que é útil principalmente quando se pretende resumir um grande número de retornos de ativos, usando o método da maximização da verossimilhança completa e estimativas de correlação individual. Trata-se, portanto, do modelo DCC generalizado (GDCC):

$$Q_t = [1 - \sum_{i=1}^n \alpha_i - \beta]S + \alpha\alpha^T \circ \epsilon_{t-1}\epsilon_{t-1}^T + \beta Q_{t-1} \quad (29)$$

Onde α é um vetor de dimensão n . Aqui a definição positiva é garantida sem restrições, entretanto, perde-se a propriedade de segmentação por correlação.

McAleer et al (2008) apresentam o modelo GARCC (Correlação Condicional Autorregressiva Generalizada), onde os resíduos padronizados seguem um processo VAR de coeficiente aleatório e assim tal modelo mostrou-se mais geral que o modelo de Engle (2002). Os autores consideram quatro casos específicos do modelo GARCC. Os casos de 1 a 3 são especializações do Caso 4 e demonstram que um modelo de correlação condicional variável no tempo pode ser derivado quando os resíduos padronizados seguem um processo VAR com coeficientes aleatórios. Desse modo, os autores buscam fazer uma generalização do modelo ao fornecer uma representação em que todas as correlações dinâmicas podem ter um padrão dinâmico diferente.

Sandqvist (2017) faz uma crítica a esses modelos no sentido de que conforme aumenta o sistema, o número de parâmetros aumenta rapidamente, surgindo assim várias especificações mais restritivas. Desse modo, o problema com a estimativa de covariâncias condicionais e correlações para um grande sistema é que os modelos diretos (VEC ou BEKK) são muito complicados para serem estimados, enquanto o DCC escalar é muito restritivo, tornando a dinâmica comum não realista.

Billio et al. (2006) apresenta o modelo GARCH multivariado de Correlação Condicional Dinâmica Flexível (FDCC) que também busca generalizar o modelo proposto por Engle (2002). O modelo FDCC relaxa a suposição de dinâmica comum entre todos os ativos usados no modelo DCC, onde a dinâmica de correlação de determinadas variáveis não pode ser tratada de forma idêntica à outras variáveis. A dinâmica não pode ser comum para todas as correlações, mas para os autores uma parametrização muito generalizada não é viável; assim, eles sugerem agrupar variáveis em conjuntos semelhantes que reflitam as necessidades empíricas de

alocação de ativos setoriais ou geográficos. Portanto, os autores estendem o modelo DCC introduzindo uma estrutura diagonal em bloco, onde as dinâmicas são restritas a serem iguais entre os grupos de variáveis. O modelo FDCC generaliza a abordagem de Franses e Hafner (2003), como vimos na equação (27):

$$Q_t = [1 - \sum_{i=1}^n \alpha_i - \beta]S + \alpha\alpha^T \circ \epsilon_{t-1}\epsilon_{t-1}^T + \beta Q_{t-1} \quad (30)$$

Onde β é um escalar e α é um vetor de dimensão k

Para os próprios autores a flexibilidade do modelo FDCC tem um custo, pois se perde a propriedade de segmentação de variância, uma vez que, a correlação incondicional não está incluída no modelo FDCC, o que leva a necessidade de parâmetros adicionais para estimar. No entanto, a propriedade de direcionamento de correlação pode ser inclusa no modelo com um conjunto adicional de restrições de parâmetro $\alpha_i\alpha_j + \beta_i\beta_j + c_ic_j = 1$ para $i, j = 1, \dots, n$. O modelo FDCC é baseada em um procedimento de duas etapas: a primeira etapa se concentra na estimação univariada, enquanto a segunda se concentra nas correlações. Vale ressaltar que ao restringir grupos de variáveis para seguir dinâmicas comuns, surge a necessidade de definir esses grupos previamente.

Billio e o Caporin (2008) introduzem um novo modo do tipo DCC que generaliza o DCC Flexível: o DCC Flexível Quadrático também pode ser considerado um caso especial do DCC Assimétrico de Cappiello et al (2006). Desse modo, os autores sugerem a seguinte parametrização do Q_t :

$$Q_t = C^T S C + A^T \epsilon_{t-1} \epsilon_{t-1}^T A + B^T Q_{t-1} B \quad (31)$$

onde A , B e C são matrizes simétricas. O modelo de Billio e o Caporin (2008) corresponde a um FDCC Quadrático com matrizes de parâmetros particionadas na diagonal. A estrutura quadrática do modelo garante a definitividade positiva de Q_t , e além disso, no DCC padrão, os parâmetros α e β devem satisfazer uma restrição ($\alpha + \beta < 1$) que exclui padrões de correlação explosivos.

Conforme observado por Akkoc e Civcir (2019), o modelo DCC-GARCH considera que as correlações entre as séries são dinâmicas e dependem das informações passadas sobre as volatilidades. Os parâmetros α e β são responsáveis por determinar em que medida as informações passadas são integradas na estimativa da correlação condicional. Nesse contexto, os resultados do DCC indicam que os parâmetros α (representando o efeito ARCH) e β (representando o efeito GARCH) estão vinculados, respectivamente, à persistência dos choques a curto e longo prazo,

além da soma desses dois parâmetros. Quanto mais próximo de 1, maior é o grau desses parâmetros, indicando uma maior persistência na volatilidade.

Orskaug (2009) descreve como os parâmetros de um modelo DCC-GARCH podem ser determinados. Desse modo, a estimação do modelo DCC- GARCH será demonstrada a partir da distribuição t de Student, por ser mais comumente utilizada. Quando os erros padronizados, z_t , são distribuídos em t de Student multivariado, a densidade conjunta de z_1, \dots, z_t é:

$$f(z|v) = \prod_{t=1}^T \frac{\Gamma\left(\frac{v+n}{2}\right)}{\Gamma\left(\frac{v}{2}\right)[\pi(v-2)]^{n/2}} \left[1 + \frac{z_t^T z_t}{v-2}\right]^{-\frac{n+v}{2}} \quad (32)$$

Onde $\Gamma(\cdot)$ é uma função gamma. Usando a regra de transformação, a função de verossimilhança de $\alpha_t = H_t^{1/2} z_t$ é:

$$L(\theta) = \prod_{t=1}^T \frac{\Gamma\left(\frac{v+n}{2}\right)}{\Gamma\left(\frac{v}{2}\right)[\pi(v-2)]^{n/2} |H_t|^{1/2}} \left[1 + \frac{a_t^T H_t^{-1} a_t}{v-2}\right]^{-\frac{n+v}{2}} \quad (33)$$

Onde θ é o parâmetro do modelo. A probabilidade logarítmica é obtida tomando o logaritmo e substituindo $H_t = D_t R_t D_t$

$$\ln(L(\theta)) = \sum_{t=1}^T \left(\ln \left[\Gamma\left(\frac{v+n}{2}\right) \right] - \ln \left[\Gamma\left(\frac{v}{2}\right) \right] - \frac{n}{2} \ln[\pi(v-2)] - \frac{1}{2} \ln[|D_t R_t D_t|] - \frac{v+n}{2} \ln \left[1 + \frac{a_t^T D_t^{-1} R_t^{-1} D_t^{-1} a_t}{v-2} \right] \right) \quad (31)$$

Quanto a distribuição normal, os erros padronizados θ são divididos em dois grupos; $(\phi, \psi) = (\phi_1, \dots, \phi_n, \psi)$, onde $\phi_i = (\alpha_{0i}, \alpha_{1i}, \dots, \alpha_{qi}, \beta_{1i}, \dots, \beta_{pi})$ são os parâmetros do modelo GARCH univariado para a i-th série de ativos, $i = 1, \dots, n$ e $\psi = (a, b, v)$.

A otimização da equação 31 é difícil. Desse modo, os parâmetros são obtidos em dois passos. Na primeira etapa, o parâmetro ϕ é estimado assumindo que os erros padronizados são distribuídos normalmente, enquanto o parâmetro ψ é estimado na segunda etapa usando a verossimilhança correta em 31, dado o parâmetro ϕ .

3.1.3.1 -Estimação do parâmetro ϕ

Vários autores mostraram que a mudança da distribuição de erros não afeta virtualmente os parâmetros. Assim, os parâmetros $\phi = \phi_1, \dots, \phi_n$ dos modelos GARCH univariados são ajustados usando a máxima-verossimilhança; assumindo que os erros são distribuídos de forma normal.

Supondo que os erros distribuídos são de forma normal, quando os erros padronizados, z_t , são distribuídos de forma normal multivariada, a distribuição conjunta de z_1, \dots, z_t é:

$$f(x_t) = \prod_{t=1}^T \frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2} z_t^T z_t\right\} \quad (34)$$

Como $E(z_t) = 0$ e $E(z_t^T z_t) = I$, sendo que $t = 1, \dots, T$ é o período de tempo usado para estimar a modelo. Usando a regra para transformação linear de variáveis, a função de verossimilhança para $\alpha_t = H_t^{1/2} z_t$ é:

$$L(\theta) = \prod_{t=1}^T \frac{1}{(2\pi)^{n/2} |H_t|^{1/2}} \exp\left\{-\frac{1}{2} a_t^T H_t^{-1} a_t\right\} \quad (35)$$

A probabilidade logarítmica é obtida tomando o logaritmo e substituindo $H_t = D_t R_t D_t$

$$\ln(L(\theta)) = -\frac{1}{2} \sum_{t=1}^T (n \ln(2\pi) + \ln(|H_t|) + a_t^T H_t^{-1} a_t) \quad (36)$$

$$\ln(L(\theta)) = -\frac{1}{2} \sum_{t=1}^T (n \ln(2\pi) + \ln(|D_t R_t D_t|) + a_t^T D_t^{-1} R_t^{-1} D_t^{-1} a_t) \quad (37)$$

$$\ln(L(\theta)) = -\frac{1}{2} \sum_{t=1}^T (n \ln(2\pi) + 2 \ln(|D_t|) + \ln(|R_t|) + a_t^T D_t^{-1} R_t^{-1} D_t^{-1} a_t) \quad (38)$$

No primeiro estágio R_t é substituído pela matriz identidade I_n , o que resulta na função de quase-verossimilhança:

$$\ln(L(\theta)) = -\frac{1}{2} \sum_{t=1}^T (n \ln(2\pi) + 2 \ln(|D_t|) + \ln(|I_n|) + a_t^T D_t^{-1} I_n^{-1} D_t^{-1} a_t) \quad (39)$$

$$\ln(L(\theta)) = -\frac{1}{2} \sum_{t=1}^T (n \ln(2\pi) + 2 \ln(|D_t|) + a_t^T D_t^{-1} I_n^{-1} D_t^{-1} a_t) \quad (40)$$

$$\ln(L(\theta)) = -\frac{1}{2} \sum_{t=1}^T \left(n \ln(2\pi) + \sum_{i=1}^n \left[\ln(h_{it}) + \frac{a_{it}^2}{h_{it}} \right] \right) \quad (41)$$

$$\ln(L(\theta)) = \sum_{i=1}^n \left(-\frac{1}{2} \sum_{t=1}^T \left(\ln(h_{it}) + \frac{a_{it}^2}{h_{it}} \right) + constante \right) \quad (42)$$

Essa probabilidade logarítmica é a soma das probabilidades logarítmicas das equações GARCH univariadas de n ativos, significando que os parâmetros dos diferentes modelos univariados podem ser determinados separadamente. A partir desta primeira etapa, o conjunto de parâmetros $\phi = \phi_1, \dots, \phi_n$ é estimado. Quando ϕ é estimado, também a variância condicional h_{it} é estimada para cada ativo $i = 1, \dots, n$, e $\epsilon_t = D_t^{-1/2} a_t$ e $\bar{Q} = E[\epsilon_t \epsilon_t^T]$ podem ser estimados.

