

**FUNDAÇÃO UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL – UFMS**  
**ESCOLA DE ADMINISTRAÇÃO E NEGÓCIOS – ESAN**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CONTÁBEIS – PPGCC**

**MARCUS VINÍCIUS PEREIRA GUASSO**

**EXPECTATIVA E REALIDADE: UMA ANÁLISE COMPARATIVA DOS EFEITOS  
DA OPERAÇÃO CARNE FRACA SOBRE O SEGMENTO DE CARNES A PARTIR  
DOS INDICADORES CONTÁBEIS**

**Campo Grande**  
**2021**

**MARCUS VINÍCIUS PEREIRA GUASSO**

**EXPECTATIVA E REALIDADE: UMA ANÁLISE COMPARATIVA DOS EFEITOS  
DA OPERAÇÃO CARNE FRACA SOBRE O SEGMENTO DE CARNES A PARTIR  
DOS INDICADORES CONTÁBEIS**

Dissertação apresentada ao Programa de Pós-Graduação *stricto sensu* em Ciências Contábeis da Fundação Universidade Federal de Mato Grosso do Sul, como requisito para a obtenção do título de Mestre.

**Linha de Pesquisa:** Contabilidade Societária e Finanças.

**Orientadora:** Prof.<sup>a</sup>. Dr.<sup>a</sup>. Elisabeth de Oliveira Vendramin

**Campo Grande**

**2021**

**MARCUS VINÍCIUS PEREIRA GUASSO**

**EXPECTATIVA E REALIDADE: UMA ANÁLISE COMPARATIVA DOS EFEITOS  
DA OPERAÇÃO CARNE FRACA SOBRE O SEGMENTO DE CARNES A PARTIR  
DOS INDICADORES CONTÁBEIS**

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul – UFMS como requisito para a obtenção do título de Mestre em Contabilidade.

**COMISSÃO JULGADORA:**

---

**Prof. Dr. Lucas Casonato Jacinto**  
**Pontifícia Universidade Católica do Paraná – PUCPR**

---

**Prof. Dr. Jorge Luís Sanchez Arevalo**  
**Fundação Universidade Federal de Mato Grosso do Sul – UFMS**

---

**Prof.<sup>a</sup> Dr.<sup>a</sup> Elisabeth de Oliveira Vendramin**  
**Fundação Universidade Federal de Mato Grosso do Sul – UFMS**  
**Professora Orientadora – Presidente da Banca Examinadora**

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

**Campo Grande – MS, 25 de agosto de 2021**

## RESUMO

Guasso, M. V. P. *Expectativa e realidade: Uma análise comparativa dos efeitos da Operação Carne Fraca sobre o segmento de carnes e derivados a partir dos indicadores contábeis* (Dissertação de Mestrado). Escola de Administração e Negócios – ESAN, Fundação Universidade Federal de Mato Grosso do Sul – UFMS, Campo Grande, MS, Brasil.

O objetivo do presente trabalho foi analisar os possíveis efeitos da deflagração da Operação Carne Fraca observados na evolução dos indicadores contábeis das empresas do segmento de carnes e derivados, à luz da teoria do efeito contágio. Para tal, foi utilizado o modelo de previsão de séries temporais *FFORMA*, com o intuito de efetuar previsões para os dados esperados em um cenário hipotético sem a Operação Carne Fraca e compará-los com os dados observados na presença da operação. Os resultados constatarem maior eficiência do modelo *FFORMA* em prever os dados das empresas antes da deflagração da Operação Carne Fraca, indicando possível influência da operação nos dados observados, corroborando a análise gráfica. Adicionalmente, os resultados sugerem indícios de efeito contágio nos indicadores de rentabilidade da empresa Minerva e nos indicadores de liquidez da empresa Marfrig. A presente pesquisa contribuiu para o campo da pesquisa científica em contabilidade financeira ao propor o uso de uma metodologia de previsão de séries temporais pouco explorada na análise dos dados contábeis. Tal metodologia teve destaque na principal competição de previsão de séries temporais, *M Competition*, publicada em 2020 e, portanto, seu uso configura inovação na pesquisa em contabilidade financeira.

**Palavras-chave:** Indicadores contábeis. Carne fraca. Séries temporais. *FFORMA*.

## ABSTRACT

Guasso, M. V. P. *Expectation and reality: A comparative analysis of the Carne Fraca Operation effects on the meat and derivatives segment using accounting indicators* (Dissertação de Mestrado). Escola de Administração e Negócios – ESAN, Fundação Universidade Federal de Mato Grosso do Sul – UFMS, Campo Grande, MS, Brasil.

This study purpose was to analyze the possible effects on accounting indicators evolution from companies of the meat and derivatives segment due to the outbreak of *Carne Fraca* Operation, drawing upon the contagion effect theory. To this end, we adopted the FFORMA time series forecasting model to estimate the expected data in a hypothetical scenario without the *Carne Fraca* Operation and compared them with the data observed with the operation. The results showed greater efficiency of the FFORMA model in predicting companies' data before the *Carne Fraca* Operation outbreak, indicating a possible operation influence on the observed data, corroborating the graphical analysis. Moreover, the results suggest the contagion effect in the Minerva company's profitability and Marfrig company's liquidity indicators. This study has contributed to the financial accounting literature by proposing a time series forecasting methodology that has been little explored in the accounting data analysis. The main temporal series forecasting competition, M Competition, highlighted this methodology in 2020, and its use constitutes innovation and methodological contribution.

**Keywords:** Accounting indicators. *Carne fraca*. Time series. FFORMA.

## SUMÁRIO

|                                                                          |            |
|--------------------------------------------------------------------------|------------|
| <b>1 INTRODUÇÃO .....</b>                                                | <b>6</b>   |
| <b>2 REFERENCIAL TEÓRICO.....</b>                                        | <b>11</b>  |
| 2.1 Análise das Demonstrações Contábeis .....                            | 11         |
| 2.1.1 Regulamentação e normas .....                                      | 11         |
| 2.1.2 Demonstrações contábeis .....                                      | 13         |
| 2.1.3 Indicadores contábeis .....                                        | 16         |
| 2.1.3.1 Indicadores de Liquidez .....                                    | 17         |
| 2.1.3.2 Indicadores de Endividamento .....                               | 18         |
| 2.1.3.3 Indicadores de Rentabilidade .....                               | 20         |
| 2.2 Efeito Contágio.....                                                 | 22         |
| <b>3 OPERAÇÃO CARNE FRACA .....</b>                                      | <b>24</b>  |
| 3.1 A Operação .....                                                     | 24         |
| 3.2 Repercussão na Mídia .....                                           | 26         |
| 3.3 Reação dos Agentes Econômicos.....                                   | 27         |
| 3.4 Estudos Relacionados.....                                            | 29         |
| <b>4 PROCEDIMENTOS METODOLÓGICOS.....</b>                                | <b>31</b>  |
| 4.1 Características da Pesquisa.....                                     | 31         |
| 4.2 Universo Populacional.....                                           | 31         |
| 4.3 Coleta de Dados .....                                                | 32         |
| 4.4 Tratamento dos Dados .....                                           | 34         |
| 4.5 Projeção dos Dados.....                                              | 36         |
| 4.5.1 Contextualização.....                                              | 36         |
| 4.5.2 Competição M4.....                                                 | 38         |
| 4.5.3 Modelos de previsão de séries temporais .....                      | 39         |
| 4.5.4 Modelo fforma .....                                                | 40         |
| 4.5.5 Utilização do modelo <i>FFORMA</i> .....                           | 40         |
| <b>5 ANÁLISE DE RESULTADOS .....</b>                                     | <b>43</b>  |
| <b>6 CONSIDERAÇÕES FINAIS .....</b>                                      | <b>55</b>  |
| <b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>                                   | <b>57</b>  |
| <b>APÊNDICE A – Rotinas utilizadas para o modelo <i>FFORMA</i> .....</b> | <b>64</b>  |
| <b>APÊNDICE B – Rotinas utilizadas para o <i>t-test</i> .....</b>        | <b>107</b> |

## 1 INTRODUÇÃO

Dono de uma extensão territorial de 8.510.295,914 km<sup>2</sup>, conforme aponta o Instituto Brasileiro de Geografia e Estatística – IBGE (IBGE, 2020), onde está distribuída sua população de mais de 210 milhões de pessoas (IBGE, 2019b), o Brasil tem a produção de alimentos como um talento natural, apresentando ganhos na produtividade impulsionados pelo clima favorável e pela farta oferta de grãos, mesmo sem a necessidade do emprego de alta tecnologia, conforme aponta a Associação Brasileira de Proteína Animal – ABPA (2020).

Essa produtividade pode ser observada em seu PIB, o qual, em 2020, atingiu aproximadamente R\$ 7,4 trilhões, significando uma queda de 4,1% em relação ao ano anterior. Embora o PIB aponte queda, o único setor a crescer foi justamente a agropecuária, com a pecuária de corte representando 10% do total do PIB. Tal representatividade advém de um crescimento real de 6% em relação ao ano anterior, evidenciando a força do setor na economia brasileira, segundo dados da Associação Brasileira das Indústrias Exportadoras de Carnes – ABIEC (2021).

Tal importância pode ser notada ao analisar o mercado de carne bovina em 2020, quando, mesmo sendo o terceiro maior consumidor do produto – atrás apenas de Estados Unidos da América e China, o Brasil teve exportação recorde em volume e faturamento. Essa marca foi impulsionada pela demanda chinesa, que se consolidou como o principal importador da carne brasileira. Ainda que a maior parte da carne produzida (73,58%) tenha como destino o mercado interno, nota-se a importância da exportação para o setor (ABIEC, 2021).

Além disso, a exportação da pecuária de corte representou quase 20% do total da exportação do agronegócio. Entretanto, não é só a carne bovina, representando 43,09% da exportação da pecuária de corte, que merece destaque no comércio internacional. A carne de frango também teve uma representatividade parecida, sendo responsável por 30,44% dessa exportação, além do comércio de carne suína, que representou 11,46% da exportação da pecuária de corte (ABIEC, 2021).

Em 2020, a produção da carne de frango dividiu-se em: 69% para o mercado interno e o restante para a exportação, qualificando o Brasil como o maior exportador de carne de frango no período. Grande parte dessa produção teve Ásia e Oriente Médio como destino externo, os quais foram responsáveis por mais de 70% do consumo dessa carne (ABPA, 2021).

Ao mesmo tempo, a carne suína teve 77% de sua produção voltada para o mercado interno, restando apenas 23% para a exportação. No entanto, ainda assim, colocou o Brasil como quarto maior exportador desse produto, destacando-se novamente a Ásia que, sozinha, consumiu aproximadamente 79% dessa exportação (ABPA, 2021).

Tanto a suinocultura quanto a avicultura de uma forma geral, têm uma importante participação social, gerando milhares de empregos diretos e indiretos em seu modelo de produção integrado, com mais de 100 mil famílias engajadas. Além dos empregos e rendas gerados, tais produtos e seus derivados garantem a segurança alimentar no Brasil, onde 98,5% dos lares consomem algum tipo de proteína animal de maneira regular (ABPA, 2021).

De forma geral, segundo os resultados definitivos do Censo Agropecuário de 2017 (IBGE, 2019a), em comparação com os números do Censo Agropecuário anterior, de 2006, houve um aumento de 5% na área total de estabelecimentos agropecuários no Brasil. No entanto, nota-se uma redução de 2% na quantidade de estabelecimentos, o que pode indicar um aumento da concentração do setor. De acordo com esses dados, existem em torno de cinco milhões de propriedades rurais, espalhadas por uma área total de mais de 350 milhões de hectares, gerando por volta de 15 milhões de empregos diretos.

Relacionada ao segmento de carnes e derivados, em 2017, foi deflagrada pela Polícia Federal a Operação Carne Fraca, conforme aponta o Inquérito Policial – IPL (IPL 0136/2015, 2017), a qual estava baseada em um suposto esquema fraudulento de corrupção por fiscais do Ministério da Agricultura, Pecuária e Abastecimento (MAPA) e envolvia as gigantes do setor: JBS S.A. e BRF S.A..

Essa operação investigou uma suposta rede de irregularidades que estaria beneficiando grande parte da estrutura de fornecimento das principais empresas do segmento de carnes do país (Polícia Federal, 2017a; MAPA, 2017b; Giehl, 2017), gerando apreensão e insegurança em todo o setor. Seja essa insegurança por motivação fitossanitária, dada a expectativa gerada quanto à qualidade dos alimentos; ou a própria insegurança econômica, de como todo esse processo impactaria no comércio (DIEESE, 2017; Magioli, 2017).

Visto que eventos imprevisíveis, de natureza sistêmica, podem atingir tanto as ações dos tomadores de decisão das próprias empresas quanto os agentes que interagem com elas, seus impactos podem afetar o comportamento financeiro das



empresas e, portanto, serem verificados por meio de suas demonstrações contábeis (Matarazzo, 1998; Silva, 2019). Dessa forma, faz-se necessária a constante avaliação das empresas que compõem o setor, bem como as possíveis influências que sofrem do meio externo. Nesse sentido, a presente pesquisa visa abordar o contexto da Operação Carne Fraca, analisando seus possíveis impactos.

Via de regra, a análise baseia-se nas demonstrações tidas como obrigatórias pela Lei nº 6.404/76 (Assaf Neto, 2020), entre as quais, as que usualmente recebem maior ênfase são o Balanço Patrimonial e a Demonstração do Resultado do Exercício (Marion, 2019). Para garantir a comparabilidade da análise entre empresas de diferentes tamanhos, pode-se relacionar os valores absolutos dessas demonstrações, encontrando valores relativos e, assim, formando índices, aqui tratados por indicadores contábeis (Assaf Neto, 2020; Marion, 2019; Martins et al., 2019; Ross et al., 2015).

A literatura acadêmica em contabilidade financeira já reconhece que os escândalos investigados pelas operações da Polícia Federal podem afetar os demonstrativos contábeis das empresas ao influenciar as expectativas dos acionistas. Bastos et al. (2016) analisaram os impactos da operação Lava Jato, em meio à crise internacional do petróleo, nos retornos das ações e nos indicadores contábeis da Petrobras, antes e depois da deflagração dessa operação. Os autores encontraram uma certa estabilidade quanto aos retornos das ações e um impacto negativo nos indicadores da empresa: queda nos indicadores de liquidez e de rentabilidade, além de um aumento no endividamento da entidade.

No mesmo sentido, mas com o foco voltado para a Operação Carne Fraca, pode-se destacar o estudo de Costa et al. (2017) que, da mesma forma, observaram os impactos da operação nos retornos das ações nas duas maiores empresas investigadas nessa operação: JBS e BRF. Posteriormente, Silva et al. (2019) expandiram o estudo de Costa et al. (2017), observando todas as empresas listadas na bolsa de valores brasileira no segmento de carnes e derivados, mesmo as não investigadas, além de ampliarem a periodicidade de comparação.

Ainda quanto aos retornos das ações, Barros et al. (2017) além de comparar as empresas envolvidas na operação com as empresas não envolvidas brasileiras, do mesmo setor, também observaram as empresas do México, mercado considerado concorrente nesse ramo. Esses três estudos mencionados obtiveram resultados que se complementam, principalmente pela expansão amostral e distanciamento

temporal, permitindo aos dois últimos estudos, com maiores períodos de análise e comparação, encontrar efeito negativo, no geral, para as empresas brasileiras.

Na mesma linha de comparar as empresas investigadas, JBS e BRF, com as empresas não envolvidas (nesse caso, apenas a Marfrig) na Operação Carne Fraca, mas, analisando os indicadores contábeis, Ito et al. (2019) observaram e compararam os indicadores das empresas nos anos de 2016 e 2017.

Por fim, Rocha et al. (2020) expandiram o horizonte temporal para o período de 2013 a 2018, utilizando como metodologia o teste de Chow, com o objetivo de verificar a ocorrência de quebras estruturais, entendidas como mudanças graduais ou abruptas, nesse período. O referido estudo limita-se a observar esses efeitos apenas nos estados do Paraná e em Rondônia, que pode sugerir um vislumbre do cenário macro, porém sem força para generalização.

Diante desse contexto, o presente trabalho avança em relação a literatura existente pois pretende, por meio da abrangência de todas as empresas do segmento de carnes listadas na bolsa de valores, a constatação do evento ocorrido pela ótica de indicadores contábeis, propondo o uso de uma metodologia pouco explorada na pesquisa científica em contabilidade financeira, o campo da previsão de séries temporais.

A busca pelo melhor modelo preditivo motivou a criação de diversas competições mundo a fora, destacando-se as *M Competitions*, que propiciaram debates e motivaram enorme evolução no campo das previsões de séries temporais, tornando-as parâmetro de eficiência (Makridakis et al., 2020; Petropoulos & Makridakis, 2020). A última *M Competition* publicada, até então, foi a *M4 Competition*, a qual destacou-se o Modelo *FFORMA* (Montero-Manso et al., 2020) ao obter o melhor desempenho de previsão para séries temporais de frequência trimestral, além de ser considerado como totalmente replicável (Makridakis et al., 2020b), motivando seu uso nesta pesquisa.

Por todo o exposto, a pesquisa justifica-se pela possibilidade de verificar a evolução dos indicadores contábeis de todas as empresas do segmento de carnes e derivados listadas na bolsa de valores oficial brasileira (Brasil, Bolsa, Balcão – B3), no contexto da Operação Carne Fraca, pela ótica do modelo *FFORMA*, a fim de responder a seguinte questão: existe variação entre os indicadores contábeis esperados e os observados, no contexto da Operação Carne Fraca, nas empresas do segmento de carnes?

Assim, o presente trabalho tem o objetivo geral de analisar os possíveis efeitos da Operação Carne Fraca observados, à luz da teoria do efeito contágio, na evolução dos indicadores contábeis das empresas do segmento de carnes e derivados listadas na B3. Portanto, o estudo está delimitado, em uma escala setorial, a todas as empresas que compõem o segmento de carnes e derivados na bolsa de valores oficial do Brasil e, na escala temporal, delimita-se ao período em torno da Operação Carne Fraca, partindo do primeiro trimestre de 2011 até o primeiro trimestre de 2019.

Visando atingir o objetivo geral, a pesquisa desdobra-se nos seguintes objetivos específicos: (1) evidênciação da evolução dos indicadores contábeis das empresas do segmento de carnes e derivados, do primeiro trimestre de 2011 até o primeiro trimestre de 2016, período utilizado como ajuste para o modelo *FFORMA*; (2) projeção do modelo *FFORMA* da evolução dos indicadores contábeis das empresas do segmento de carnes, do segundo trimestre de 2016 até o primeiro trimestre de 2017, comparando-a com os dados observados, a fim de verificar a precisão do modelo no período anterior à deflagração da Operação Carne Fraca; (3) projeção do modelo *FFORMA* da evolução dos indicadores contábeis das empresas do segmento de carnes, do segundo trimestre de 2017 até o primeiro trimestre de 2019, proporcionando um cenário hipotético sem a interferência da Operação Carne Fraca, a fim de compará-lo com o cenário real observado no mesmo período.

As contribuições deste estudo enriquecem a metodologia existente na pesquisa científica em contabilidade financeira ao propor o uso de uma metodologia com enfoque nas contribuições dos modelos de previsão de séries temporais, bem como seus desafios, avanços e possibilidades. Além de propor a análise de todo o setor, não apenas das empresas diretamente envolvidas com o evento a ser analisado.

A pesquisa está organizada e estruturada em seis seções: a primeira sendo esta parte introdutória; a segunda seção aborda as referências que dão base à teoria que sustenta a pesquisa; a terceira seção contextualiza e explora a literatura sobre a Operação Carne Fraca; a quarta seção corresponde aos procedimentos metodológicos, apontando as características da pesquisa, indicando todo o processo de coleta e tratamento dos dados, além de explicar as estratégias utilizadas para analisar esses dados; a quinta seção dispõe a análise dos resultados encontrados com o desenvolvimento do trabalho; e, por fim, a sexta seção trata das considerações finais da pesquisa.

## **2 REFERENCIAL TEÓRICO**

Neste tópico serão abordados os principais pontos que envolvem esta pesquisa, contextualizando-a e dando o embasamento teórico necessário. O tópico foi dividido em dois subtópicos, sendo eles: 1) Análise das Demonstrações Contábeis – que visa esclarecer alguns pontos sobre a extração e interpretação de informação das demonstrações contábeis; e 2) Efeito Contágio – introduzindo sobre a teoria que complementa o tema destacado.

### **2.1 Análise das Demonstrações Contábeis**

Antes de aprofundar na análise das demonstrações contábeis via indicadores contábeis é fundamental primeiro conhecer os conceitos e a estrutura das demonstrações contábeis, entendendo sua evolução e objetivos (Assaf Neto, 2020). Dessa forma, esse subtópico foi dividido em três partes: 1) Regulamentação e normas – contextualizando resumidamente o processo de evolução recente da legislação e das normas contábeis; 2) Demonstrações contábeis – abordando de forma introdutória sobre os principais aspectos das demonstrações; e 3) Indicadores contábeis – aprofundando o conhecimento, destacando os principais indicadores utilizados.

#### **2.1.1 Regulamentação e normas**

A contabilidade pode ser entendida como um modelo que busca demonstrar a realidade econômica e financeira das empresas de forma simplificada, com o objetivo de fornecer informações sobre o desempenho, resultados e estrutura patrimonial dessas entidades (Assaf Neto, 2020; Martins et al., 2019).

No Brasil, a contabilidade é historicamente influenciada pela exigência legal e isso, embora tenha trazido contribuições importantes, limitou a evolução ou, pelo menos, dificultou a adoção prática de princípios contábeis adequados (Gelbcke et al., 2018; Niyama & Silva, 2013).

Visto que a contabilidade é a principal linguagem de comunicação entre os agentes econômicos e dado o constante processo de globalização da economia mundial, é necessária sua evolução (Niyama & Silva, 2013). A existência de diferentes práticas contábeis é um problema quando se pretende compreender as demonstrações internacionais, existindo absoluta necessidade de uma normatização contábil mundial (Gelbcke et al., 2018).

O processo de harmonização das normas internacionais ocorre pela adoção das *International Financial Reporting Standards – IFRS*, que são os pronunciamentos sobre a contabilidade internacional publicados pelo *International Accounting Standards Board – IASB* (Assaf Neto, 2020). No Brasil, o responsável por subsidiar a emissão de normas contábeis, via pronunciamentos técnicos com vistas ao processo de convergências às normas internacionais, é o Comitê de Pronunciamentos Contábeis – CPC, criado em 2005 (Assaf Neto, 2020; Silva, 2019; Niyama, 2014; Gelbcke et al., 2018).

Após a criação do CPC e com a aprovação da Lei n. 11.638/07, o Brasil avançou a passos largos no processo de harmonização às práticas contábeis internacionais (Martins et al., 2018). Assim, deu ênfase em um modelo internacional de lei societária e levou a um reposicionamento das práticas e comportamentos tradicionais dos profissionais de contabilidade (Marion, 2019).

Posteriormente, foi promulgada a Lei n. 11.941/09, que promoveu complementos alterando novamente a Lei das Sociedades Anônimas (Lei n. 6.404/76) (Gelbcke et al., 2018). Essas mudanças estabeleceram novos procedimentos na elaboração e divulgação das demonstrações contábeis (Assaf Neto, 2020).

Com isso, o CPC divulgou em 2010 o Pronunciamento Técnico CPC 37 (R1) – Adoção Inicial das Normas Internacionais de Contabilidade, com o objetivo de garantir que as primeiras demonstrações contábeis no padrão internacional, modelo *IFRS*, contenham informações de alta qualidade (CPC 37 (R1), 2010), orientando os procedimentos contábeis relativos à mudança (Gelbcke et al., 2018).

Consolidando a decisão pela convergência às normas internacionais, o CPC adotou integralmente o documento elaborado pelo *IASB*, *Framework for the Preparation and Presentation of Financial Statements*, emitindo seu próprio documento-base que norteia a contabilidade brasileira, denominado, na época, CPC 00 – Estrutura Conceitual para Elaboração e Apresentação das Demonstrações Contábeis (Gelbcke et al., 2018). Esse documento foi revisado pela segunda vez em dezembro de 2019 e passou a ser denominado como CPC 00 (R2) – Estrutura Conceitual para Relatório Financeiro.