Desse modo, os parâmetros a serem estimados é $\psi = (a, b, v)$

3.1.3.2 - Estimação do parâmetro ψ

Os parâmetros $\psi = (a, b, v)$ são estimados na segunda etapa usando a probabilidade logarítmica corretamente especificada na equação 31:

$$\ln(L(\theta)) = \sum_{t=1}^T \left(\ln \left[\Gamma \left(\frac{v+n}{2} \right) \right] - \ln \left[\Gamma \left(\frac{v}{2} \right) \right] - \frac{n}{2} \ln[\pi(v-2)] - \frac{1}{2} \ln[|D_t R_t D_t|] - \frac{v+n}{2} \ln \left[1 + \frac{a_t^T D_t^{-1} R_t^{-1} D_t^{-1} a_t}{v-2} \right] \right) \quad (43)$$

$$\ln(L(\theta)) = \sum_{t=1}^T \left(\ln \left[\Gamma \left(\frac{v+n}{2} \right) \right] - \ln \left[\Gamma \left(\frac{v}{2} \right) \right] - \frac{n}{2} \ln[\pi(v-2)] - \frac{1}{2} \ln[|R_t|] - \ln[|D_t|] - \frac{v+n}{2} \ln \left[1 + \frac{\epsilon_t^T R_t^{-1} \epsilon_t}{v-2} \right] \right) \quad (44)$$

Como D_t é constante ao condicionar os parâmetros do primeiro passo, podemos excluir o termo constante e maximizar:

$$\ln(L(\theta)) = \sum_{t=1}^T \left(\ln \left[\Gamma \left(\frac{v+n}{2} \right) \right] - \ln \left[\Gamma \left(\frac{v}{2} \right) \right] - \frac{n}{2} \ln[\pi(v-2)] - \frac{1}{2} \ln[|R_t|] - \frac{v+n}{2} \ln \left[1 + \frac{\epsilon_t^T R_t^{-1} \epsilon_t}{v-2} \right] \right) \quad (45)$$

3.2 BASE DE DADOS

3.2.1 Índice de Confiança do Empresário Industrial (ICEI)

Desde 1998 a Confederação Nacional da Indústria (CNI) desenvolveu o Índice de Confiança do Empresário Industrial (ICEI) com o intuito de fazer uma Sondagem Industrial, de modo que, mensalmente a CNI divulga, em seu portal virtual, o relatório do resultado do Índice de Confiança do Empresário Industrial (ICEI). A classificação de atividades utilizada foi baseada na lista de Códigos de Atividades Econômicas - CNAE, versão 2.0, mesma metodologia utilizada pelo IBGE. Desse modo, os dados utilizados incluem o período de fevereiro de 2010 (para incluir séries que não tinham observação em janeiro) a fevereiro de 2020 (período pré-pandemia)¹.

O ICEI começou a ser divulgado em 1999 e possui grande relevância pois foi criado para produzir resultados nacionais e estaduais abrangendo empresas de pequeno, médio e grande porte; desse modo, o indicador ICEI mede como os empresários avaliam as condições econômicas e suas implicações sobre a sua empresa, o que torna possível compreender a tendência da indústria e do comportamento da produção industrial em relação ao investimento, empregabilidade, produção e decisões que são baseadas em expectativas. Por exemplo, quanto maior for o grau de confiança, maior seria a tendência de haver maior nível de investimento.

¹ A metodologia pelo qual o ICEI foi desenvolvido, encontra-se disponível para download em <https://www.portaldaindustria.com.br/estatisticas/icei-indice-de-confianca-do-empresario-industrial/>.

Assim, o ICEI é um indicador que serve para identificar mudanças na tendência da produção industrial com certa antecedência, e assim ajuda a prever o produto industrial e, por conseguinte, do PIB brasileiro, uma vez que quanto mais confiante estiverem os empresários, mais eles tendem a aumentar o investimento e a produção. De acordo com a metodologia desenvolvida pela CNI (2020), as informações necessárias para a construção do ICEI são coletadas por meio de dois questionários que abrangem o Brasil inteiro:

- (i) o questionário da Sondagem Industrial; e
- (ii) o questionário da Sondagem Indústria da Construção.

A Sondagem Industrial é realizada em parceria com federações de indústria de 24 estados (AC, AL, AM, BA, CE, ES, GO, MA, MG, MS, MT, PA, PB, PE, PR, RJ, RN, RO, RR, RS, SC, SE, SP e TO) e do Distrito Federal. Já a Sondagem Indústria da Construção conta com a parceria de federações de indústria e Sindicatos da Indústria de construção de 22 estados (AL, AM, BA, CE, ES, GO, MA, MG, MT, PA, PB, PE, PR, RJ, RN, RO, RR, RS, SC, SE, SP e TO) e do Distrito Federal; e ainda, colaboram os sindicatos da indústria da construção civil (Sinduscon) de 14 estados (AL, BA, CE, ES, GO, MA, MG, PE, RJ, RO, SC, SE, SP-SINICESP e TO) e do Distrito Federal. A CNI elabora indicadores estaduais, regionais e nacionais para diferentes portes, do mesmo modo são elaborados indicadores setoriais nacionais.

Os resultados setoriais estão disponibilizados de acordo com a versão 2.0 da Classificação Nacional de Atividades Econômicas (CNAE 2.0). Os resultados por porte de empresa passam a ser elaborados de acordo com a definição da Eurostat (Escritório de Estatística da União Européia). Pela nova definição, são consideradas pequenas empresas aquelas com 10 a 49 empregados; médias as com 50 a 250 empregados e grandes as com 250 ou mais empregados.

De acordo com a metodologia empregada pela Confederação Nacional da Indústria (CNI), O ICEI é um indicador de difusão que varia de 0 a 100. Os indicadores de difusão são indicadores de base móvel (50 pontos), construídos de forma que entre 0 e 50 o resultado é considerado uma expectativa pessimista dos empresários, e de 51 a 100, uma perspectiva otimista por parte destes.

O ICEI é construído com base em quatro perguntas:

- I. Condições atuais da economia brasileira: P_{α}
- II. Condições atuais da empresa: P_{β}

- III. Expectativa sobre a economia brasileira: P_γ
- IV. Expectativa sobre a empresa: P_δ

Para cada porte de empresa ou setor de atividade são calculados, indicadores de difusão para cada uma das quatro perguntas básicas. Os indicadores são calculados a partir da frequência relativa das respostas. Cada pergunta permite cinco alternativas excludentes. Cada alternativa é associada, da mais negativa para a mais positiva, aos pesos 0,0; 0,25; 0,50; 0,75; e 1,0. O indicador relativo a cada pergunta é a média desses escores, ponderada pelas frequências relativas das respostas, ou seja:

$$IP_i = \sum_{j=1}^5 (F_{ij} \times \bar{\omega}_j) \times 100$$

Onde:

IP_i : Indicador da pergunta i , onde $i = P_\alpha, P_\beta, P_\gamma$ e P_δ .

F_{ij} : Frequência relativa das respostas do tipo j , para a pergunta i .

$\bar{\omega}_j$: pesos da resposta do tipo $j = 1, \dots, 5$.

Figura 1: Pesos das opções de Respostas

Tipo de resposta	Expectativa	Condições atuais	Peso ($\bar{\omega}_j$)
1	Muito Pessimista	Pioraram muito	0,00
2	Pessimista	Pioraram	0,25
3	Deve permanecer a mesma situação	Não se alteraram	0,50
4	Otimista	Melhoraram	0,75
5	Muito otimista	Melhoraram muito	1,00

Fonte: Confederação Nacional da Indústria (2020)

Figura 2: Bloco de perguntas referentes ao ICEI

Índice de confiança do empresário industrial - ICEI

É extremamente importante que este bloco de perguntas seja respondido pelo principal executivo da empresa.

13 – Em comparação com os últimos seis meses, o sr. (a) diria que as condições gerais:

	Pioraram muito	Pioraram	Não se alteraram	Melhoraram	Melhoraram muito
da economia brasileira	1 <input type="checkbox"/>	2 <input type="checkbox"/>	3 <input type="checkbox"/>	4 <input type="checkbox"/>	5 <input type="checkbox"/>
do estado	1 <input type="checkbox"/>	2 <input type="checkbox"/>	3 <input type="checkbox"/>	4 <input type="checkbox"/>	5 <input type="checkbox"/>
de sua empresa	1 <input type="checkbox"/>	2 <input type="checkbox"/>	3 <input type="checkbox"/>	4 <input type="checkbox"/>	5 <input type="checkbox"/>

14 – Qual a sua expectativa para os próximos seis meses com relação:

	Muito pessimista	Pessimista	Deve permanecer a mesma situação	Confiante	Muito confiante
à economia brasileira	1 <input type="checkbox"/>	2 <input type="checkbox"/>	3 <input type="checkbox"/>	4 <input type="checkbox"/>	5 <input type="checkbox"/>
ao estado	1 <input type="checkbox"/>	2 <input type="checkbox"/>	3 <input type="checkbox"/>	4 <input type="checkbox"/>	5 <input type="checkbox"/>
à sua empresa	1 <input type="checkbox"/>	2 <input type="checkbox"/>	3 <input type="checkbox"/>	4 <input type="checkbox"/>	5 <input type="checkbox"/>

Fonte: Confederação Nacional da Indústria (2020)

Com base nos indicadores de cada pergunta, são calculados dois indicadores:

i) Indicador de condições atuais e ii) Indicador de expectativa.

O Indicador de condições atuais é a média ponderada dos indicadores das perguntas P_α e P_β , com pesos 1 e 2, respectivamente:

$$I_{condições\ atuais} = \frac{IP_\alpha + (IP_\beta \times 2)}{3} \quad (44)$$

O Indicador de expectativa é a média ponderada dos indicadores das perguntas P_γ e P_δ , com pesos 1 e 2, respectivamente:

$$I_{Expectativas} = \frac{IP_\gamma + (IP_\delta \times 2)}{3} \quad (45)$$

O ICEI para cada um dos portes de empresa é igual à média ponderada dos indicadores de condições atuais (peso 1) e expectativas (peso 2) dos respectivos portes.

$$ICEI^k = \frac{I^k_{condições\ atuais} + (I^k_{Expectativas} \times 2)}{3} \quad (46)$$

Onde k indica o porte de empresa considerado.

O ICEI para cada um dos setores de atividade é igual à média ponderada dos indicadores de condições atuais (peso 1) e expectativas (peso 2) dos respectivos setores de atividade

$$ICEI^s = \frac{I^s_{condi\tilde{c}oes\ atuais} + (I^s_{Expectativas} \times 2)}{3} \quad (47)$$

Onde s indica o setor de atividade considerado.

Segundo a CNI, os indicadores agregados (geral, construção, extrativa e transformação) são calculados a partir da média ponderada dos indicadores por porte de empresa. Desse modo, primeiramente são calculados os indicadores para cada um dos três portes de empresa considerados (pequeno, médio e grande) ou dois no caso de alguns estados, conforme a equação

$$ICEI^{IG} = \sum_{k=1}^3 (ICEI^k \times \beta^k) \times 100 \quad (48)$$

Onde:

$ICEI^{IG}$: ICEI do agregado da indústria.