O CPC 00 (R2) tem o objetivo de auxiliar os usuários a interpretar a informação das demonstrações contábeis, sendo de fundamental importância, pois nele está baseada toda a elaboração das demonstrações contábeis (Gelbcke, et al., 2018).

### 2.1.2 Demonstrações contábeis

A Estrutura Conceitual traz que o objetivo do relatório financeiro para fins gerais é fornecer informações financeiras sobre a entidade que reporta (Pronunciamento técnico CPC 00 (R2), 2019), tratando como sinônimos as expressões “relatórios financeiros”, “análises de balanços”, “análises das demonstrações contábeis” (Assaf Neto, 2020).

A análise das demonstrações caracteriza-se como a arte de saber extrair relações úteis para o objetivo que se tem em mente, a partir dos relatórios contábeis tradicionais. Apesar das técnicas desenvolvidas, não existe uma metodologia propriamente dita a ser seguida para obter-se um diagnóstico preciso (Assaf Neto, 2020; Iudícibus, 2017).

A análise começa onde termina a contabilidade, pois deve traduzir os dados contidos nas demonstrações financeiras, transformando-os em informações. Afinal, dados são números ou descrição de eventos que sozinhos podem não produzir um efeito de reação no usuário, enquanto informações apresentam essa característica, embasando a tomada de decisão (Matarazzo, 1998).

A análise das demonstrações contábeis é desenvolvida com base nas demonstrações formalmente apuradas pela empresa, tratadas como os insumos básicos do processo (Assaf Neto, 2020). Tais demonstrações são definidas na Lei n. 6.404 (1976): a) balanço patrimonial; b) demonstração dos lucros ou prejuízos acumulados; c) demonstração do resultado do exercício; d) demonstração dos fluxos de caixa; e) demonstração do valor adicionado – apenas para companhias abertas.

De acordo com essa Lei, os relatórios devem exprimir com clareza a situação do patrimônio da companhia e as mutações ocorridas no exercício. Assim, pode-se extrair as informações sobre a posição econômico-financeira da empresa, avaliando seu desempenho econômico, financeiro e patrimonial (Assaf Neto, 2020).

Ainda, pode-se comparar as informações extraídas com as informações de períodos passados, diagnosticando as causas que levaram à evolução apresentada. Além de destacar tendências futuras, confrontando-as com metas pré-estabelecidas e/ou com outras empresas do mesmo segmento (Assaf Neto, 2020; Silva, 2019).

Cabe ressaltar que, em grande parte, os relatórios financeiros baseiam-se em estimativas e julgamentos, não representações exatas (Pronunciamento técnico CPC

00 (R2), 2019). Sua utilidade depende do rigor com que as empresas empregam os conceitos estabelecidos pelos pronunciamentos técnicos (Assaf Neto, 2020).

Além dos princípios e conceitos estabelecidos pelo CPC 00, outro documento que merece destaque é o Pronunciamento Técnico CPC 26 (R1) – Apresentação das Demonstrações Contábeis (2011). Tal pronunciamento define que as demonstrações contábeis são aquelas cujo propósito atendem as necessidades informacionais dos usuários externos, por esses não poderem exigir relatórios específicos para suas necessidades, corroborando o CPC 00 (R2).

Assim, o objetivo das demonstrações contábeis é proporcionar informação que seja útil na tomada de decisão (Pronunciamento técnico CPC 26 (R1), 2011). Para ser útil, as informações devem ser relevantes e representar fidedignamente a situação da empresa, observando as características qualitativas de informações financeiras, sendo comparáveis, verificáveis, tempestivas e compreensíveis (Pronunciamento técnico CPC 00 (R2), 2019).

Com as alterações na Lei n. 6.404/76, pela Lei n. 11.638/07 e Lei n. 11.941/08, a estrutura de Balanço Patrimonial do modelo da Legislação Societária (modelo LS) foi substituída para atender as normas internacionais, passando a seguir o modelo *IFRS*, alterando significativamente a estrutura dessa demonstração.

Posterior às alterações na Lei, o CPC divulgou o Pronunciamento Técnico CPC 29 – Ativo Biológico e Produto Agrícola (2009), trazendo mais algumas alterações no reconhecimento e mensuração de ativos vivos referentes às atividades agropecuárias, alterando substancialmente a prática contábil até então (Gelbcke et al., 2018).

As demonstrações que recebem maior ênfase, dentre as obrigatórias estipuladas pela Lei n. 6.404/76, são o Balanço Patrimonial (BP), evidenciando a situação financeira, e a Demonstração do Resultado (DRE), evidenciando junto com o BP a situação econômica (Assaf Neto, 2020; Marion, 2019; Martins et al., 2019).

O BP tem por finalidade uma representação estática da posição financeira e patrimonial da empresa, visto que sua estrutura estará provavelmente diferente após seu encerramento. No entanto, dada a relevância de suas informações, é uma demonstração indispensável, pois, a partir dos elementos de seus grupos de contas, pode-se tirar conclusões sobre diversos aspectos (Assaf Neto, 2020; Gelbcke et al., 2018; Martins et al., 2019).

A DRE tem o objetivo de fornecer aos usuários as características essenciais da formação do resultado, podendo ser avaliadas as tendências em termos de receitas,

custos e despesas de naturezas variadas apropriados segundo o regime de competência, ou seja, independentemente de terem sido pagos ou recebidos (Assaf Neto, 2020; Gelbcke et al., 2018; Martins, et al., 2019).

Assim como o BP, a DRE também sofreu modificações com a alteração da Lei n. 6.404/76 pela Lei n. 11.941/08. Complementarmente, o Pronunciamento Técnico CPC 26 (R1) (2011) estabeleceu a estrutura mínima para sua elaboração. Tal estrutura não colide com a da Lei, mas contém pequenas alterações como a apresentação das despesas e receitas financeiras separadas, não compondo o que pode ser chamado de resultado operacional (Gelbcke et al., 2018).

Essas demonstrações mencionadas são partes fundamentais do processo de análise de demonstrações, que se desenvolve por meio de técnicas oriundas de diferentes áreas do saber, passando por um processo de aprimoramento e sofisticação (Assaf Neto, 2020; Marion, 2019).

Ao se propor uma análise, é comum querer comparar imediatamente os números absolutos apresentados pelas empresas, afinal a análise é fundamentalmente comparativa. Porém, sem um tratamento prévio pode-se esbarrar na diferença de tamanho entre essas entidades, na qual ter números maiores não significa necessariamente estar melhor (Assaf Neto, 2020; Ross et al., 2015).

Uma forma de sanar esse problema é relacionar entre si os números absolutos, tornando-os relativos e, assim, formando os tais indicadores, aqui tratados por indicadores contábeis. Dessa forma, pode-se proceder a comparação dos dados encontrados em outras empresas, podendo sua interpretação informar uma visão macro da situação econômico-financeira da entidade, sem maiores distorções (Marion, 2019; Martins et al., 2019; Ross et al., 2015)

Vale ressaltar que a análise é fundamentalmente comparativa, os índices avaliados isoladamente não produzem informações suficientes para uma conclusão, devendo ser comparados com o passado e com concorrentes. O grande objetivo da comparação é verificar a evolução, pois a análise é feita sempre visando no futuro e não apenas a situação atual (Assaf Neto, 2020; Gelbcke et al., 2018).

Complementarmente, pode-se aplicar a análise horizontal – avaliação dos componentes das demonstrações ao longo do tempo; e a análise vertical – análise da participação relativa dos componentes em um total específico (Assaf Neto, 2020; Martins et al., 2019). Contudo, para uma ampla visão da situação da empresa, faz-se necessário o estudo de indicadores contábeis (Iudícibus, 2017; Silva, 2019).



### 2.1.3 Indicadores contábeis

A literatura contábil-financeira trata os indicadores por diversos nomes como índices, indicadores, quocientes e os classificam em grupos de acordo com sua metodologia (Assaf Neto, 2020; Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010). Como representam relações entre os números absolutos das demonstrações contábeis, serão tratados nesta pesquisa por indicadores contábeis.

A interpretação dos indicadores é o ponto alto da análise das demonstrações financeiras, sendo o instrumental que classicamente representa o conceito dessa análise, pois permite melhor extrair conclusões sobre a avaliação do desempenho da entidade (Assaf Neto, 2020; Iudícibus, 2017; Padoveze & Benedicto, 2010).

Complementarmente, permite comparações entre empresas de diferentes tamanhos, fornecendo uma visão macro da sua situação econômico-financeira por meio da construção de séries históricas, garantindo, assim, que se tenha base para inferir o que poderá acontecer no futuro e contribuir com o processo decisório (Iudícibus, 2017; Martins et al., 2019; Ross et al., 2015; Silva, 2019).

Para isso, não se deve considerar qualquer indicador isoladamente, da mesma forma que não é recomendado o uso em grandes quantidades. O excesso de indicadores pode prejudicar a análise, pois quanto mais forem utilizados, mais fácil perder o foco da análise em conjunto. Assim sendo, embora existam diversos índices úteis, alguns se impõem pela importância, sendo necessários para a análise (Assaf Neto, 2020; Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010).

Ao longo dos anos os indicadores têm sido trabalhados em grupos. Os grupos mais utilizados para análise das demonstrações contábeis, considerados fundamentais e suficientes para se conhecer a situação econômico-financeira de uma empresa, são os de liquidez, estrutura patrimonial e rentabilidade. Os dois primeiros tratam a posição financeira da empresa, enquanto o último apresenta o desempenho econômico (Marion, 2019; Martins et al., 2019; Silva, 2019; Ross et al., 2015).

É importante reiterar a necessidade da análise dos indicadores em conjunto, dado que interagem entre si: a rentabilidade tem um efeito muito grande sobre a liquidez, pois a saúde financeira da empresa é decorrente da existência de rentabilidade. Já a estrutura do endividamento pode explicar a rentabilidade, uma vez que o custo de capital para quem toma os recursos é a rentabilidade de quem cede esses recursos (Iudícibus, 2017; Padoveze & Benedicto, 2010).

### **2.1.3.1 Indicadores de Liquidez**

Os indicadores de liquidez demonstram a situação financeira da entidade quanto aos compromissos assumidos, evidenciando a capacidade de pagamento de dívidas e avaliando seu grau de solvência, sendo de fundamental compreensão (Assaf Neto, 2020; Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010; Ross et al., 2015; Silva, 2019).

A vantagem de considerar apenas itens circulantes é que seus valores contábeis e de mercado são, provavelmente, semelhantes. Porém, deve-se observar alguns pontos relevantes: a situação representada por esses indicadores é estática e com diferenças temporais, pois a realização dos itens do ativo e do passivo circulante podem ser diferentes (Martins et al., 2018; Ross et al., 2015).

Por conta dos diferentes prazos de realização para ativos e passivos, a literatura financeira geralmente divide os indicadores de liquidez em quatro: liquidez geral, liquidez corrente, liquidez seca e liquidez imediata. Ainda que existam variados tipos e fórmulas de cálculo, existe um consenso quanto à interpretação desses indicadores (Padoveze & Benedicto, 2010).

O índice de liquidez geral considera todos os ativos e passivos, incluindo os de longo prazo. Dessa forma, amplia a divergência entre os prazos de recebimentos e pagamentos, podendo gerar distorções bastante acentuadas, o que diminuiria sua utilidade (Iudícibus, 2017; Marion, 2019; Martins et al., 2018, 2019; Padoveze & Benedicto, 2010; Silva, 2019).

No outro extremo, o índice de liquidez imediata considera apenas os valores em moeda ou quase moeda. Dado que as empresas geralmente mantêm poucos recursos disponíveis em caixas e equivalentes, pois esses estão sujeitos aos efeitos inflacionários, torna-se um indicador com pouca importância informacional (Iudícibus, 2017; Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010; Silva, 2019).

Dessa forma, o foco da presente pesquisa, quanto aos indicadores de liquidez, prevalece nos indicadores de liquidez corrente e liquidez seca. O primeiro demonstra a capacidade da empresa, em bens e direitos realizáveis no curto prazo, em relação às dívidas com prazos semelhantes, o que lhe deu o status de melhor indicador da situação de liquidez da empresa (Assaf Neto, 2020; Iudícibus, 2017; Martins et al., 2019; Padoveze & Benedicto, 2010; Silva, 2019).

Esse indicador representa quanto existe no ativo circulante para cada real de dívida do passivo circulante e, portanto, o conceito geralmente aplicável para a sua interpretação seria “quanto maior, melhor”. No entanto, deve-se observar o equilíbrio com a rentabilidade, dado que quanto maior a liquidez, maior a retenção de dinheiro, imobilizando recursos que poderiam ser investidos e ressaltando a importância da análise dos indicadores em conjunto (Assaf Neto, 2020; Padoveze & Benedicto, 2010).

O indicador de liquidez seca demonstra as dívidas de curto prazo em condições de serem pagas com o uso apenas de itens com maior liquidez, geralmente excluindo os estoques e as despesas antecipadas. Esse indicador é bastante utilizado pelos analistas pela sua importância em ser uma alternativa mais adequada para avaliar conservadoramente a situação da liquidez da empresa (Assaf Neto, 2020; Iudícibus, 2017; Martins, et al., 2019; Padoveze & Benedicto, 2010).

O estoque é considerado uma fonte de incertezas, dado as distorções que diferentes critérios de avaliação podem acarretar, além de estar sujeito a tornar-se obsoleto. Portanto, sua exclusão justifica-se pela eliminação do ativo circulante menos líquido. A exclusão das despesas antecipadas é justificada pela sua natureza, pois geralmente não se trata de recurso realizável em numerário (Assaf Neto, 2020; Marion, 2019; Iudícibus, 2017; Ross et al., 2015).

### **2.1.3.2 Indicadores de Endividamento**

Os indicadores de endividamento são utilizados dentro da análise da estrutura patrimonial da empresa para estabelecer relações entre as fontes de recursos do ativo, o qual pode ser financiado por capitais de terceiros, representados pelo passivo circulante e passivo não circulante, e por capitais próprios, representados pelo patrimônio líquido (Iudícibus, 2017; Marion, 2019; Martins et al., 2019).

Esses indicadores são de muita importância, pois, ao relacionar as fontes de recursos entre si, retratam a posição relativa do capital próprio em relação ao capital de terceiros. Assim, demonstram as decisões financeiras adotadas pela empresa em relação à composição de capitais do seu financiamento, evidenciando o nível de endividamento da empresa (Iudícibus, 2017; Marion, 2019; Silva, 2019). Esse grupo está representado, nesta pesquisa, por dois indicadores: a proporção do endividamento e a composição do endividamento.

O índice de proporção do endividamento demonstra quanto a empresa tem de capital de terceiros na estrutura do seu balanço patrimonial em relação aos capitais

próprios, levando em conta todas as dívidas de todos os vencimentos e credores. Além de caracterizar o financiamento do ativo, verifica a disponibilidade de recursos próprios para garantir os recursos de terceiros em uma eventual condição de descontinuidade das operações (Iudícibus, 2017; Martins et al., 2019; Padoveze & Benedicto, 2010; Ross et al., 2015).

Embora não exista um consenso sobre a condição ideal, existe uma tendência em se trabalhar com capitais de terceiros, principalmente em épocas de inflação. Essa tendência é contrabalanceada pelo risco, pois tal situação tornaria a empresa vulnerável a uma eventual crise. Mesmo assim, isso pode ser interessante quando o custo de captação desses recursos for menor do que a rentabilidade auferida com o investimento (Iudícibus, 2017; Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010; Silva, 2019).

No entanto, é importante concomitantemente analisar a qualidade da dívida, ou seja, como estão alocados os capitais de terceiros. Para abordar justamente esse ponto, existe o indicador de composição do endividamento. Esse indicador demonstra quanto da dívida total com os capitais de terceiros é referente ao curto prazo, permitindo a visualização do perfil da dívida total (Iudícibus, 2017; Martins et al., 2019; Silva, 2019).

Não existe uma composição geral do endividamento ótima, entretanto, considera-se mais saudável a preferência por dívidas de longo prazo. Tal preferência justifica-se por, tendo suas dívidas vencendo no longo prazo em uma eventual situação de crise, a empresa teria mais tempo para reorganizar-se e planejar a situação (Iudícibus, 2017; Marion, 2019; Martins et al., 2019; Silva, 2019).

Em situação oposta, uma empresa com a maior parte de seus compromissos vencíveis no curto prazo teria que tomar decisões desfavoráveis do ponto de vista econômico para quitar suas dívidas. Todavia, pode-se alongar os prazos dessas obrigações a partir da renegociação de dívidas antigas ou buscar maiores prazos na contratação de novos empréstimos (Marion, 2019; Martins et al., 2019; Silva, 2019).

Apresentados os indicadores de liquidez, demonstrando a situação financeira, e os indicadores de endividamento, demonstrando as preferências de financiamento, deve-se complementá-los apresentando agora os indicadores de rentabilidade, demonstrando a capacidade de gerar recursos para quitar essas dívidas (Silva, 2019).

### **2.1.3.3 Indicadores de Rentabilidade**

Analisar a rentabilidade em termos absolutos tem pouca utilidade informacional. Assim, para melhor destacar o desempenho econômico, os indicadores de rentabilidade relacionam os resultados obtidos pela empresa com o tipo de investimento. Seja esse representado pelo ativo total, por um conceito específico ou pelo próprio patrimônio líquido (Iudícibus, 2017; Marion, 2019; Silva, 2019).

A análise da rentabilidade é considerada a parte mais importante e fundamental da análise das demonstrações, pois além do retorno dos investimentos, pode-se também analisar o retorno das próprias vendas, avaliando a produtividade, a lucratividade e a eficiência da gestão dos investimentos (Marion, 2019; Martins et al., 2018; Padoveze & Benedicto, 2010; Silva, 2019).

É importante destacar que taxas de retornos estão sujeitas a aproximações, a critérios contábeis alternativos e diferentes modelos contábeis (Assaf Neto, 2020; Martins et al., 2018). Dessa forma, é necessário estabelecer alguns conceitos e critérios para mensuração de instrumentos essenciais para este estudo: investimento e resultado operacional.

O investimento refere-se ao montante que foi efetivamente investido na atividade operacional da empresa, sendo proveniente de recursos de terceiros e/ou dos capitais próprios. A captação dos recursos de terceiros incorre em despesas financeiras, chamadas de passivos financeiros ou passivos onerosos (Assaf Neto, 2020; Martins et al., 2018; Silva, 2019).

Assim, pode-se dizer então que o investimento é o somatório do patrimônio líquido com os passivos onerosos, ou, pode-se ainda fazer o processo contrário, dizendo que o investimento é o valor do ativo total, reduzindo-se o valor dos passivos não onerosos (Assaf Neto, 2020; Martins et al., 2018, 2019).

Visto que o passivo oneroso se refere aos passivos que incorreram em despesas financeiras, o passivo não oneroso, portanto, refere-se aos passivos que não incorreram, pelo menos não de forma explícita. Ou seja, refere-se aos passivos voltados ao funcionamento da atividade operacional (Assaf Neto, 2020; Martins et al., 2018, 2019; Silva).

Outro ponto a ser mencionado é o fato de as demonstrações contábeis representarem apenas dados estáticos de encerramento do exercício. No entanto, foram as variações médias que geraram os resultados, sendo essas, portanto, as

utilizadas, via média aritmética simples (Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010).

Estabelecido os critérios e conceitos referentes ao cálculo do investimento, resta abordar sobre o resultado operacional. Esse refere-se ao resultado que os investimentos geraram na execução das atividades operacionais da empresa. Portanto, depende exclusivamente das decisões de investimento, desconsiderando-se as decisões de financiamento, das quais incorrem despesas financeiras (Assaf Neto, 2020; Marion, 2019; Martins et al., 2018; Padoveze & Benedicto, 2010).

Na sequência, pode-se abordar os indicadores de rentabilidade mais utilizados: retorno sobre o investimento e o retorno sobre o patrimônio líquido. O retorno sobre o investimento é um dos indicadores mais utilizados, sendo provavelmente o mais importante indicador individual. Tal indicador evidencia o quanto os investimentos realizados proporcionaram de resultado, medindo a eficiência global da empresa na geração de lucros, desconsiderando a forma como esses investimentos foram financiados (Iudícibus, 2017; Marion, 2019; Martins et al., 2019; Padoveze & Benedicto, 2010; Silva, 2019).

Embora o retorno sobre o investimento tenha importância individual para a análise global da empresa, o retorno sobre o patrimônio líquido é considerado, pela ótica dos acionistas, o principal indicador da análise de rentabilidade, pois demonstra o retorno do capital próprio investido na empresa (Assaf Neto, 2020; Iudícibus, 2017; Martins et al., 2018; Silva, 2019).

Como esse indicador leva em consideração as formas de financiamento, dado o enfoque nos capitais próprios, entende-se necessário aqui considerar as despesas financeiras. Para isso, utiliza-se o próprio lucro líquido apurado pela empresa (Martins et al., 2018; Assaf Neto, 2020).

Ainda, visando a possibilidade de análise em conjunto, deve-se atentar em manter a coerência de raciocínio do cálculo do investimento, utilizando o patrimônio líquido médio, via média aritmética simples, mesmo que esse ainda contenha parte do resultado do período (Martins et al., 2018).

Definidas as características que cerceiam a análise das demonstrações contábeis, bem como elencados os pormenores do uso de indicadores contábeis, pode-se dar continuidade à construção do referencial teórico, apresentando outro ponto que complementa a presente pesquisa: a teoria do efeito contágio.

## 2.2 Efeito Contágio

A teoria do efeito contágio é um tema amplamente explorado pela literatura, no entanto, não existe uma definição estabelecida e universalmente aceita para o fenômeno observado (Ferreira, 2012; Vartanian, 2012; Vidal & Securato, 2011). Os autores buscam conceituar esse efeito de acordo com suas pesquisas empíricas, o que naturalmente terá um caráter particular para cada um (Corsetti et al., 2005; Dornbusch et al., 2000; Forbes & Rigobon, 2000;).

Em linhas gerais, as definições da teoria do efeito contágio sempre aparecem relacionadas a uma crise em um determinado país, com efeitos negativos expandidos rapidamente para outro país, o qual não possuía relação comercial, que justificasse essa rápida expansão, com o país de origem da crise (Dornbusch et al., 2000; Forbes & Rigobon, 2002; Pericoli & Sbracia, 2003).

Dessa forma, é comum encontrar citações às crises do México (1994), Ásia (1997), Rússia (1998), Brasil (1999) e Argentina (2001) como exemplos desse efeito, uma vez que as consequências dessas crises extrapolaram os territórios de origem e atingiram mercados sem relevante relação comercial ou financeira que justificasse isso (Ferreira, 2012; Vartanian, 2012).

Dornbusch et al. (2000) evidenciam dois eventos que possivelmente causariam o efeito contágio: o primeiro diz respeito aos próprios fundamentos macroeconômicos observados (relações comerciais, ligações financeiras, entre outros); o segundo é a reação dos diversos investidores, que, inseguros ao perceberem uma crise em determinado país, passam a agir de maneira conservadora, diminuindo seus investimentos também em outros países não relacionados (Freire, 2017; Perobelli et al. 2013).

Essa ideia de que uma das causas do efeito contágio é a reação dos investidores também é corroborada por outros autores. Corsetti et al. (2005) relacionam o efeito contágio às quebras estruturais em períodos de crises, que podem refletir pânicos de mercado ou efeito manada – quando um investidor passa apenas a replicar o comportamento de outros investidores (Vidal & Securato, 2011).

No mesmo sentido, Rigobon (2002) destaca o comportamento dos investidores entre as possíveis causas, relacionando-o às teorias: dos múltiplos equilíbrios – em resumo, investidores aumentam seus investimentos em tempos de equilíbrio e, em meio à crise, recuam seus investimentos também em outros países não relacionados;

efeito manada; e aprendizagem – os investidores julgam que o que aconteceu em um país se repetirá em outro com semelhanças estruturais e políticas (Freire, 2017).