$ICEI^k$: ICEI para o porte da empresa k, onde k = 1, 2, 3

β^k : Peso do porte k

A série histórica do índice de Confiança do Empresário Industrial (ICEI) pode ser encontrado no site da CNI no seguinte endereço: <https://www.portaldaindustria.com.br/estatisticas/icei-indice-de-confianca-do-empresario-industrial/>. Na pesquisa avançada foram aplicados filtros para escolher os ICEI's dos setores industriais da CNAE 2.0. Desse modo, foram escolhidos 27 setores:

Tabela 1: Setores Escolhidos

(10) Alimentos
(11) Bebidas
(13) Têxteis
(14) Vestuário e acessórios
(15A) Couros e artefatos de couro
(15B) Calçados e suas partes
(16) Madeira
(17) Celulose e papel
(18) Impressão e reprodução
(19B) Biocombustíveis
(20B) Perfumaria, sabões, detergentes, produtos de limpeza e de higiene pessoal
(21) Farmoquímicos e farmacêuticos

(22A) Produtos de borracha
(22B) Produtos de material plástico
(23) Produtos de minerais não metálicos
(24) Metalurgia
(25) Produtos de metal
(26) Equipamento de informática, eletrônicos e ópticos
(27) Máquinas e materiais elétricos
(28) Máquinas e equipamentos
(29) Veículos automotores
(30) Outros equipamentos de transporte
(32) Produtos diversos
(33) Manutenção e reparação
(41) Construção de Edifícios
(42) Obras de Infraestrutura
(43) Serviços especializados para construção

O IBGE disponibiliza um sistema de busca que permite indicar a posição de cada código na estrutura da CNAE, incluindo o desdobramento de subclasses CNAE e as Notas Explicativas de seu conteúdo. Desse modo, a tabela abaixo mostra a estrutura dos setores escolhidos nesse trabalho:

Tabela 2: Estrutura da Classificação da CNAE 2.0

Seção	Divisão	Denominação
C	10-33	Indústria de transformação
F	41-43	Construção

3.2.2 Variáveis econômicas

Um dos objetivos desse trabalho é examinar quais variáveis econômicas são relevantes para explicar o comovimento setorial em uma análise de regressão. Assim, a seguir serão apresentadas as variáveis escolhidas e suas respectivas fontes. Vale ressaltar que, tais variáveis foram selecionadas em forma de série temporal, no período de fevereiro de 2010 a fevereiro de 2020.

A primeira variável econômica é o Endividamento e Inadimplência do Consumidor (PEIC)², que é divulgada pela Fecomércio, cujo objetivo é diagnosticar o nível de endividamento e inadimplência do consumidor, desse modo, alguns indicadores importantes são apontados: nível de endividamento, percentual de inadimplentes, intenção de pagar dívidas em atraso e nível de comprometimento da renda.

A segunda variável econômica é o índice Ibovespa (IBOV)³, que é o principal índice do mercado de ações, sendo importante indicador de desempenho médio dos ativos mais negociados e representativos do mercado de ações do Brasil.

A terceira variável econômica é o Índice Nacional de Preços ao Consumidor Amplo (IPCA)⁴ que é um dos principais indicadores de inflação no Brasil, elaborado pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Ele é reconhecido como a métrica oficial para aferir a taxa de inflação do país. Foram usados como variável nesse trabalho os Índice acumulado nos últimos 12 meses (em %).

Finalmente, a última variável será o Índice de Atividade Econômica do Banco Central - IBC-Br⁵, que é um Indicador mensal contemporâneo da atividade econômica.

3.3 ESTIMAÇÃO

Utilizamos dados mensais do Índice de Confiança do Empresário Industrial (ICEI) ajustados sazonalmente para setores industriais da CNAE 2.0. O período amostral é de de janeiro de 2010 a fevereiro de 2020. Os dados contêm 27 setores escolhidos conforme a tabela 1. Uma simples análise gráfica mostra que todas as séries possuem tendências (Gráfico A1 no Apêndice), desse modo, utilizamos a transformação de primeira diferença em log para cada série, o resultado do teste Dickey-Fuller se encontra no apêndice 1.

Foi rodado o modelo DCC-GARCH (1,1)⁶ para dados mensais, de fevereiro de 2010 a fevereiro de 2020 (o mês anterior a pandemia). Cada série foi suavizada e

² Os dados sobre o Endividamento das famílias foram encontrados no próprio site da Fecomércio (<https://www.fecomercio.com.br/pesquisas/indice/peic>).

³ É formado pelas ações com maior volume negociado nos últimos meses e encontram-se disponíveis em <https://www.infomoney.com.br/cotacoes/b3/indice/ibovespa/historico/>

⁴ A série histórica do IPCA encontra-se em <https://www.ibge.gov.br/estatisticas/economicas/precos-e-custos/9256-indice-nacional-de-precos-ao-consumidor-amplo?=&t=downloads>.

⁵ A série histórica do IBC-Br encontra-se em: <https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>.

⁶ Utilizando a linguagem de programação R-Studio.

diferenciada. Além disso, foi utilizado o X-13ARIMA-SEATS para realizar o ajuste sazonal de cada uma das séries.

O primeiro passo foi especificar o modelo Garch através da definição dos parâmetros do modelo GARCH, como o número de defasagens para os termos autorregressivos e de média móvel, bem como outras configurações relacionadas à especificação do modelo⁷. O modelo de volatilidade condicional utilizado foi o modelo Simple GARCH por se tratar de um modelo mais simples.

O pacote “rmgarch” fornece uma seleção de modelos GARCH multivariados com métodos para ajuste, filtragem, previsão e simulação com funções de suporte adicionais para trabalhar com os objetos retornados⁸. Desse modo, devido a possíveis assimetrias na correlação condicional usamos o modelo assimétrico se o logaritmo da verossimilhança for significativamente maior do que o do modelo flexível.

Cada série foi modelada por processo autorregressivo de média móvel (ARMA) escolhido. Desse modo, a ordem ótima GARCH(p, q), o modelo e a distribuição são escolhidos pelo

As suposições da distribuição dos resíduos consideradas incluem distribuição Normal, Normal Assimétrica, t-Student e t-Student assimétrica. A distribuição utilizada foi a t-Student Assimétrica, que é uma extensão da distribuição t-Student que incorpora um parâmetro de assimetria, adicionando flexibilidade ao modelo para acomodar assimetrias nos dados. É importante destacar que a ordem ótima GARCH(p, q), ARMA(l,k) e a distribuição foram escolhidos pelo critério Akaike⁹. Os testes diagnósticos para os resíduos ARMA(l,k) são apresentados na Tabela A4 no Apêndice.

3.4 MÉTODO "MACGYVER"

Com o intuito de lidar com o problema de alta dimensionalidade, usamos para tratar os dados o chamado método "MacGyver" proposto por Engle (2009). Essa abordagem agrega as estimativas dos modelos bivariados por meio de procedimentos simples, como a média ou mediana.

Esse método é embasado em pares, todavia, em vez de calcular a média dos log-verossimilhanças de pares de observações, as log-verossimilhanças foram

⁷ Para tal propósito foi utilizado o pacote “rugarch” no R.

⁸ . O pacote tem os modelos DCC (de Engle (2002), aDCC (DCC assimétrico de Capiello et al. (2006)) e FDCC (DCC flexível de Billio e o Caporin (2008))

⁹ Conforme os resultados presentes Tabela A2 e a Tabela A3, no Apêndice

maximizadas separadamente e, em seguida, os estimadores resultantes foram robustamente combinados usando medianas. Desse modo, como estamos trabalhando com um total de 27 séries temporais de Índice de confiança, temos 351 modelos bivariados, ou seja, 351 séries de correlação dinâmica.

Desse modo, a principal ideia por trás da estratégia MacGyver de Engle é estimar modelos GARCH em um ambiente de alta dimensão de forma eficiente e robusta. Em muitos casos, especialmente quando se trabalha com muitas séries temporais, a estimação tradicional de modelos GARCH pode ser computacionalmente intensiva e sujeita a problemas de instabilidade numérica. A abordagem MacGyver busca superar essas limitações. Assim, as principais etapas da estratégia MacGyver de Engle:

- Estimação de Pares: em vez de estimar diretamente os modelos GARCH para cada série temporal individual, Engle propõe estimar o modelo para pares de séries temporais.
- Maximização das Log-Verossimilhanças Separadamente: para cada par de séries temporais, as log-verossimilhanças do modelo GARCH são maximizadas separadamente, o que é um processo mais simples e eficiente em comparação com a estimação de modelos em série individuais.
- Combinação Robusta: depois de estimar os modelos GARCH para os pares de séries temporais, os estimadores resultantes são combinados de forma robusta usando medianas. Isso é feito para mitigar quaisquer efeitos extremos ou influências atípicas que podem surgir durante a estimação.

A estratégia MacGyver é particularmente útil quando se lida com um grande número de séries temporais, de modo a reduzir a carga computacional associada à estimação de modelos GARCH.

4. DISCUSSÃO DOS RESULTADOS

iremos apresentar o resultado do modelo gerado com todas as 27 séries, utilizando o modelo flexível (FDCC). Sabemos que estimar um único modelo com muitas séries implica que a dinâmica das correlações seria a mesma para todas as séries. Então, conforme dito anteriormente, usaremos o método de MacGyver para mitigar quaisquer efeitos extremos ou influências atípicas que podem surgir durante a

estimação, desse modo, as estatísticas descritivas dos parâmetros estimados dos modelos bivariados DCC(1,1)-(G)ARCH são apresentadas na Tabela 3.

Tabela 3: Resultado das Correlações Dinâmicas dos Modelos Bivariados DCC-GARCH (1,1)

	MÉDIA	ERRO PADRÃO ¹⁰	T VALUE	Pr(> t) ¹¹	MEDIANA	MÁXIMO	MÍNIMO
α	0,2047	0,0783	3,0042	0,0501	0,1615	0,7572	0,0000
β	0,7022	0,1118	2940,8274	0,0000	0,8285	0,9799	0,0000

Segundo Desvallons (2019), os parâmetros α é a própria variância condicionais nos termos ARCH e o efeito de persistência de curto prazo, enquanto β é a própria volatilidade condicional nos termos GARCH e a persistência de longo prazo da volatilidade. Akkoc e Civcir (2019) afirmam que a persistência da volatilidade das variáveis é medida pela soma de α e β , desse modo, à medida que a soma desses dois parâmetros se aproxima da unidade, a persistência da variância aumenta, em outras palavras, ocorre alta persistência na volatilidade da Correlação Condicional Dinâmica. Ao mesmo tempo, β é maior que α , o que significa que as variâncias passadas predominam sobre as variâncias atuais. Os mesmos autores afirmam que valores altos no β , acima de 0,90 sugerem persistência a longo prazo na transmissão de volatilidade. Vale destacar que β é significativo a 1%, e α está no limite da significância a 5%.

As estatísticas descritivas dos parâmetros estimados do modelo DCC-(G)ARCH em conjunto é apresentada na Tabela 3. Embora a estimativa para α seja relativamente grande em alguns setores, o que segundo Sandqvist (2017) indica que o processo de correlação entre os setores seja bastante errático e relativamente pouco integrados, os resultados são positivos, uma vez que a estimativa para a média de α é de 0,2047. Da mesma forma, as estimativas para β se mostram satisfatórias uma vez que são não negativas e menores do que a unidade, sendo sua média igual a 0,7022. A mediana para α é de 0.1615 e para β é de 0.8285. Portanto, a soma das médias ($\alpha + \beta$) é igual a 0,9069, o que mostra um alto nível de persistência no processo de correlação.

¹⁰ Foi considerada a mediana dos erros padrões dos modelos bivariados com o intuito de expurgar valores muito discrepantes.

¹¹ Foi considerada a mediana dos p-valores dos modelos bivariados o intuito de expurgar valores muito discrepantes.

Portanto, o resultado da Tabela 3 mostra que o α é estatisticamente significativo, o que implica que há uma persistência de choque de curto prazo na correlação condicional dinâmica entre os índices de confiança dos setores industriais. Da mesma forma, o resultado do β mostra que há persistência de longo prazo na correlação dinâmica entre os pares dos índices de confiança dos setores industriais. Como β é bem maior que α então as variâncias do longo prazo predominam sobre as variâncias de curto prazo. Além disso, como $\alpha + \beta$ estão muito próximos da unidade, temos um alto nível de persistência no processo de correlação dos índices de confiança dos setores industriais.

Vale destacar que a existência de uma persistência elevada no processo de correlação sugere que as relações entre as os pares de setores têm a tendência de se manterem relativamente constantes ao longo do tempo, mesmo diante de alterações nas condições da economia. Ou seja, essa característica implica que as correlações históricas exercem uma influência de longo prazo nas correlações futuras. A persistência na correlação indica que as interações entre os setores têm uma estabilidade consistente e que eventos inesperados ou mudanças nas condições econômicas têm um impacto duradouro nas correlações ao longo do tempo. Embora um nível elevado de persistência possa indicar uma maior capacidade preditiva nas relações entre as variáveis, também pode aumentar o risco se houver mudanças substanciais nas condições econômicas.