Portanto, pode-se assumir que o efeito contágio ocorre quando há uma reversão de expectativa econômico-financeira instaurada em um país específico e essa tem seus efeitos negativos expandidos para outros países, possivelmente motivada pelas reações dos agentes econômicos envolvidos.

A partir de situações de assimetria informacional, tais agentes passam a agir irracionalmente, motivados pela insegurança financeira e/ou, quando já existe o movimento, copiam as ações de outros investidores na mesma situação. Dessa forma, por acreditarem que uma crise existente num país irá se repetir em outro de estrutura similar, ainda que este não tenha relação com aquele, acabam por, de fato, ajudarem essa crise a acontecer no país.

Percebe-se que a literatura, via de regra, associa o efeito contágio com economia internacional, quase sempre abordando relações entre países (e.g. Corsetti et al., 2005; Dornbusch et al., 2000; Forbes & Rigobon, 2000; Pericoli & Sbracia, 2003; Rigobon, 2002). No entanto, alguns autores fogem dessa limitação de escopo e expandem o conceito para outros contextos, tratando de relações entre empresas, mercados e, então, países (Freire et al., 2017).

A inexistência de uma definição estabelecida permite a exploração da teoria. Assim, amparado pelas visões dissidentes acerca do efeito contágio estar confinado ao comércio internacional, a interpretação utilizada neste trabalho é a de que o efeito poderia ocorrer entre empresas que atuam em um mesmo setor. Logo, propõe uma leitura contrária ao que seria esperado a partir das teorias convencionais de competição, em que o prejuízo de uma empresa implicaria no benefício de suas concorrentes.

A possibilidade contraintuitiva aqui admitida é a de que a preocupação em relação à qualidade de um produto gere desconfiança sobre seus substitutos perfeitos, uma vez que eles estão relacionados na indústria pelo mesmo órgão fiscalizador de qualidade. Dessa forma, os potenciais efeitos negativos proporcionados pelas práticas corruptivas investigadas na Operação Carne Fraca se estenderiam também para as empresas que não foram alvos de investigação, sugerindo a incidência de efeito contágio.



### **3 OPERAÇÃO CARNE FRACA**

Estabelecidas as bases teóricas, resta o aprofundamento na operação propriamente dita. Este tópico traça um panorama da Operação Carne Fraca, discutindo os principais pontos que se destacam sobre o tema. Para isso, está subdividido em quatro partes, sendo elas: 1) A Operação – contextualizando e apontando as características da operação; 2) Repercussão na Mídia – abordando como o assunto foi retratado pela imprensa; 3) Posicionamento do Governo e das Empresas – destacando quais ações tomaram os agentes públicos e privados diretamente envolvidos na operação; 4) Reação do Mercado Consumidor – pontuando como o mercado consumidor reagiu a esse evento; e 5) Outros Estudos Relacionados – tratando sobre os achados da literatura que se relacionam com o tema em debate.

#### **3.1 A Operação**

Após quase dois anos de investigação, a Polícia Federal deflagrou em março de 2017 a Operação Carne Fraca, considerada, até então, a maior operação da história. Tal operação teve a finalidade de investigar um suposto esquema corruptivo envolvendo agentes públicos e empresários do setor de carnes que beneficiava frigoríficos e demais estabelecimentos da cadeia produtiva de grandes empresas do Brasil (DIEESE, 2017; Giehl, 2017; Gonçalves & Campos, 2017; MAPA, 2017b; Polícia Federal, 2017a).

De acordo com o Inquérito Policial (IPL), a investigação teve início em 2015, após denúncias de um fiscal federal que presenciara diversas práticas irregulares com conivência de fiscais da Superintendência Federal da Agricultura (SFA), braço do Ministério da Agricultura (MAPA) no Paraná (IPL 0136/2015, 2017).

O MAPA é o responsável pela fiscalização das indústrias de produtos de origem animal e vegetal, acompanhando e supervisionando empresas que solicitam o Serviço de Inspeção Federal (SIF), necessário para que os produtos possam ser comercializados interna ou externamente (DIEESE, 2017).

Os indícios e provas oriundos da investigação levaram a crer na existência de uma organização criminosa atuante na estrutura do MAPA. Dessa forma, o nome “Carne Fraca” faz alusão à expressão popular, onde além de referenciar à suposta baixa qualidade do alimento em questão, demonstra também a fragilidade moral dos agentes públicos que se submeteram às práticas corruptivas (IPL 0136/2015, 2017; Polícia Federal, 2017a).

Tais práticas ocorriam em virtude de os agentes públicos, utilizando-se da posição fiscalizatória, aceitarem propina para emitir certificados sanitários sem a devida fiscalização, permitindo diversas irregularidades afetando a qualidade do produto comercializado. Os agentes públicos envolvidos eram desde os próprios fiscais até a superiores que, por sua vez, utilizavam-se da influência do cargo para alterar os fiscais encarregados da inspeção das empresas envolvidas, atendendo os interesses das mesmas (IPL 0136/2015, 2017; Polícia Federal, 2017a).

As diversas irregularidades apontadas, iam de notas fiscais fraudadas de compras de carnes inexistente, substituídas por produtos mais baratos; falsificação de embalagem, alterando a data de vencimento; utilização de produtos químicos em desacordo com as normas técnicas; excesso de água para aumentar o peso dos produtos; entre outras irregularidades que atingem diretamente a saúde pública (DIEESE, 2017; Giehl, 2017; IPL 0136/2015, 2017; MAPA, 2018; Vieira, 2017).

Mais de 30 empresas alimentícias eram investigadas, entre elas, as gigantes do segmento de carnes e derivados: JBS e BRF. A BRF tornou-se alvo por irregularidades em um frigorífico de Goiás, além de ao seu gerente de relações institucionais ser atribuído, entre outros, os crimes de corrupção passiva e ativa, falsificação e lavagem de dinheiro (Gonçalves & Campos, 2017; MAPA, 2018).

Já a JBS, foi citada por irregularidades quanto à emissão de certificação sanitária, tendo um funcionário, que anteriormente atuava como fiscal, acusado do crime de corrupção ativa por ter pago propina a agentes públicos para evitar a fiscalização dos produtos (Gonçalves & Campos, 2017; Silva, 2016).

É importante mencionar que a Operação Carne Fraca teve outras três fases: a segunda foi deflagrada ainda em 2017, em maio, sendo chamada de Operação Antídoto, nome em referência ao objetivo de acabar com o crime de obstrução e destruição de provas cometido principalmente pelo ex-Superintendente Regional do MAPA em Goiás (Polícia Federal, 2017b).

A terceira fase foi deflagrada em 2018, com o nome de Operação Trapaça, em alusão às fraudes nos resultados de exames operados por laboratórios de análises de alimentos a fim de burlar o SIF, atendendo a empresários do setor (Polícia Federal, 2018). A última, até então, foi deflagrada no final de 2019, denominada Romanos, em referência às diversas passagens bíblicas do livro de mesmo nome que tratam de confissão e justiça, tendo como foco os crimes de corrupção passiva de auditores fiscais federais (Polícia Federal, 2019).

### 3.2 Repercussão na Mídia

Embora tenha ocorrido diversas fases, a fase inicial foi a mais conturbada. A imprensa brasileira, de março a julho de 2017, publicou mais de 16 mil reportagens citando o MAPA no contexto da Operação Carne Fraca. A partir dessas reportagens, infere-se que o maior dano à imagem do ministério veio nos primeiros vinte dias de crise, quando surgiram as primeiras notícias (MAPA, 2018; Salomão, 2018).

Muito pela forma espalhafatosa como foram divulgadas as investigações pela mídia e até por erros da própria polícia, como nas afirmações do suposto uso de papelão como ingrediente, que mais tarde entendeu-se referir à embalagem do produto e o uso de produtos supostamente cancerígenos, mais tarde também refutado (Anvisa, 2017; Giehl, 2017; Salomão, 2018).

A maneira abrupta da deflagração da operação gerou muitas notícias e, no afimco de prender a atenção dos leitores, essas tornaram-se mercadorias com intuito de aumentar a visualização e repercussão. Em alguns momentos, apresentavam informações divergentes entre o que era publicado e o que era efetivamente investigado, limitando a credibilidade das fontes e vieses (Hummel & Volcan, 2017; Pinto, 2017; Richarde et al., 2019).

Para ilustrar essa repercussão, pode-se destacar dois estudos, um voltado aos portais de notícias virtuais e outro à mídia televisiva. Hummel e Volcan (2017) analisaram 44 notícias publicadas pelo portal G1 nos três primeiros dias da deflagração da operação. Os autores concluíram que as sucessivas publicações pouco acrescentavam de novos fatos e acumulavam-se em repetições com manchetes chamativas. Embora o estudo aborde apenas um portal, merece destaque pela visibilidade do mesmo.

Hergesel e Silva (2017) verificaram os estilos de narrativa aplicados nos jornais vinculados ao Núcleo de Jornalismo do SBT, encontrando variações estilísticas entre eles. Segundo os autores, o jornal *Primeiro Impacto* apresentou um viés apelativo e sensacionalista, com julgamentos antecipados e condenando passionalmente os possíveis suspeitos.

Já o jornal *SBT Brasil* apresentou uma abordagem mais séria e moralista, mas com um tom opinativo pelo posicionamento emotivo, demonstrando inconformidade com o que era narrado. Por fim, o jornal *SBT Notícias* conduziu a narrativa de forma neutra, sem palavras de ordem, organizando cronologicamente a trama, resumindo e

trazendo novidades baseadas nos fatos e no que foi oficialmente mencionado (Hergesel & Silva, 2017).

A desinformação criou um efeito sensacionalista. A repercussão das notícias na mídia dava a entender que as carnes eram vendidas vencidas, misturadas com papelão e com substâncias cancerígenas (Hergesel & Silva, 2017; Pinto, 2017). Porém, apesar de repugnantes, as irregularidades referiam-se a uma parcela da produção e relacionavam-se diretamente a desvios de conduta profissional, não representando mau funcionamento generalizado que colocaria em xeque a qualidade da carne brasileira (Maggi, 2017; MAPA, 2017b; Vieira, 2017).

Os principais noticiários não distinguiam quais eram os frigoríficos interditados, levando a crer que a prática era generalizada. No entanto, a investigação contemplava 21 frigoríficos, de um universo de quase 5 mil estabelecimentos, e envolvia 34 funcionários, dentre os 2.500 fiscais do MAPA (DIEESE, 2017, Pinto, 2017).

A omissão de informações que ajudariam a entender a real dimensão do problema pode gerar um impacto social enorme. Somente na 14ª notícia do segundo dia isso foi veiculado nos títulos das notícias publicadas pelo portal G1, persistindo o natural receio do consumidor quanto à confiabilidade da cadeia produtiva de carnes (Giehl, 2017; Hummel & Volcan, 2017).

### **3.3 Reação dos Agentes Econômicos**

Com o objetivo de convencer a comunidade internacional de que o problema não era generalizado, o governo brasileiro agiu rápido. O então ministro fez diversas reuniões e aparições na mídia para esclarecer as informações divergentes e assegurar a eficiência dos órgãos de fiscalização brasileiros, reiterando a qualidade dos alimentos produzidos (Magioli, 2017; MAPA, 2017a, 2017c). As empresas seguiram a mesma linha de reiterar imediatamente a qualidade dos produtos, através de comunicados oficiais (Silva, 2016).

Silva (2016) analisou os efeitos para a imagem do Brasil e o posicionamento das empresas envolvidas na operação, constatando que tanto BRF quanto JBS apostaram em vídeos de funcionários consumindo seus produtos e demonstrando orgulho de trabalhar na companhia. O autor aponta que o gerenciamento da mídia digital em geral foi favorável, embora apresentasse falhas, demonstrando um certo despreparo e surpresa por parte das empresas.

Silva e Melo (2019) identificaram e analisaram os argumentos utilizados nas notas de esclarecimento das empresas JBS e BRF sobre a operação, apontando as técnicas argumentativas utilizadas. Constataram o uso do gênero com finalidade de mudar a opinião popular, desfazendo confusões de informações e apresentando argumentos capazes de persuadir clientes quanto ao exposto pela Polícia Federal.

Soares (2018) propôs compreender o impacto das crises de marca no comportamento dos consumidores, analisando como esses reagiram nas mídias sociais em relação à operação. Primeiro buscou entender a reação das empresas diante da crise de imagem, verificando suas publicações, o que proporcionou identificar padrões distintos.

Segundo o autor, enquanto a JBS assumiu uma estratégia gerencial de ação corretiva, defendendo não só a marca institucional (grupo JBS) como também as marcas de seus produtos individuais (Friboi, Seara, etc.), a BRF optou por uma estratégia de negação, focando somente na blindagem da marca corporativa, sem relacionar as marcas dos seus produtos.

Ainda, o estudo de Soares (2018) indicou que, embora as empresas apresentassem grandes prejuízos imediatos, a resposta rápida das marcas, aliada à alta familiaridade junto aos consumidores, apontaram um efeito reduzido da crise no mercado interno, onde os consumidores tendem a relevar as denúncias em virtude das boas lembranças relacionadas às marcas em questão.

Mesmo que as acusações tenham sido negadas pelas empresas envolvidas e pelo governo, além de minimizadas por especialistas, as consequências imediatas após a deflagração eram inevitáveis (Giehl, 2017; DIEESE, 2017). Reduziu-se o consumo e consequentemente as receitas, tanto no mercado nacional quanto no comércio internacional, onde foram impostas justificáveis barreiras como forma de proteção sanitária e comercial (DIEESE, 2017; Vieira, 2017).

No entanto, essa situação foi se alterando em virtude da rápida ação das autoridades em ressaltar a robustez do sistema de inspeção sanitária brasileiro (MAPA, 2017d; Pinto, 2017). As medidas deram resultado, revertendo quase em sua totalidade as restrições impostas pelos países dos principais mercados em que o Brasil atua (MAPA, 2017e; Maggi, 2017).

Porém, é fato que esses acontecimentos representam um lamentável episódio não só para o segmento de carnes e derivados, mas para todo o agronegócio brasileiro, incorrendo num prejuízo de difícil mensuração (Gurgel, 2017).

### 3.4 Estudos Relacionados

Algumas consequências foram provisórias, porém seus impactos foram perceptíveis, sendo alvo de estudos. Coelho (2017) investigou o impacto da operação na exportação de carnes bovinas, suínas e aviárias, concluindo que houve queda acentuada na exportação no mês de abril, o mês seguinte à deflagração da operação, gerando um impacto estatisticamente significativo no volume e montante da exportação de carne bovina.

Link e Ternus (2018) identificaram como a operação impactou a imagem e o consumo de carnes, por meio de um questionário respondido por 198 pessoas, entre os meses de julho a outubro de 2017. Evidenciaram que o consumo continuou presente (97%), além de concluírem que a operação instigou os consumidores a serem mais críticos em relação à qualidade da carne, ocasionando positivamente uma maior preocupação em relação ao produto que estão adquirindo.

No mesmo sentido, Rocha et al. (2017) investigaram a reação do mercado consumidor de carnes nas regiões norte e nordeste do estado de Minas Gerais, por meio de um questionário com 500 respondentes. Os autores inferiram que a população respondente não estava disposta a mudar os hábitos de compra e consumo de carnes (49%), embora uma parcela mostre preocupação com as marcas investigadas, propondo substituí-las no seu hábito alimentar (20%), enquanto outros estiveram dispostos a consumir menos carne de uma forma geral (23%).

Queiroz e Leite (2019) buscaram compreender como a vulnerabilidade do consumidor se manifestou no contexto da Operação Carne Fraca. Entrevistando 13 consumidores, os autores constataram que, entre as condições externas, a vulnerabilidade se fez presente principalmente em decorrência da assimetria informacional. Segundo os autores, a percepção de corrupção sistêmica favorece a insegurança do consumidor em não confiar nem nas instituições privadas, pois essas visariam apenas o lucro, estando sujeitas a práticas condenáveis; nem nas instituições públicas, pois essas estariam dispostas a burlar leis em benefícios próprios.

Com um enfoque nas empresas, Costa et al. (2017) estudaram os impactos da operação nos retornos das ações das investigadas JBS e BRF. Os autores constataram que não houve reação estatisticamente significativa nos retornos anormais das ações. Porém, numa análise gráfica, inferiram reação negativa maior na empresa JBS, em torno do anúncio da operação.

Complementando o estudo anterior, Silva et al. (2019) verificaram os retornos das ações de todas as empresas do segmento de carnes, ampliando também o horizonte temporal. Os resultados encontrados indicaram a JBS como a companhia mais impactada, registrando o menor retorno anormal. Entre as empresas não envolvidas na operação, os autores encontraram impacto negativo na Excelsior, enquanto as empresas Marfrig e Minerva foram as menos impactadas.

Na mesma linha de comparação, Barros et al. (2017) buscaram evidências de efeito contágio por meio dos retornos das ações das empresas JBS e BRF, investigadas pela operação Carne Fraca, com empresas nacionais não investigadas, além de empresas do mesmo setor atuantes no México. Os resultados apresentaram, em geral, retornos anormais negativos para as ações das empresas brasileiras após a deflagração da Operação Carne Fraca, enquanto as empresas mexicanas apresentaram retornos anormais positivos, inferindo a presença de efeito contágio.

Também com objetivo de comparar empresas envolvidas com não envolvidas, mas contemplando a ótica dos indicadores, Ito et al. (2019) compararam, entre os anos 2016 e 2017, as empresas investigadas pela operação, JBS e BRF, com a empresa Marfrig, não investigada. Os resultados indicam impacto negativo apenas nos indicadores das empresas JBS e BRF, embora tenham se recuperado a partir do terceiro trimestre.

Por fim, Rocha et al. (2020) analisaram os efeitos da Operação Carne Fraca nas exportações de carne bovina nos estados do Paraná e de Rondônia no período de 2013 a 2018, aplicando o teste de Chow, com intuito de investigar quebras estruturais. Os autores encontraram redução de 7% nas exportações do Paraná em 2017, em relação ao ano anterior. Enquanto em Rondônia, houve um aumento de 24% no mesmo ano de 2017, indicando uma quebra estrutural.

Dessa forma, a partir dos estudos expostos, presentes na literatura acadêmica sobre o tema, mesmo aqueles que sofrem de limitações tais como pequenas amostras ou especificidade da região trabalhada que os impedem de generalizar seus resultados, pode-se inferir alguns efeitos, tanto em território nacional quanto no comércio externo, causados pelas práticas corruptivas investigadas pela Operação Carne Fraca.

## **4 PROCEDIMENTOS METODOLÓGICOS**

Neste tópico será abordado sobre os procedimentos metodológicos que caracterizam esta pesquisa científica. Dessa forma, encontra-se dividido nos seguintes subtópicos: 1) Características da Pesquisa – classificando as características gerais do estudo em questão; 2) Universo Populacional – evidenciando o objeto da análise; 3) Coleta de Dados – destacando todo o caminho percorrido para ajuste e coleta dos dados; 4) Tratamento de Dados – apontando as decisões metodológicas da pesquisa para padronização dos dados; e 5) Projeção dos Dados – apresentando, explicando e justificando o método escolhido.

### **4.1 Características da Pesquisa**

A presente pesquisa caracteriza-se como descritiva quanto a sua natureza, pois procura descrever sistematicamente uma situação, tendo uma perspectiva teórica positivista, utilizando-se de metodologia quantitativa (Crotty, 1998; Richardson, 2017).

Embora a formação do referencial teórico naturalmente ocorra pela pesquisa bibliográfica, abrangendo a bibliografia publicada em relação ao tema de estudo, a coleta de dados é dada pela pesquisa documental, pois os dados foram acessados em um banco de dados com publicações originais, caracterizando como dados secundários (Marconi & Lakatos, 2019).

Os dados coletados foram organizados quantitativamente, seguido pelo cálculo de indicadores contábeis, gerando os dados base para a utilização do modelo de previsão de séries temporais FFORMA (Montero-Manso et al., 2020), utilizado para projetar os indicadores contábeis ao longo do tempo e, por fim, procedendo a análise dos resultados encontrados.

### **4.2 Universo Populacional**

Universo ou população é o conjunto de seres que apresentam pelo menos uma característica em comum e a delimitação desse universo, no campo da pesquisa científica, consiste em explicitar quem será pesquisado, enumerando suas características comuns (Marconi & Lakatos, 2019).

Dessa forma, o universo desta pesquisa é formado por todas as empresas listadas, cujos dados são disponibilizados ao público, na bolsa de valores brasileira, no setor de consumo cíclico, subsetor de alimentos processados, segmento de carnes



e derivados: “BRF S.A.”, “EXCELSIOR ALIMENTOS S.A.”, “JBS S.A.”, “MARFRIG GLOBAL FOODS S.A.”, “MINERVA S.A.” e “MINUPAR PARTICIPACOES S.A.”.

Empresas listadas na B3 têm de estar registradas na CVM (B3, 2018) e para isso têm de apresentar, entre os documentos das demonstrações, o relatório de auditores independentes, requerido pela Lei n. 6.404/76, com opinião não modificada (Instrução CVM 480, 2009), isto é, garantindo a representação adequada da situação econômico-financeira da empresa, atribuindo maior segurança aos analistas e valorizando a qualidade da informação contábil (Assaf Neto, 2020).

### **4.3 Coleta de Dados**

A coleta de dados procedeu via pesquisa documental, com a utilização da plataforma Economática®. Tal plataforma reconhece as empresas pelos seus ativos correntes, que estão representados pelo nome da empresa e código do ativo, a seguir: BRF (BRFS3), Excelsior (BAUH3), JBS (JBSS3), Marfrig (MRFG3), Minerva (BEEF3) e Minupar (MNPR3).

Destacados os ativos correntes objeto da pesquisa, foi selecionada a base de dados “Demonstrativos financeiros”, onde foram ajustadas as configurações dos parâmetros, detalhadas a seguir.

A primeira configuração refere-se à data das demonstrações utilizadas. Portanto, foi configurado, como data inicial, as demonstrações de dezembro de 2010, primeiro período disponível em que todas as empresas apresentam as demonstrações padronizadas no modelo IFRS; e, como data final, as demonstrações de março de 2019, proporcionando um recorte temporal de dois anos após a deflagração da operação, horizonte temporal utilizado para previsões de séries trimestrais.

Na sequência, foi selecionado o período trimestral para as informações referentes à DRE, com o intuito de garantir a comparabilidade dos dados entre as próprias demonstrações, uma vez que o BP também apresenta dados trimestrais, de modo a se obter a maior quantidade de dados disponíveis para comparação.

Quanto à moeda, foi selecionado o ajuste por inflação, pois mesmo em contextos de baixa inflação, seus efeitos acumulados tendem a ser relevantes, exercendo grande influência sobre as demonstrações econômicas. O ajuste é calculado com base no Índice Nacional de Preços ao Consumidor Amplo – IPCA, índice oficial da medida de inflação da economia brasileira (Assaf Neto, 2020; Gelbcke et al., 2018; Silva, 2019).

A próxima configuração é sobre a consolidação das demonstrações contábeis consolidadas, que fornecem dados de um grupo econômico sob controle comum como uma única entidade, oferecendo um foco amplo da situação da empresa e permitindo, assim, conhecer a real posição financeira do grupo econômico (Assaf Neto, 2020; Gelbcke et al., 2018; Pronunciamento técnico CPC 36 (R3), 2012).

Dessa forma, foi selecionado a opção “Sim\*” para, quando existir, retornar dados referentes ao consolidado e, quando não, retornar dados das demonstrações individuais – com a Excelsior sendo a única empresa com demonstrações individuais.

Na sequência, tem-se a configuração sobre o período dos Balanços Patrimoniais, sendo selecionado a opção “Todos”, de modo que retornem os dados do BP referente aos quatro trimestres do ano, proporcionando mais comparações em um mesmo exercício social, além de conciliar com o período escolhido para a DRE.

O próximo item é o campo “Mostrar os itens”, referindo-se a quais contas e/ou demonstrações mostrar. Como, por padrão, são mostradas todas as demonstrações, selecionou-se a opção “Somente os marcados” para que somente sejam abrangidos o BP e a DRE. As contas do BP foram selecionadas até o terceiro nível (com exceção feita ao patrimônio líquido, que seguiu até o quarto nível), para que sejam utilizadas de forma agrupada, melhorando a percepção dos dados e facilitando a comparação.