4.1 ASPECTOS ASSIMÉTRICOS

Conforme afirma Foerster, Sarte e Watson (2011), o nível de comovimento pode flutuar. Isso pode ocorrer devido a reações assimétricas a choques desfavoráveis e favoráveis ou reações diferentes em relação à magnitude de um choque. Podemos levar em consideração as assimetrias nas volatilidades condicionais, onde choques negativos e positivos tenham efeitos diferentes. Sandqvist (2017) afirma que se um processo assimétrico é modelado pelo modelo simétrico padrão, a variância condicional estimada após um choque negativo seria subestimada, enquanto a volatilidade condicional seria muito alta após um choque positivo.

A versão assimétrica do modelo DCC (aDCC) é preferida para a maioria dos casos pelo critério dos logaritmos de verossimilhança (LV), todavia, a diferença foi

vagamente maior no modelo assimétrico do que no modelo simétrico, ou seja, a diferença nas médias foi relativamente pequena, conforme a Tabela 4, que apresenta a média do LV's dos pares de correlação dinâmica do modelo flexível (FDCC) e do modelo assimétrico (ADCC).

Tabela 4: Média das LV dos modelos simétricos e assimétricos

	ADCC	FDCC
Logaritmo de verossimilhança	283,31	277,87

Vale ressaltar que 72% dos logaritmos de verossimilhança foram maiores para o modelo assimétrico, e 28% para o modelo flexível. Entretanto os logaritmos da verossimilhança dos modelos assimétricos não foram significativamente maiores do que os do modelo simétricos, em muitos casos a diferença ficou próxima de zero. Portanto, embora não seja conclusivo, há evidências limitadas de assimetrias nas correlações, o que implica que a maioria dos pares de setores reage de forma semelhante a choques comuns, independentemente do sinal dos choques.

Além disso, sabemos que o parâmetro γ^{12} do modelo ADCC mede o efeito assimétrico, assim, um valor positivo de γ indica que as correlações aumentam mais em resposta a choques negativos do que a choques positivos. Os resultados mostram valores positivos para todos os gamas (γ), com média de 0,025. Assim, a maioria dos Índices de confiança podem reagir de forma mais intensa a choques desfavoráveis do que a choques favoráveis (pois a estimativa para o parâmetro de assimetria é positiva). Todavia, no modelo assimétrico, embora os parâmetros γ dos pares de setores sejam todos positivos, ficaram muito próximos de zero.

Desse modo, como há evidências limitadas de assimetria, optamos pelo modelo flexível para estimar a Correlação Condicional Média dos setores de confiança das indústrias brasileiras, conforme veremos na seção subsequente.

4.2 COMOVIMENTO DOS ÍNDICES DE CONFIANÇA

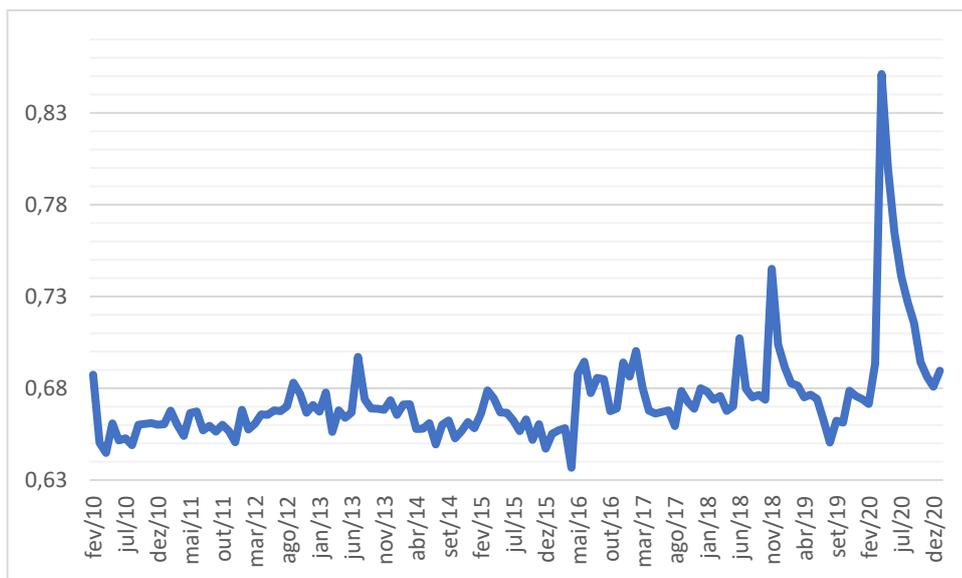
Com o intuito de observar o comovimento dos índices de confiança dos empresários como um todo, calculamos as correlações condicionais média¹³,

¹² Conforme Cappiello et al (2006).

¹³ Foi feito o mesmo cálculo com a mediana, e os resultados foram muito similares

considerando os 27 setores industriais. Desse modo, na figura 2 é possível observar a trajetória desse comovimento. Como podemos ver, o processo de correlação não apresenta um aspecto estável no decorrer dos anos, ou seja, o comovimento flutua ao longo dos anos. Nesse sentido, entre 2010 e 2012 o gráfico apresenta uma tendência de crescimento e uma certa estabilidade, principalmente entre 2011 e 2012. Em meados de 2012 até 2014 ocorre grandes oscilações e a média fica em patamar menor que o período anterior. Em 2014 inicia-se uma tendência de queda até meados de 2015, quando então ocorre um pico e a partir de 2016 há uma mudança de patamar, e assim ocorre uma estabilidade na média, com várias oscilações até 2020, sendo a maior em 2019. Em 2020 há um pico no comovimento devido a pandemia de Covid-19. Desse modo, a comovimentação não é constante, mas varia consideravelmente ao longo do tempo, sendo que em alguns períodos os setores se movem mais fortemente do que em outros momentos.

Figura 3: Correlação Condicional Média



Como discutido anteriormente, apesar da média do critério de verossimilhança do modelo assimétrico ser ligeiramente maior, há evidências limitadas de assimetrias nas correlações. Isso sugere que a maioria dos pares de setores reage de maneira semelhante a choques comuns, independentemente do sinal desses choques. Essa característica é evidenciada na figura 3, o que ilustra um comportamento setorial de comovimento variável, não constante, mas marcado por movimentos irregulares. Vale notar que as correlações aparentam ter aumentado significativamente durante algumas recessões econômicas, crises políticas e pandemia da Covid-19.

4.3 POSSÍVEIS FATORES QUE CAUSAM FLUTUAÇÕES NAS CORRELAÇÕES SETORIAIS.

Na seção anterior, foi possível observar evidências de flutuações nas correlações condicionais entre os índices de confiança dos setores industriais na economia brasileira. Entretanto, a análise DCC-GARCH não é suficiente para avaliar as causas das correlações setoriais não constantes. Segundo Sandqvist (2017), geralmente os setores se movem juntos devido aos efeitos diretos de fatores comuns e à transmissão de choques devido a ligações setoriais. Desse modo, para autora as mudanças ao longo do tempo no comovimento interindustrial podem ser causadas por:

1. Alterações na magnitude dos choques comuns
2. Mudanças na sensibilidade dos setores a fatores comuns
3. Força variável da propagação de choques.

Contudo, visto que a força da propagação de impactos está principalmente ligada às conexões entre setores, as quais são consideradas como relativamente estáveis ou com alterações gradativas, os dois primeiros argumentos da autora em questão devem ser os principais catalisadores das variações nas relações entre indústrias.

4.3.1 Alterações na magnitude dos choques comuns

Investigamos quais fatores comuns têm relevância no comportamento conjunto do índice de confiança nos setores industriais em um estudo de regressão, utilizando como variáveis independentes as variáveis econômicas cujas fontes foram abordadas anteriormente. Desse modo, os fatores comuns incluem o coeficiente dos ativos do IBOVESPA em log, o índice de IPCA em log e o endividamento das famílias em log. Desse modo, foram feitas duas regressões (Tabela 5 e Tabela 6) para o período de fevereiro de 2010 a fevereiro de 2020 (antes da pandemia), cuja variável dependente é a correlação condicional média FDCC dos índices de confiança dos setores industriais, e as variáveis independentes são as variáveis econômicas mencionadas.

De forma a medir a magnitude do efeito que o cenário econômico tem sobre o comovimento do índice de confiança empresarial, fizemos dois cenários onde o primeiro não possui o IBC-BR no modelo enquanto o outro cenário considera.

A tabela 5 mostra os resultados do modelo de regressão sem o índice de Atividade Econômica. Vale ressaltar que foi incluído um atraso de um mês nas

variáveis independentes, uma vez que, o índice de confiança dos empresários é influenciado por fatores econômicos de períodos de passado recente, não apenas corrente. Ou seja, se no último mês a economia vai mal, o empresário baixa suas expectativas.

Tabela 5: Resultados FDCC estimados com variáveis econômicas

	log(DC.1)						
	(1)	(2)	(3)	(4)	(5)	(6)	(7)
l_IBOV	0.044*** (0.008)			0.043*** (0.008)	0.043*** (0.008)		0.042*** (0.007)
l_Endividamento		-0.058** (0.028)		-0.050* (0.025)		-0.059** (0.028)	-0.051** (0.025)
l_IPCA			-0.019** (0.008)		-0.016** (0.007)	-0.019** (0.008)	-0.016** (0.007)
Constant	-0.564*** (0.033)	-0.475*** (0.049)	-0.343*** (0.014)	-0.645*** (0.052)	-0.531*** (0.035)	-0.444*** (0.049)	-0.614*** (0.053)
Observations	122	122	122	122	122	122	122
R ²	0.219	0.034	0.045	0.243	0.249	0.080	0.275
Adjusted R ²	0.212	0.026	0.037	0.231	0.236	0.064	0.256

Notes: MQO simples cuja variável dependente é a média da correlação dinâmica dos Índices de confiança (Coluna I) Considera-se apenas uma variável independente o log dos ativos do IBOVESPA (Coluna II) Considera-se apenas uma variável independente, o log do Endividamento das famílias (Coluna III) Considera-se apenas uma variável independente, o Índice de Inflação (IPCA) Coluna IV) Considera-se apenas uma variável independente o log dos ativos do IBOVESPA Coluna V) Considera-se como variáveis independentes o log do IPCA e o log do IBC Coluna VI) Considera-se como variáveis independentes o log do Endividamento e do IPCA Coluna VII) Considera-se todas as variáveis independentes
*p<0.1, **p<0.05, ***p<0.01

É interessante observar o R² de cada uma das regressões pois só apresentar um patamar acima de 20% quando a variável concernente aos ativos do IBOVESPA é incluída na regressão da Tabela 5.

Na Tabela 6, a variável do Índice de atividade econômica apresenta um efeito muito maior que as demais variáveis, é significativa a 1% e negativa, ou seja, quando a atividade econômica vai mal há um aumento do comovimento dos índices de confiança empresarial. Já o endividamento perde significância no último modelo, indicando que tal variável pode não ter grande importância para a confiança empresarial. O R² chega em um patamar de 30% ao incluir o IBC-BR no modelo,

demonstrando sua importância para explicar o comovimento. Podemos concluir que em momentos de piora econômica a confiança empresarial dos setores industriais é mais parecida do que em períodos de relativo avanço econômico.

Tabela 6: Resultados FDCC estimados incluindo IBC-BR

	log(DC.1)							
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
LIBC.1	-0.254*** (0.068)				-0.236*** (0.067)	-0.219*** (0.061)	-0.205*** (0.060)	-0.185*** (0.062)
L_Endividamento		-0.058** (0.028)						-0.034 (0.025)
L_IPCA			-0.019** (0.008)		-0.016** (0.008)		-0.013* (0.007)	-0.013* (0.007)
L_IBOV				0.044*** (0.008)		0.041*** (0.007)	0.041*** (0.007)	0.040*** (0.007)
Constant	0.879*** (0.334)	-0.475*** (0.049)	-0.343*** (0.014)	-0.564*** (0.033)	0.818** (0.331)	0.528* (0.304)	0.486 (0.302)	0.334 (0.321)
Observations	122	122	122	122	122	122	122	122
R ²	0.105	0.034	0.045	0.219	0.134	0.296	0.315	0.326
Adjusted R ²	0.098	0.026	0.037	0.212	0.120	0.284	0.298	0.303

Notas:

MQO simples cuja variável dependente é a média da correlação dinâmica dos Índices de confiança (Coluna I) Considera-se como variável independente o log do IBC.