A configuração seguinte é sobre a análise automática da plataforma Economática®, podendo ser selecionada uma análise automática horizontal e/ou análise vertical, porém como este não é o objetivo do estudo, que pretende seguir por metodologia própria, foi selecionado a opção “nenhuma”.

Dada a grandeza das empresas objeto da pesquisa, a unidade selecionada para apresentação dos dados foi “em milhares”, uma vez que, respeitando a natureza dos números trabalhados, com essa apresentação em milhares, as demonstrações contábeis geralmente tornam-se mais compreensíveis (Pronunciamento técnico CPC 26 (R1), 2011).

Por fim, o último campo é denominado “Opções avançadas”, sendo indiferente na realização desta pesquisa, ficando desmarcado pois está apenas relacionado com destaque das contas através de cores diferentes.

Efetuada as configurações dos parâmetros das demonstrações, seleciona-se os ativos correntes, gerando as respectivas demonstrações contábeis para cada empresa e exportando-as.

#### 4.4 Tratamento dos Dados

Após completada a coleta, os dados foram tabulados utilizando o *software Microsoft Excel*, destacando o BP e a DRE pelo período correspondente ao último trimestre de 2010 até o primeiro trimestre de 2019, para todas as empresas em análise: BRF, Excelsior, JBS, Marfrig, Minerva e Minupar.

Com os dados tabulados, pode-se proceder ao cálculo dos indicadores estipulados. Entretanto, deve-se tomar cuidado quanto às diferentes fórmulas de cálculo usadas, tornando necessária a documentação do processo, evidenciando cada indicador (Marion, 2019; Martins et al., 2018, 2019; Ross et al., 2015; Silva, 2019). Sendo assim, estão demonstrados os indicadores usados, com respectivas siglas e fórmulas de cálculo, na Tabela 1, a seguir.

**Tabela 1**

Indicadores contábeis, siglas e fórmulas de cálculo.

| Indicador                          | Sigla | Fórmula de Cálculo                                                                                                                     |
|------------------------------------|-------|----------------------------------------------------------------------------------------------------------------------------------------|
| Liquidez Corrente                  | LC    | $\frac{\text{Ativo Circulante}}{\text{Passivo Circulante}}$                                                                            |
| Liquidez Seca                      | LS    | $\frac{\text{Ativo Circulante} - \text{Estoques} - \text{Desp. Antecipadas} - \text{Ativo Biológico (CP)}}{\text{Passivo Circulante}}$ |
| Proporção do Endividamento         | PE    | $\frac{\text{Passivo}}{\text{Passivo} + \text{Patrimônio Líquido}}$                                                                    |
| Composição do Endividamento        | CE    | $\frac{\text{Passivo Circulante}}{\text{Passivo}}$                                                                                     |
| Retorno sobre o Investimento       | RI    | $\frac{\text{Resultado Operacional Líquido}}{\text{Investimento Médio}}$                                                               |
| Retorno sobre o Patrimônio Líquido | RP    | $\frac{\text{Lucro Líquido}}{\text{Patrimônio Líquido Médio}}$                                                                         |

A partir da Tabela 1, pode-se tecer alguns comentários das especificidades do cálculo dos indicadores, a começar pela Liquidez Seca (LS). Para essa pesquisa, como trata-se de empresas sujeitas a ativo biológico no ativo circulante (Rodrigues, 2017; Santos & Silva, 2018), optou-se pela subtração também desse item, além dos tradicionais, mantendo a essência do indicador de definir a capacidade de pagamento a curto prazo dando preferência aos itens de maior rotação (Assaf Neto, 2020).

Quanto ao Retorno sobre o Investimento (RI), cabe destacar a divergência existente sobre seu conceito. Alguns autores o reconhecem como retorno sobre o ativo (e.g. Padoveze & Benedicto, 2010; Iudícibus, 2017; Martins et al., 2018, 2019; Marion, 2019; Silva, 2019), enquanto outros autores o dividem em dois conceitos: ativo e investimento (e.g. Ross et al., 2015; Assaf Neto, 2020).

O grupo que reconhece os dois como sendo a mesma coisa, geralmente, definem o ativo como algo próximo ao conceito de investimento estabelecido no referencial teórico deste estudo. Dessa forma, esta pesquisa aborda apenas o retorno sobre o investimento, embora entenda que exista distinção entre os dois.

Outro importante ponto que merece destaque sobre o RI é a utilização, para seu cálculo, de itens não observáveis diretamente nas demonstrações contábeis: Investimento e Resultado Operacional Líquido, calculados a parte.

O investimento refere-se ao montante que foi efetivamente investido na atividade operacional da empresa, podendo ser proveniente de recursos de terceiros ou dos capitais próprios. A captação desses recursos de terceiros incorre em despesas financeiras, sendo chamados de passivos onerosos. Dessa forma, pode-se dizer que o investimento é o somatório do PL com esses passivos onerosos (Assaf Neto, 2020; Martins et al., 2018).

O resultado operacional refere-se ao resultado que os investimentos geraram na execução das atividades operacionais da empresa. Portanto, depende exclusivamente das decisões de investimento, não importando as decisões de financiamento, das quais podem incorrer despesas financeiras (Assaf Neto, 2020; Martins et al., 2018; Padoveze & Benedicto, 2010).

Dessa forma, para que não haja influência do financiamento, desconsiderou-se as despesas financeiras do resultado operacional, incorporando ao resultado tanto a remuneração do capital próprio quanto a dos recursos de terceiros.

Entretanto, o resultado operacional é tido como líquido após a incidência dos tributos sobre a renda e, portanto, se são desconsiderados os efeitos das despesas financeiras sobre o resultado operacional, deve-se então considerar os efeitos dos tributos sobre o lucro incidindo sobre elas. Para isso, admitiu-se a alíquota padrão de 34% (Assaf Neto, 2020; Martins et al., 2018, 2019; Padoveze & Benedicto, 2010).

Outro ponto importante é que, dado o caráter estático das demonstrações, utilizou-se a média aritmética simples para o Investimento e o PL usados nos indicadores de rentabilidade, pois entende-se ser a média que gera o resultado. Justificando, com isso, a coleta dos dados do primeiro trimestre de 2010.

Em alguns casos, os investimentos efetuados pelos acionistas podem ser consumidos pelos resultados das operações, ou seja, o prejuízo acumulado fica maior que o PL, tornando esse negativo. Nessa condição, o capital de terceiros passa a

financiar a operação da empresa, impactando diretamente, no escopo desta pesquisa, nos indicadores PE, RI e RP.

No caso do indicador PE, desconsiderou-se o PL negativo, pois, nessa circunstância existem apenas capitais de terceiros financiando as operações da empresa, tornando o valor do indicador igual a 1.

Quanto aos indicadores de rentabilidade, estes serão desconsiderados totalmente, dado que o PL negativo impactaria diretamente no cálculo do Investimento, desfigurando o RI; além de inviabilizar por completo a figura do RP, já que, nessa circunstância, não existiria capital próprio investido nas operações.

Tal situação foi constatada nas empresas Minerva e Minupar. Para a empresa Minerva, os ajustes foram efetuados no primeiro, terceiro e quarto trimestres de 2015. Contudo, a partir de 2018 a empresa voltou a apresentar PL negativo, o que motivou sua exclusão da análise desse período, para os indicadores PE, RI e RP. Já a empresa Minupar apresentou PL negativo durante quase todo o período de análise, o que incorreu na sua exclusão da análise para esses três indicadores.

#### **4.5 Projeção dos Dados**

Definidos os indicadores contábeis utilizados, bem como suas respectivas fórmulas de cálculos, resta agora apontar como esses dados obtidos serão processados e projetados a fim de alcançar o objetivo desta pesquisa.

Assim, esse subtópico está dividido em três partes: 1) Contextualização – abordando de forma introdutória o campo de previsão de séries temporais; 2) Competição M4 – evidenciando os principais achados da, até então, última edição da principal competição de previsões de séries temporais; 3) Modelos de previsão de séries temporais – comentando os principais aspectos dos modelos em evidência; 4) Modelo FFORMA – destacando as características e resultados que justificam seu uso nesta pesquisa; e 5) Utilização do modelo FFORMA – discorrendo sobre os ajustes e o uso propriamente dito do modelo em questão.

##### **4.5.1 Contextualização**

Não faz muito tempo que as previsões passaram dos religiosos e supersticiosos para o campo científico, estendendo-se para além das ciências físicas só no final do século XIX e, embora tenham alta precisão nas ciências exatas, não compactuam da mesma exatidão nas ciências sociais, onde são comuns erros, como nas tentativas

de prever ciclos econômicos. Porém, é inegável a necessidade e influência das previsões no processo decisório (Makridakis et al., 2020).

O histórico das previsões de séries temporais é ainda mais recente, a partir do final da década de 1960, quando desencadearam estudos empíricos – que levariam às competições, fornecendo evidências objetivas para comparar a precisão dos vários modelos e validar diferentes hipóteses; aprimorando a precisão e a estimativa da incerteza das previsões; e, assim, melhorando notavelmente as previsões no campo das ciências sociais ao longo dos anos (Hyndman, 2020; Makridakis et al., 2020).

Com esse propósito de produzir evidências objetivas e gerar debate na comunidade, Makridakis e Hibon criaram em 1982 a *M Competition*, a primeira competição, de fato, de previsão de séries temporais, envolvendo 1.001 séries. Aceitaram previsões de qualquer pessoa que quisesse participar e disponibilizaram os dados necessários para a reprodução dos resultados para quem se interessasse em confirmar (Hyndman, 2020; Makridakis et al., 2020a).

Os resultados dessa competição sugeriram três conclusões principais: modelos estatisticamente sofisticados geralmente não produzem previsões mais precisas do que modelos simples; o desempenho dos modelos varia de acordo com a medida de precisão utilizada e a frequência observada; e a combinação de vários modelos supera esses mesmos modelos individualmente (Hyndman, 2020).

Embora pareçam senso comum para os analistas, essas conclusões eram revolucionárias na época, produzindo um efeito profundo na pesquisa de previsão, levando os pesquisadores a focar sua atenção nos modelos com boas previsões e não mais nas propriedades matemáticas desses modelos (Hyndman, 2020).

Dado o sucesso e objetivos alcançados com a primeira competição, as *M Competitions* estenderam-se ao longo dos anos, com a segunda edição, *M2 Competition*, ocorrendo em 1993, com a diferença de usar apenas 29 séries temporais, mas acrescentando informações contextuais, além de ser realizada em tempo real (Hyndman, 2020). A terceira competição, *M3 Competition*, ocorreu em 1998 e envolveu 3.003 séries temporais (Hyndman, 2020).

Dessa forma, as *M Competitions* tornaram-se referências na pesquisa empírica de previsões. Através dos conjuntos de dados publicamente acessíveis, inspiraram e motivaram pesquisadores e profissionais da área de previsão a desenvolver e testar seus próprios modelos, trazendo significativos avanços teóricos e de modelagem, preenchendo a lacuna entre a teoria e a prática (Petroopoulos e Makridakis, 2020).

#### 4.5.2 Competição M4

A quarta edição das *M Competitions* ocorreu em 2018, sendo composta por 100.000 séries temporais. Nessa edição, além das frequências das competições anteriores (anuais, trimestrais e mensais), foram incluídas frequências mais altas, como semanais, diárias e até mesmo horárias, enquanto o horizonte de previsões seguia a individualidade da tomada de decisão para cada frequência (Hyndman, 2020; Makridakis et al., 2020b; Petropoulos & Makridakis, 2020).

Para as previsões trimestrais, objeto desse estudo, foi estipulado oito previsões, dado que as decisões para essa frequência geralmente abrangem períodos variando de alguns meses a dois anos à frente (Makridakis et al., 2020b).

A unidade de medida do desempenho foi a chamada média ponderada geral (*overall weighted average – OWA*), que consiste na média ponderada entre a medida da edição anterior – erro percentual absoluto médio simétrico (*symmetric mean absolute percentage error – sMAPE*), e o erro médio absoluto escalonado (*mean absolute scale error – MASE*) (Makridakis et al., 2020; Makridakis et al., 2020b).