(Coluna II) Considera-se como variável independente o log do Endividamento das famílias

(Coluna III) Considera-se como variável independente o log do Índice de Inflação (IPCA)

(Coluna IV) Considera-se como variável independente o log dos ativos do IBOVESPA

(Coluna V) Considera-se como variáveis independentes o log do IBC com defasagem e do IPCA

(Coluna VI) Considera-se como variáveis independentes o log do IBC defasado e do IBOVESPA

(Coluna VII) Considera-se como variáveis independentes o IBC e o IPCA

(Coluna VIII) Considera-se todas as variáveis independentes

*p<0.1, **p<0.05, ***p<0.01

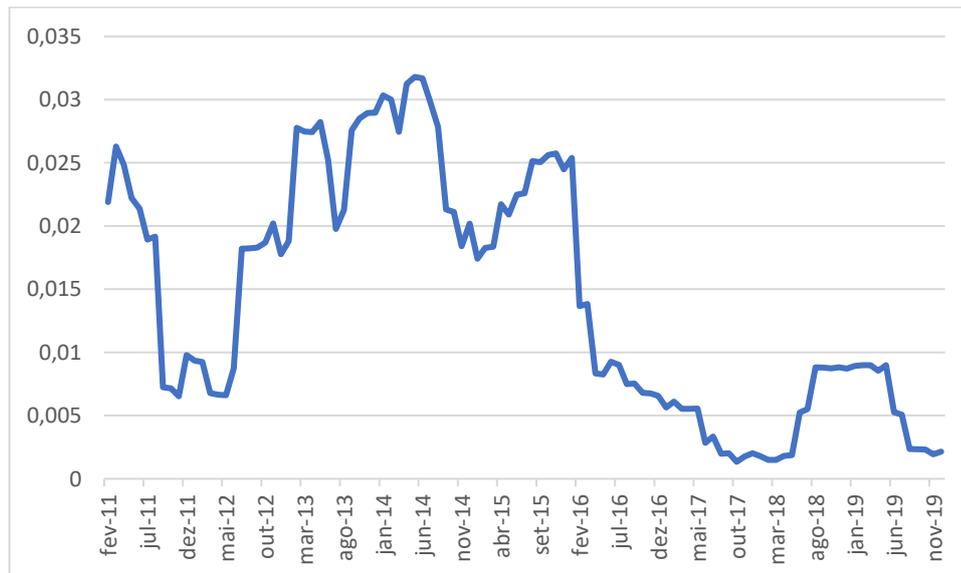
Os resultados da Tabela 6 confirmam que os índices de confiança podem funcionar como sinais do desempenho econômico, ou seja, pode indicar um aumento esperado nos gastos e nos investimentos, antecipando um crescimento futuro do Produto Interno Bruto (PIB). Tal resultado ocorre devido a confiança ser moldada pela percepção e pelos aspectos psicológicos. Quando as empresas têm a convicção de que a economia está em um bom estado, é mais provável que adotem comportamentos que promovam o crescimento econômico. É nesse aspecto que os resultados mostram um comovimento dos ICEI's muito mais maior ao incluir o IBC-BR na regressão.

4.3.2 Força variável da propagação de choques

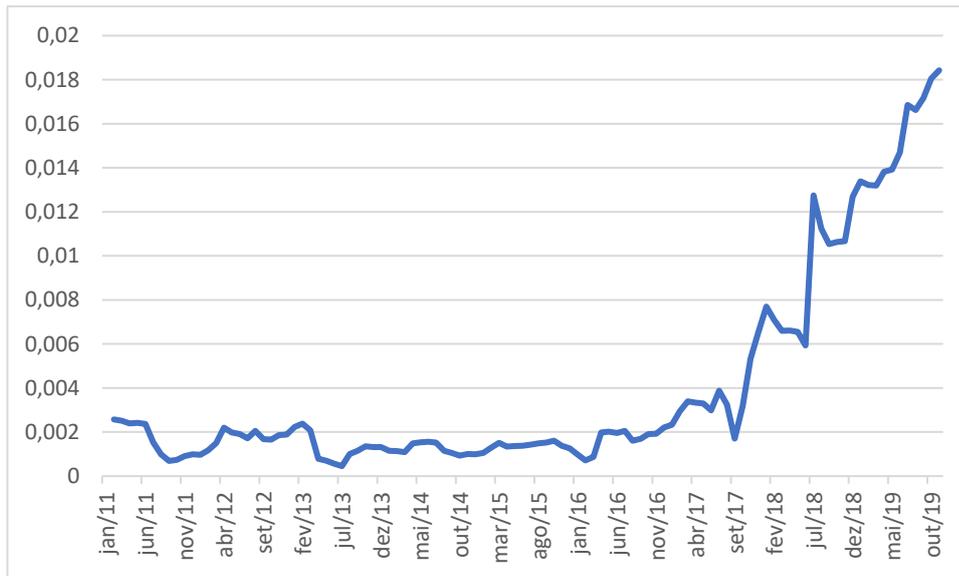
Conforme a metodologia empregada por Sandqvist (2017) para analisar se os movimentos nas correlações ocorrem devido a mudanças na variância dos fatores comuns, foi feita variâncias móveis (12 meses) da taxa de variação das variáveis independentes utilizadas na análise de regressão da Tabela 6. Com os resultados apresentados na Figura 4, Figura 5 e Figura 6 podemos observar que as variâncias dos fatores comuns flutuam consideravelmente, e claramente não são constantes ao longo do tempo.

A Figura 4 apresenta a variância móvel da taxa de variação do endividamento das famílias, onde podemos ver grande volatilidade ao longo dos anos, com um forte decréscimo a partir de 2016.

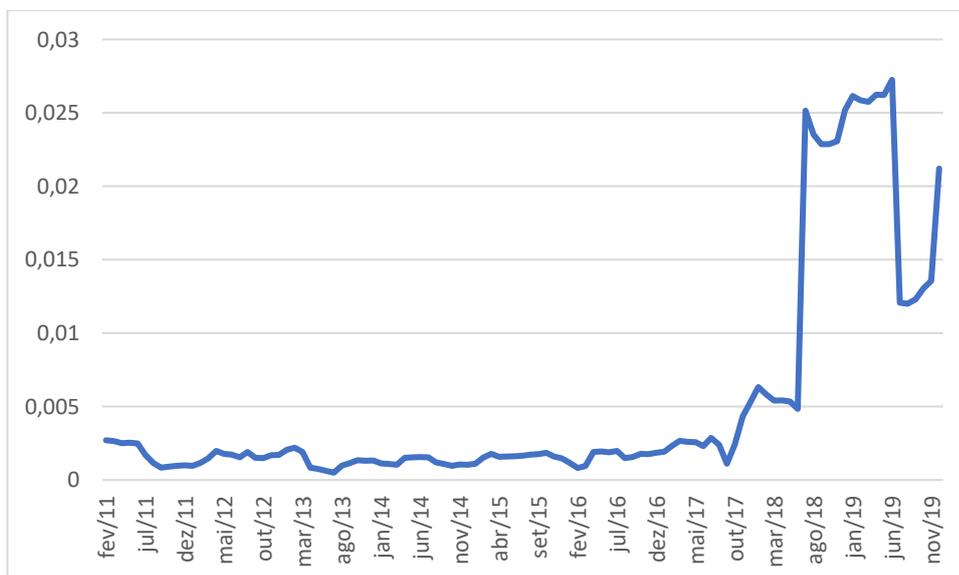
Figura 4: Variância do Endividamento



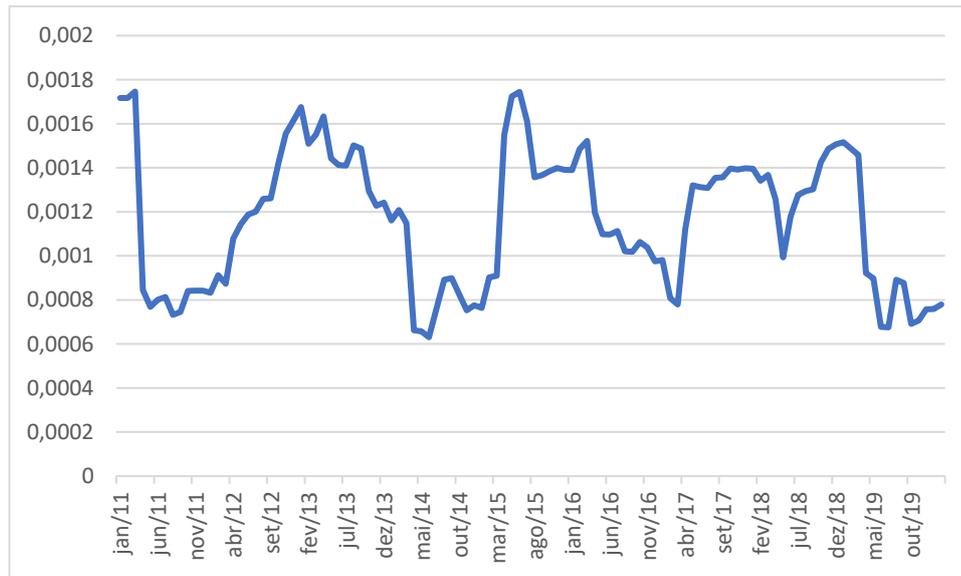
A figura 5 mostra a variância móvel da taxa de variação dos preços de ações do IBOVESPA, que apresenta estabilidade até 2016, quando começa um forte crescimento.

Figura 5: Variância IBOV

A figura 6 mostra a variância móvel da taxa de variação do Índice de IPCA. Assim, há uma grande estabilidade até meados de 2017, e a partir dessa data ocorre uma forte mudança de nível.

Figura 6: Variância do IPCA

Finalmente, a Figura 7 mostra a variância móvel da taxa de variação do IBC-
BR, onde há grande volatilidade, com períodos de crescimento e decréscimo ao longo dos anos.

Figura 7: Variância do IBC-BR

Os resultados implicam que as variâncias dos fatores comuns apresentam mudanças importantes a partir de 2015-17, quando ocorrem a crise econômica e política no cenário brasileiro, uma vez que, a variabilidade do endividamento cai consideravelmente, a variabilidade do IPCA e do IBOVESPA crescem exponencialmente. Desse modo, queremos enfatizar que essas descobertas mostram que as variâncias dos fatores agregados claramente não são constantes ao longo do tempo.

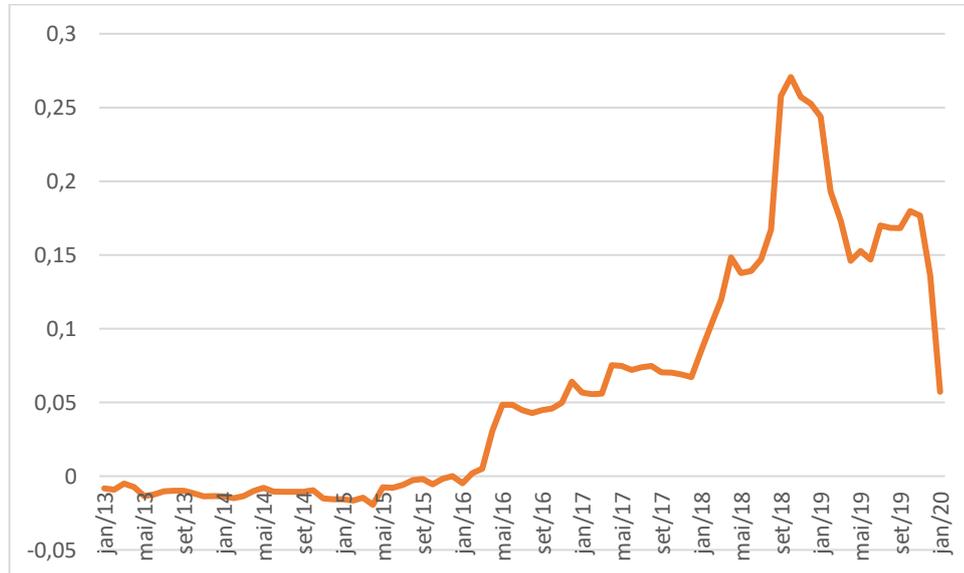
4.3.3 Mudanças na sensibilidade dos setores a fatores comuns

Finalmente, com o intuito de abordar as possíveis mudanças na sensibilidade do índice de confiança dos setores industriais aos fatores comuns, é realizada uma análise de regressão móvel do modelo (8) da Tabela 6, cujo tamanho do intervalo é de 36 meses, conforme mostram as figuras de 8 a 11. Desse modo, ao analisar os coeficientes padronizados em movimento nas figuras abaixo, podemos observar que cada um dos coeficientes das variáveis independentes do de tal modelo de regressão, há movimentos consideráveis, que inclusive mudam de sinal no período de crise, entre 2015 e 2017, em meio às incertezas políticas.

A figura 8 mostra o coeficiente de endividamento das famílias apresenta volatilidade ao longo dos anos, mantendo-se muito próximo de zero até janeiro de 2016, ou seja, tinha efeito nulo sobre a variável dependente. A partir desse período fica positiva com pico em setembro de 2019 e depois volta a ser decrescente. Após

esse período tem uma tendência de crescimento e passa a ser positivo, mudando de patamar em meados de 2018, com pico em outubro de 2018

Figura 8: Coeficiente do Endividamento



O coeficiente do IPCA na Figura 9 também apresenta volatilidade ao longo dos anos. Embora fique negativo até setembro de 2018, o vale ocorre em dezembro de 2016. A partir desse período fica positiva com pico em setembro de 2019 e depois volta a ser decrescente.

Figura 9: Coeficiente do IPCA



Já o coeficiente do preço das ações do Ibovespa, na Figura 10 apresenta certa estabilidade até meados de 2016, e após esse período apresenta alta volatilidade. A partir de fevereiro de 2016 há uma tendência de crescimento até fevereiro de 2017, e após essa data começa a decrescer, ficando negativo a partir de setembro de 2018,

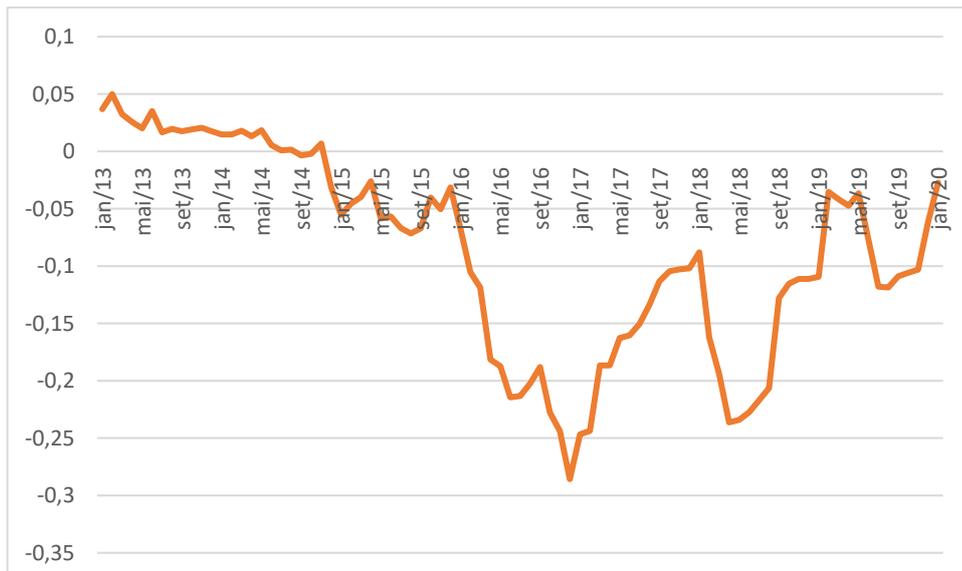
cujo vale ocorre em outubro de 2019, quando então começa uma tendência de crescimento.

Figura 10: Coeficiente do preço de ações do Ibovespa



Finalmente, temos na figura 11 coeficiente do IBC-BR, que se mantém estável e positivo até agosto de 2014, quando então fica negativo e começa a decrescer até chegar no vale em dezembro de 2016. Após esse período apresenta períodos de crescimento e decrescimentos.

Figura 11: Coeficiente do IBC-BR



Desse modo, os resultados mostram que as mudanças na sensibilidade dos setores aos fatores agregados desempenham um papel nos movimentos no

comovimento setorial, uma vez que variam no tempo. No entanto, mais pesquisas são necessárias para aprimorar a interpretação com mais detalhes.

5. CONSIDERAÇÕES FINAIS

Conforme ressaltamos anteriormente, a maior contribuição desse trabalho consiste em estudar a volatilidade condicional dos Índices de Confiança dos setores industriais brasileiros, haja vista que o comovimento setorial é crucial para explicar os ciclos de econômicos. Para alcançar esse fim, fizemos uma análise da dinâmica do contágio de confiança a partir da estrutura multivariada Dynamic Conditional Correlation (DCC-GARCH).

Desse modo, para explicar os ciclos econômicos é muito importante entender a dinâmica do comovimento setorial, uma vez que, a volatilidade agregada depende principalmente da correlação entre tais setores. Um alto nível de comovimento setorial geralmente é interpretado como uma evidência de fortes impactos diretos de choques agregados em todos os setores, bem como a transmissão de choques comuns e setoriais para toda a economia devido a ligações setoriais.

Os resultados mostraram que a soma de α e β estão muito próximos da unidade e são significativos, o que indica um alto nível de persistência no processo de correlação dos índices de confiança dos setores industriais, logo, as relações entre esses índices têm a tendência de se manterem relativamente constantes ao longo do tempo, ainda que haja mudanças no cenário econômico. Além disso, mudanças nas condições econômicas têm um impacto duradouro nas correlações ao longo do tempo. Apesar de um alto grau de persistência sugerir uma maior capacidade de prever as relações entre variáveis, essa característica também pode acarretar maior risco em caso de alterações significativas nas condições econômicas.

Além disso, os resultados apontam que a comovimentação dos índices de confiança dos setores industriais não é constante ao longo do tempo, ou seja, varia consideravelmente, sendo que em alguns períodos os setores se movem mais fortemente do que em outros momentos. Sandqvist (2017) afirma que com o passar do tempo as mudanças no comovimento interindustrial indicam alteração na magnitude dos choques comuns, mudança na sensibilidade dos setores a fatores comuns e/ou variação na intensidade da propagação de choques.

Assim, para medir a alteração na magnitude dos choques comuns investigamos quais fatores comuns têm relevância no comportamento conjunto do

índice de confiança nos setores industriais em um estudo de regressão em dois cenários. No primeiro foi utilizando como variáveis independentes os ativos do IBOVESPA em log, o índice de IPCA em log e o endividamento das famílias em log, todos defasados em um mês. No segundo cenário foi incluído IBC-BR defasado em dois meses. No primeiro cenário todas as variáveis estão relacionadas com o comovimento dos índices de confiança dos setores industriais, já no segundo cenário o IBC-BR apresentou maior importância na explicação desse comovimento. Assim, os resultados apontam que em momentos de piora econômica a confiança empresarial dos setores industriais é mais parecida do que em períodos de relativo avanço econômico. Em síntese, tal resultado aponta para a hipótese de que o agravamento das condições econômicas afeta a confiança das empresas nos setores industriais, afetando aspectos que vão desde as escolhas de investimento até a administração cotidiana das operações. A literatura aponta que a falta de confiança econômica desencadeia um ciclo de prudência e diminuição das atividades, o que, por sua vez, colabora para a criação de um ambiente empresarial mais complexo.

Os resultados desse trabalho também apontam que a variância móvel da taxa de variação dos fatores comuns muda ao longo do tempo, ou seja, há uma força variável na propagação dos choques que pode explicar o comovimento dos Índices de confiança. Da mesma forma, há mudanças na sensibilidade dos setores aos fatores agregados ao longo do tempo, e, portanto, desempenham um papel nos movimentos no comovimento setorial. Os resultados também revelam evidências limitadas de assimetrias nas correlações, o que implica que a maioria dos pares de setores reagem de forma semelhante a choques comuns, independentemente do sinal dos choques.

Em resumo, a relação entre o ciclo econômico e o comportamento dos setores econômicos é complexa e multifacetada. Cada setor pode reagir de maneira diferente às flutuações econômicas, dependendo de vários fatores, incluindo sua sensibilidade ao atual cenário econômico. Portanto, torna-se muito relevante mostrar a trajetória dinâmica do comovimento setorial dos índices de confiança entre setores industriais no Brasil em um contexto de crises econômicas, já que os vieses de expectativa podem levar a mudança na trajetória dos ciclos econômicos por impactar as decisões dos agentes. Logo, faz-se necessário que os investidores, empresas e formuladores de políticas entendam essas relações para tomar decisões informadas e responder eficazmente às mudanças na economia.

Vale ressaltar que o tema desse trabalho é um território pouco explorado pela literatura, e assim representa uma contribuição inicial para o estudo sobre comovimento setorial relacionadas à confiança empresarial, uma vez que, há um vasto oceano de possibilidades ainda a serem exploradas nesse tema. As descobertas apresentadas aqui, longe de representarem um ponto final, são, na verdade, um convite para uma exploração mais profunda e abrangente sobre o estudo do papel da confiança empresarial na economia, de modo a aperfeiçoar a previsão de trajetórias futuras das variáveis macroeconômicas e entender o funcionamento do cenário econômico vigente. Portanto é primordial que as pesquisas futuras se dediquem a explorar as lacunas identificadas, aprimorar metodologias e, assim, contribuir para a construção de um conhecimento mais completo. Portanto, este trabalho não é uma conclusão definitiva, mas sim um ponto de partida.

BIBLIOGRAFIA

- Akkoc, U., & Civcir, I. (2019). Dynamic Linkages Between Strategic Commodities And Stock Market In Turkey: Evidence From SVAR-DCC-GARCH Model. *Resources Policy*, 62, 231-239.
- Batchelor, R., & Dua, P. (1998). Improving Macro-Economic Forecasts: The Role Of Consumer Confidence. *International Journal of Forecasting*, 14(1), 71-81.
- Bauwens, L., Laurent, S., & Rombouts, J. V. (2006). Multivariate GARCH Models: a Survey. *Journal Of Applied Econometrics*, 21(1), 79-109.
- Bachmann, R., & Elstner, S. (2015). Firm optimism and pessimism. *European Economic Review*, 79, 297-325.
- Bezerra, I. (2017). Índice de Incerteza Empresarial: Uma Abordagem Usando Microdados de Sondagens. *Economia Aplicada*, 21(4), 659-679.
- Billio, M., & Caporin, M. (2009). A Generalized Dynamic Conditional Correlation Model For Portfolio Risk Evaluation. *Mathematics And Computers In Simulation*, 79(8), 2566-2578.
- Billio, M., Caporin, M., & Gobbo, M. (2006). Flexible Dynamic Conditional Correlation Multivariate GARCH Models For Asset Allocation. *Applied Financial Economics Letters*, 2(02), 123-130.
- Bollerslev, T. (1990). Modelling The Coherence In Short-Run Nominal Exchange Rates: A Multivariate Generalized ARCH Model. *The review of economics and statistics*, 498-505.
- Bollerslev, T., Engle, R. F., & Wooldridge, J. M. (1988). A Capital Asset Pricing Model With Time-Varying Covariances. *Journal of political Economy*, 96(1), 116-131.
- Bollerslev, T., Engle, R. F., & Nelson, D. B. (1994). ARCH models. *Handbook of econometrics*, 4, 2959-3038.
- Bovi, M. (2009). Economic Versus Psychological Forecasting. Evidence From Consumer Confidence Surveys. *Journal of Economic Psychology*, 30(4), 563-574.

- Cappiello, L., Engle, R. F., & Sheppard, K. (2006). Asymmetric Dynamics In The Correlations Of Global Equity And Bond Returns. *Journal of Financial econometrics*, 4(4), 537-572.
- Caporin, M., & McAleer, M. (2013). *Ten Things You Should Know About DCC* (No. 13-048/III). Tinbergen Institute Discussion Paper.
- Cassou, S. P., & Vázquez, J. (2014). Employment Comovements at The Sectoral Level Over The Business Cycle. *Empirical Economics*, 46, 1301-1323.
- Ciner, C. (2014). The Time Varying Relation Between Consumer Confidence And Equities. *Journal of Behavioral Finance*, 15(4), 312-317.
- Coibion, O., Gorodnichenko, Y., & Kumar, S. (2018). How Do Firms Form Their Expectations? New Survey Evidence. *American Economic Review*, 108(9), 2671-2713.
- Confederação Nacional da Indústria (2015). Metodologia do Índice de Confiança do Empresário Industrial (ICEI) / Confederação Nacional da Indústria. – Brasília.
- Christiano, L. J., & Fitzgerald, T. J. (1998). The business cycle: it's still a puzzle. *Economic Perspectives-Federal Reserve Bank Of Chicago*, 22, 56-83.
- del Río, I. P. D. (2016). *El Papel De La Confianza En La Evolución De La Economía: Evidencia Empírica Para El Caso Español* (Doctoral Dissertation, Universidade da Coruña).
- Dibiasi, A., & Iselin, D. (2021). Measuring Knightian Uncertainty. *Empirical Economics*, 61(4), 2113-2141.
- DiCecio, R. (2009). Sticky Wages And Sectoral Labor Comovement. *Journal of Economic Dynamics and Control*, 33(3), 538-553.
- Engle, R. (2002). Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business & Economic Statistics*, 20(3), 339-350.
- Engle, R. F., & Issler, J. V. (1993). Common Trends And Common Cycles In Latin America. *Revista Brasileira de Economia*, 47(2), 149-176.

- Engle, R. F., & Kroner, K. F. (1995). Multivariate Simultaneous Generalized ARCH. *Econometric theory*, 11(1), 122-150.
- Engle III, R. F., & Sheppard, K. (2001). Theoretical And Empirical Properties Of Dynamic Conditional Correlation Multivariate GARCH.
- Foerster, A. T., Sarte, P. D. G., & Watson, M. W. (2011). Sectoral Versus Aggregate Shocks: A Structural Factor Analysis Of Industrial Production. *Journal of Political Economy*, 119(1), 1-38.
- Forni, M., & Reichlin, L. (1998). Let's Get Real: A Factor Analytical Approach To Disaggregated Business Cycle Dynamics. *The Review of Economic Studies*, 65(3), 453-473.
- Gausden, R., & Hasan, M. S. (2016). Would Information On Consumer Confidence Have Helped To Predict UK Household Expenditure During The Recent Economic Crisis?. *Applied Economics*, 48(18), 1695-1709.
- Gausden, R., & Hasan, M. S. (2018). An Assessment Of The Contribution Of Consumer Confidence Towards Household Spending Decisions Using UK Data. *Applied Economics*, 50(12), 1395-1411.
- Ghalanos, A. (2022). The Rmgarch Models: Background And Properties.(Version 1.3-0)
- Hafner, C. M., & Franses, P. H. (2009). A Generalized Dynamic Conditional Correlation Model: Simulation And Application To Many Assets. *Econometric Reviews*, 28(6), 612-631.
- Hafner, C., & Franses, P. H. (2003). *A Generalized Dynamic Conditional Correlation Model For Many Asset Returns* (No. EI 2003-18).
- Hofmann, R. M. (2012). Comportamento Da Confiança do Consumidor E Do Empresário Industrial Brasileiro no Período 2010/11. *Indicadores Econômicos FEE*, 40(1).
- Hornstein, A. (2000). The Business Cycle And Industry Comovement. *FRB Richmond Economic Quarterly*, 86(1), 27-48.

- Júnior, J. L. R., Neto, S. A. L., Claro, D. P., Lucci, C. R., Bolzani, L. C., & de Carvalho, M. D. (2009). Índice de Confiança do Empresário de Pequenos e Médios Negócios no Brasil (IC-PMN): Metodologia e Resultados Preliminares. Insper Working Paper.
- Keynes, J. M. (1936). *A Teoria Geral do Emprego, do Juro e da Moeda*. São Paulo, SP: Atlas.
- Lemmon, M., & Portniaguina, E. (2006). Consumer Confidence And Asset Prices: Some Empirical Evidence. *The Review of Financial Studies*, 19(4), 1499-1529.
- Long, J. B., and C. I. Plosser. 1987. "Sectoral Vs. Aggregate Shocks in the Business Cycle." *The American Economic Review* 77 (2): 333–336.
- McAleer, M., Chan, F., Hoti, S., & Lieberman, O. (2008). Generalized Autoregressive Conditional Correlation. *Econometric Theory*, 24(6), 1554-1583.
- Massenot, B., & Pettinicchi, Y. (2018). Can Firms See Into The Future? Survey Evidence From Germany. *Journal of Economic Behavior & Organization*, 145, 66-79.
- Orskaug, E. (2009). *Multivariate Dcc-GARCH Model:-With Various Error Distributions* (Master's thesis, Institutt for matematiske fag).
- Paradiso, A., Kumar, S., & Margani, P. (2014). Are Italian Consumer Confidence Adjustments Asymmetric? A Macroeconomic and Psychological Motives Approach. *Journal of Economic Psychology*, 43, 48-63.
- Potter, S. (1999). Fluctuations In Confidence And Asymmetric Business Cycles. *FRB of New York Staff Report*, (66).
- Resende, M., & Zeidan, R. (2015). Psychological Biases And Economic Expectations: Evidence On Industry Experts. *Journal of Neuroscience, Psychology, and Economics*, 8(3), 160.
- Sandqvist, A. P. (2017). Dynamics Of Sectoral Business Cycle Comovement. *Applied Economics*, 49(47), 4742-4759.
- Shea, J. (2002). Complementarities And Comovements. *Journal of Money, Credit, and Banking*, 34(2), 412-433.
- Taylor, K., & McNabb, R. (2007). Business Cycles And The Role Of Confidence: Evidence For Europe. *Oxford Bulletin of Economics and Statistics*, 69(2), 185-208.

Tse, Y. K., & Tsui, A. K. (2001). A Multivariate GARCH Model With Time-Varying Correlations. *Science Direct Working Paper*, (S1574-0358), 04.

APÊNDICE

Tabela A1: Resultados dos testes Dickey-Fuller para cada setor

Teste ADF					
Em nível	Resultado	Em Log	Resultado	1ª Diferença	Resultado
Alimentos	-0.49	Alimentos	-0.23	Alimentos	-8.17
Bebidas	-0.78	Bebidas	-0.40	Bebidas	-7.97
Biocombustíveis	-0.64	Biocombustíveis	-0.27	Biocombustíveis	-11.15
Borracha	-0.45	Borracha	-0.10	Borracha	-8.98
Calçados	-0.72	Calçados	-0.28	Calçados	-8.37
Const. De edifício	-0.57	Const. De edifício	-0.24	Const. De edifício	-8.37
Couro	-0.55	Couro	-0.17	Couro	-7.89
Diversos	-0.62	Diversos	-0.62	Diversos	-0.62
elétricos	-0.59	elétricos	-0.20	elétricos	-8.50
Farmacêuticos	-0.66	Farmacêuticos	-0.34	Farmacêuticos	-10.47
Impressão	-0.63	Impressão	-0.25	Impressão	-8.59
Informática	-0.77	Informática	-0.31	Informática	-8.58
Infraestrutura	-0.73	Infraestrutura	-0.73	Infraestrutura	-0.73
Madeira	-0.38	Madeira	-0.08	Madeira	-9.75
Máquinas	-0.53	Máquinas	-0.17	Máquinas	-8.37

Teste ADF					
Em nível	Resultado	Em Log	Resultado	1ª Diferença	Resultado
Metal	-0.59	Metal	-0.21	Metal	-7.89
Metalurgia	-0.71	Metalurgia	-0.28	Metalurgia	-8.04
Minerais	-0.57	Minerais	-0.21	Minerais	-8.91
Minerais não metálicos	-0.61	Minerais não metálicos	-0.29	Minerais não metálicos	-9.13
Móveis	-0.71	Móveis	-0.27	Móveis	-8.83
Papel	-0.66	Papel	-0.26	Papel	-7.97
Perfumaria	-0.67	Perfumaria	-0.35	Perfumaria	-9.02
Plásticos	-0.71	Plásticos	-0.29	Plásticos	-7.87
Serv. De construção	-0.64	Serv. De construção	-0.30	Serv. De construção	-8.50
Têxteis	-0.60	Têxteis	-0.20	Têxteis	-8.22
Veículos	-0.51	Veículos	-0.16	Veículos	-8.61
Vestuário	-0.70	Vestuário	-0.27	Vestuário	-8.09

Tabela A2: Critério de informação FDCC

	Modelo 1 ARMA (0,0)	Modelo 2 ARMA (1,1)	Modelo 3 ARMA (1,0)	Modelo 4 ARMA (0,1)
Akaike	-65,11	-71,41	-69,33	-67,89
Bayes	-53,87	-58,98	-57,50	-56,05
Shibata	-70,74	-77,77	-75,33	-73,88
Hannan-Quinn	-60,54	-66,36	-64,52	-63,08

Tabela A3: Critério de informação ADCC

	Modelo 1 ARMA (0,0)	Modelo 2 ARMA (1,1)	Modelo 3 ARMA (1,0)	Modelo 4 ARMA (0,1)
Akaike	-71,80	-76,24	-74,94	-72,84
Bayes	-60,53	-63,80	-63,09	-60,98
Shibata	-77,45	-82,62	-80,96	-78,85
Hannan-Quinn	-67,23	-71,19	-70,13	-68,03

Tabela A4: Teste diagnóstico para ARMA (i,k) e resíduos para os setores industriais

Setores	w LB (20)	Arch LM (10)	Skewness	Kurtosis	Jarque-Bera
Bebidas	28,73*	0,79	-3,14	26,72	3311,21***
Alimentos	38,72***	2,30	-3,96	38,99	7466,47***
Biocombustível	12,476	5,24	-2,96	28,00	3630,25***
Borracha	25,413	4,14	-1,76	16,18	1023,26***
Calçados	19,285	6,51	-3,50	36,04	6273,90***
Cons. Edifício	24,220	0,75	-4,09	37,23	6811,70***
Couro	31,708	9,61	-1,16	11,19	398,51***
Diversos	19,311	0,51	-4,55	41,67	8681,02***
Elétricos	37,86***	5,61	-2,07	19,81	1648,40***
Farmacêuticos	22,906	22,81**	-0,20	7,69	121,91***
Impressão	25,129	2,80	-2,52	23,88	2536,97***
Informática	21,583	10,92	-1,46	16,92	1113,29***
Infraestrutura	27,840	0,46	-2,93	24,15	2648,42***
Madeira	18,473	11,02	-2,66	28,81	3819,53***
Máquinas	30,48*	5,10	-2,47	24,49	2674,81***
Metal	14,487	0,78	-4,35	41,09	8395,24***
Metalurgia	22,260	3,71	-2,44	22,37	2194,61***
Minerais	27,690	4,69	-2,82	28,23	3677,05***
Minerais não metálicos	19,259	4,06	-2,35	20,08	1726,02***
Móveis	26,272	3,15	-4,16	43,44	9376,17***
papel	31,40*	2,49	-2,22	18,44	1419,09***
Perfumaria	19,021	18,01*	-0,09	6,05	51,33***
Plásticos	36,229	3,10	-2,61	24,13	2605,71***
Serv. de construção	25,978	2,63	-3,00	28,42	3752,25***
Têxteis	29,15*	4,26	-3,28	32,65	5070,82***
Veículos	24,391	7,29	-2,26	21,58	2012,31***
Vestuário	27,293	1,61	-3,82	36,07	6335,71***

Gráfico A1: Índice de Confiança do Empresário Industrial (ICEI)

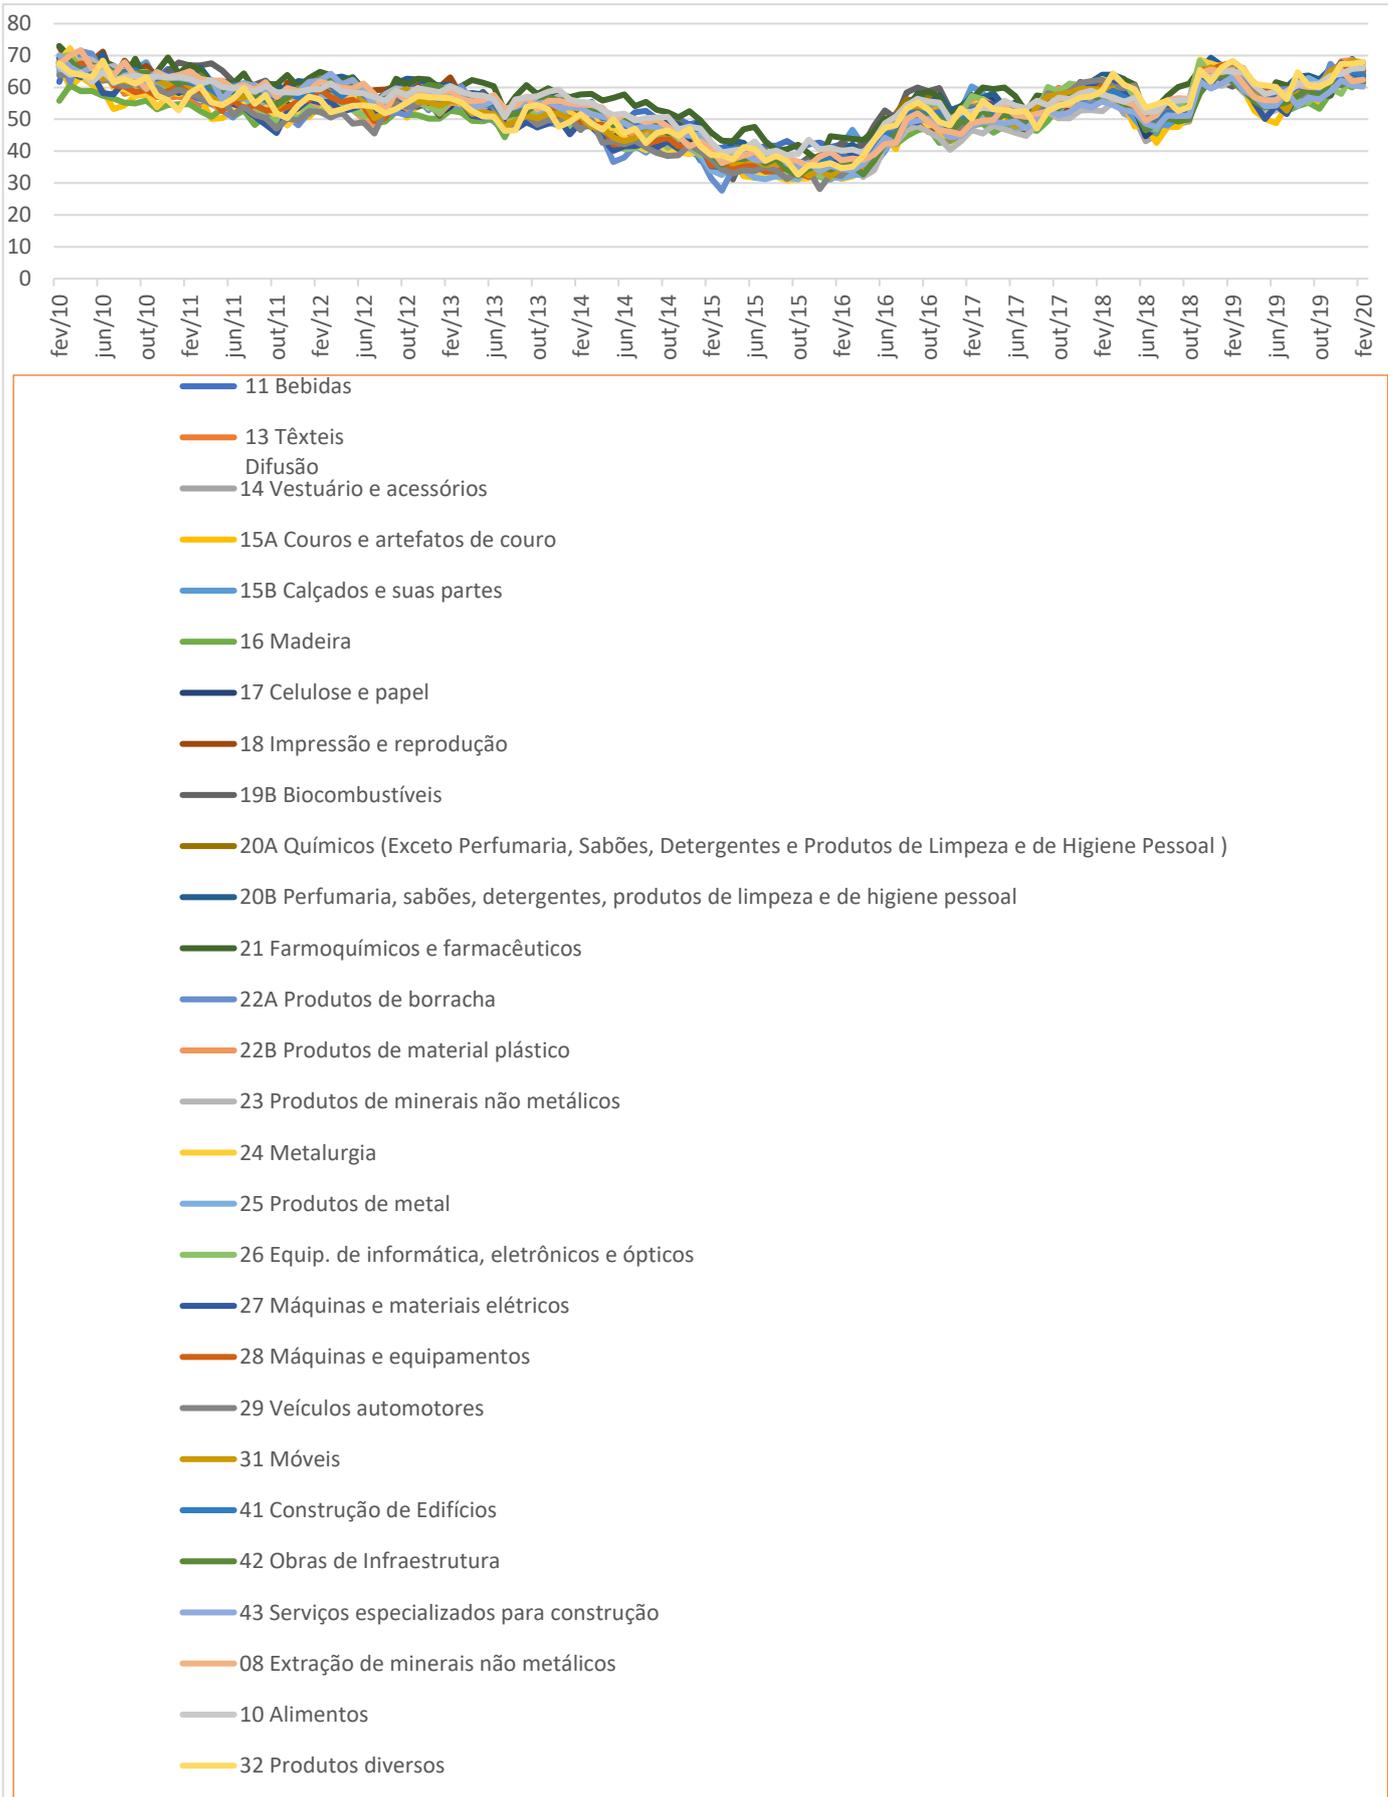
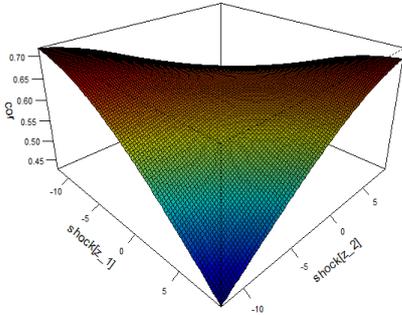
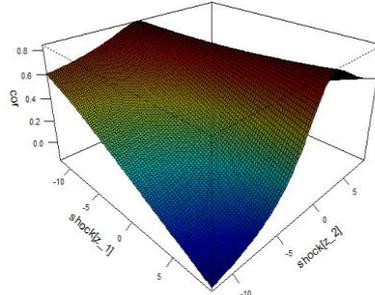


Gráfico A2: Correlação dos Choques de Novos Impactos de 9 Setores Industriais Sobre o Setor de Bebidas

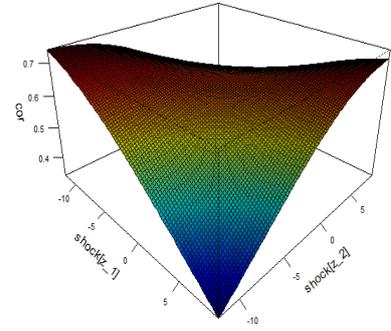
DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_calçados



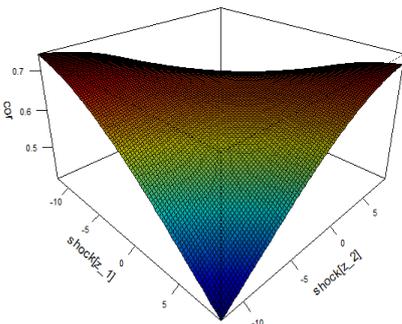
DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_alimentos



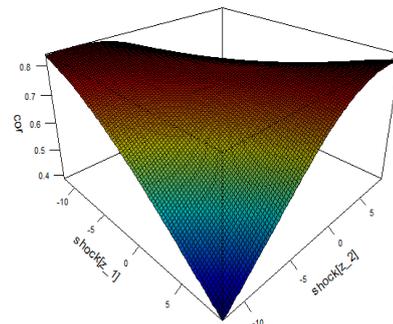
DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_biocombustiveis



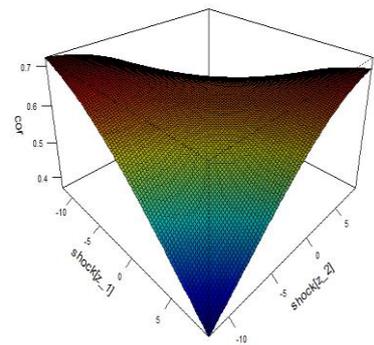
DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_borracha



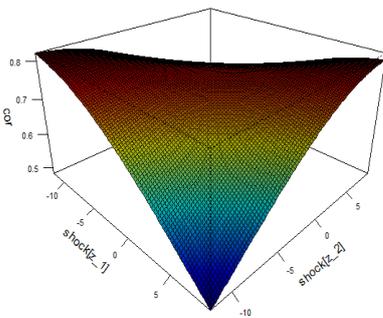
DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_cons.edificio



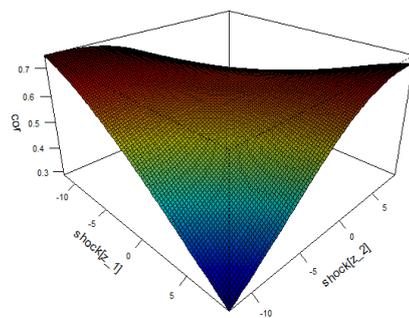
DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_Couro



DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_diversos



DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_eletricos



DCC News Impact Correlation Surface
d_seas_bebidas-d_seas_farmaceuticos