Quanto à reprodutibilidade dos dados, foi oferecida premiação específica ao melhor modelo replicável, dando ênfase e incentivando os participantes a publicarem o código do modelo utilizado, ou, em caso de direitos de propriedade, fornecerem uma versão do programa para que os organizadores pudessem avaliar a reprodutibilidade do resultado e a complexidade do modelo utilizado. Assim, os códigos para a maioria dos modelos utilizados foram disponibilizados pelos organizadores (Hyndman, 2020; Makridakis et al., 2020a, 2020b; Petropoulos & Makridakis, 2020; Taleb, 2020).

Além disso, foi introduzida a incerteza das previsões. Para que os participantes fossem elegíveis à premiação, deveriam fornecer os pontos de previsão das 100.000 séries temporais e, opcionalmente, embora altamente recomendado, os intervalos de previsão (Hyndman, 2020; Makridakis et al., 2020b; Petropoulos & Makridakis, 2020).

Os pontos de previsão fornecem a melhor previsão, de acordo com a unidade de medida estipulada, porém, sozinhos, são insuficientes e inseguros para a tomada de decisão (Hyndman & Athanasopoulos, 2018). Os intervalos de previsão, com uma cobertura de probabilidade especificada, quantificam a incerteza dos pontos de previsão, complementando-os e permitindo que essa incerteza possa ser levada em consideração na tomada de decisão (Januschowski et al., 2020; Makridakis et al., 2020; Makridakis et al., 2020b).

#### 4.5.3 Modelos de previsão de séries temporais

Com a *M4 Competition*, pode-se ver o fim dos métodos simples superando métodos complexos. O método vencedor, de acordo com a unidade de medida OWA, foi um modelo que combinava métodos estatísticos tradicionais com métodos de *machine learning*. Esse modelo, apresentado por Slawek Smyl – cientista de dados da *Uber Technologies*, é considerado híbrido, pois sua combinação é simultânea.

Enquanto o método de *machine learning* memoriza os padrões complexos dos subconjuntos de todas as séries de forma não linear, as equações de suavização exponencial capturam os principais componentes de cada série individual, gerando um aprendizado cruzado, que otimiza os parâmetros de ambos e melhora a precisão da previsão (Smyl, 2020; Januschowski et al., 2020; Petropoulos & Makridakis, 2020).

Dessa forma, pode-se observar que a chave do sucesso dos métodos de *machine learning* depende de um conjunto de dados de séries temporais suficientemente grande, pois são principalmente orientados pelos dados. Memorizam padrões não lineares de forma eficaz, não trazendo hipóteses estruturais, ou seja, não são limitados por suposições. Ajustam seus vários parâmetros de acordo com os dados, permitindo que esses falem por si (Januschowski et al., 2020; Smyl, 2020).

Mesmo que o modelo vencedor, embora combine métodos, seja considerado híbrido, os outros cinco modelos melhor classificados, com desempenhos próximos entre si, eram todos combinações de métodos. Essas combinações foram efetivamente mais precisas que os métodos estatísticos ou métodos de *machine learning* sozinhos, corroborando a ideia de que as combinações melhoram a precisão da previsão (Makridakis et al., 2020b; Petropoulos & Makridakis, 2020).

A forma geralmente usada para combinar métodos é a média simples, porém formas menos simples, como médias ponderadas, podem ter um desempenho melhor, além de diminuir o risco de selecionar um modelo mal especificado. Essa foi a forma usada pelo segundo melhor ranqueado na competição, o modelo *FFORMA* (Makridakis et al., 2020; Makridakis et al., 2020b; Montero-Manso et al., 2020).

Quando observado apenas os resultados para as séries temporais de frequência trimestral, objeto da presente pesquisa, o modelo *FFORMA* foi o melhor ranqueado, superando o modelo híbrido, além de ser considerado totalmente replicável. Por todo o exposto, o modelo *FFORMA* foi o escolhido para utilização nesta pesquisa (Makridakis et al., 2020b).



#### 4.5.4 Modelo FFORMA

O modelo *FFORMA* (*Feature-based FORecast Model Averaging*) pode ser encarado como uma expansão do modelo *FFORMS* (*Feature-based FORecast Model Selection*) proposto por Talagala et al. (2018), que utiliza os recursos das séries temporais através da combinação, com meta-aprendizado, para selecionar um único método específico para a previsão. O *FFORMA* usa o mesmo processo para selecionar pesos, fazendo uma combinação ponderada dos seus diversos métodos de previsão, como os nomes dos modelos sugerem (Montero-Manso et al., 2020).

O modelo *FFORMA* utiliza oito métodos estatísticos, todos em configuração padrão, sendo eles: método ingênuo; passeio aleatório com deslocamento; método ingênuo sazonal; método Theta; ARIMA automatizado; suavização exponencial automatizada; modelo TBATS; e método STLM-AR com decomposição sazonal e de tendência, usando *loess* com modelagem auto regressiva da série ajustada sazonalmente. Além desses, usa também um método de *machine learning*: rede neural de previsão de séries temporais (Montero-Manso et al., 2020).

O modelo *FFORMA* utiliza-se de uma abordagem de *machine learning*, usando os recursos (frequência, tendência, correlações, etc.) extraídos das séries temporais para formar o ajuste do modelo de meta-aprendizado, que, a partir das previsões individuais dos seus oito métodos estatísticos, seleciona pesos, buscando a melhor combinação ponderada, com base na medida OWA (Montero-Manso et al., 2020; Lichtendahl Jr. & Winkler, 2020).

#### 4.5.5 Utilização do modelo FFORMA

A partir dos dados encontrados, utilizou-se o RStudio – um ambiente de desenvolvimento integrado desenvolvido para o software R, pela possibilidade de reprodução do modelo *FFORMA*, pois é para esse ambiente que seu uso foi projetado.


Para facilitar, os quatro trimestres do ano serão tratados a partir daqui como Q1, Q2, Q3 e Q4. Dessa forma, os dados das empresas foram organizados em séries temporais pelo período do Q1 de 2011 até o Q1 de 2019. As séries foram então organizadas em subconjuntos de acordo com os indicadores contábeis a que se referem, sendo eles: LS, LC, PE, CE, RI e RP.

Com as séries temporais definidas, pode-se proceder ao uso do modelo *FFORMA*. Com o objetivo de melhor ilustrar seu uso, está demonstrado na Figura 1,

a seguir, um fluxograma de autoria dos autores do modelo, indicando os passos a serem seguidos, de acordo com os objetivos e contexto do seu uso.

**Figura 1**

Fluxograma de uso do modelo FFORMA.



Fonte: Montero-Manso, P. (2018). Methodology: Combination of Forecast Methods by Feature-based learning.

A partir do fluxograma da Figura 1, optou-se por seguir o caminho de treinamento do modelo, com o objetivo de conseguir o melhor ajuste. Em um primeiro momento, selecionou-se apenas o período do Q1 de 2011 até o Q1 de 2017, imediatamente anterior à deflagração da Operação Carne Fraca, sendo ajustado para que fossem projetados quatro trimestres.

Assim, o modelo FFORMA recorta e separa as quatro últimas observações de cada série do subconjunto, promovendo as previsões, a partir de cada um de seus métodos de previsão, tendo como referência o histórico de observações restantes de cada série do subconjunto. Efetuadas as previsões, calcula-se os erros de cada método de previsão para cada série.


Por meio de uma abordagem de aprendizagem cruzada, com base nos erros e em outros recursos extraídos, o modelo FFORMA produz pesos para os métodos individuais, ou seja, probabilidades de cada método ser o melhor, de modo a minimizar cada vez mais o erro, produzindo previsões mais precisas, melhorando sua performance. Esse procedimento foi efetuado para todos os subconjuntos, de modo que um ajuste específico de modelo fosse definido para cada indicador.

Com os modelos ajustados, optou-se por validar esse ajuste, fazendo as previsões para os quatro períodos que foram recortados da amostra anteriormente e que serão usados para validação. Para demonstrar a capacidade de previsão do modelo, efetuou-se a comparação dos pontos de previsão desse período com os dados reais observados.

Embora tenham sido efetuadas previsões para todos os indicadores de todas as empresas (ver Apêndice A), optou-se por resumi-las em apenas seis gráficos, um para cada indicador, com cada empresa ilustrando um determinado indicador. Essas previsões estão demonstradas na Figura 2, a seguir, e seus respectivos valores de performance registrados como “treino”, para uso no decorrer da pesquisa.

**Figura 2**

Previsão dos modelos ajustados para os indicadores pré-operação.



A Figura 2 demonstra as previsões, a partir dos modelos ajustados individualmente para cada um dos indicadores tratados nessa pesquisa. Em verde, pode-se observar o histórico dos dados, do Q1 de 2011 até o Q1 de 2016; em roxo, estão representados os dados reais do Q2 de 2016 até o Q1 de 2017; e em azul, estão as previsões efetuadas para esse mesmo período.


## 5 ANÁLISE DE RESULTADOS

A partir do modelo ajustado para cada indicador, procedeu-se os testes objeto desta pesquisa, verificados, em um primeiro momento, pela análise gráfica das figuras organizadas por indicador.

Para todas as figuras, a linha tracejada, que corta cada gráfico, representa o momento da deflagração da Operação Carne Fraca; a linha verde representa o histórico; a linha azul representa a projeção do modelo *FFORMA*; e a linha roxa representa as observações reais.

O primeiro índice é o de Liquidez Seca (Figura 3) o qual demonstra quanto existe de ativos com maiores probabilidades de se liquidarem para cada um real de dívida no passivo circulante.

**Figura 3.**  
Previsões para o indicador LS pós-operação Carne Fraca.



Com base na Figura 3, percebe-se que a empresa Minerva é a única a ter, durante todo o período, valores acima de 1, indicando ter capacidade de, a partir dos ativos com maior potencial de transformar-se em recursos financeiros, quitar suas obrigações de curto prazo.

Isso pode ser percebido inclusive no período após a deflagração da Operação Carne Fraca, quando demonstrou uma acentuada queda, chegando ao menor nível de todo o período trabalhado, fato não indicado pela previsão do modelo, a qual projetava uma certa estabilidade.

A condição da empresa BRF, após a Operação Carne Fraca, é bastante semelhante à da Minerva, com o modelo prevendo estabilidade, enquanto os

resultados observados demonstram também uma queda ao menor nível do período. Quanto ao valor do índice, esse oscilava valores próximos a 1, sugerindo uma situação relativamente saudável até a deflagração da operação.

Essa situação de relativa saúde financeira também pode ser observada na empresa Marfrig, que ficou grande parte do período com valores acima de 1. O modelo projetou uma pequena oscilação no Q1 de 2018 e certa estabilidade em torno de 1,6, enquanto os dados observados, embora corroborem a oscilação, demonstram uma queda de maior intensidade, com o pico negativo estando abaixo de 1.

Já a empresa Excelsior, no período próximo à deflagração, oscilava valores acima de 1, sendo projetadas pelo modelo pequenas oscilações no Q3 de 2017 e no Q3 de 2018, próximas a esse valor. Essas oscilações também podem ser verificadas pelos dados observados, porém em níveis acima do projetado, chegando a 1,4 no Q3 de 2018 e apresentando tendência de alta.

Quanto à JBS, a mesma apresentava tendência de queda nos anos anteriores à deflagração, embora tenha esboçado um leve sinal de melhora, ainda abaixo de 1, considerado, em tese, como saudável. O modelo projetou a sequência de estabilidade da última observação, enquanto os dados reais apresentaram uma forte alta no Q2 de 2018, ultrapassando os maiores níveis históricos, indicando uma grande capitalização de recursos ou uma possível reestruturação da composição de sua dívida.


Por fim, a empresa Minupar demonstrava estabilidade desde 2014, porém com níveis baixíssimos de liquidez – próximos a zero, sugerindo ou uma falta de ativos com potenciais de se tornarem líquidos, ou uma igualmente preocupante estrutura de dívida de curto prazo.

O modelo seguiu a estabilidade dos dados, projetando valores tendendo a zero, enquanto os dados observados, imediatamente após a deflagração, indicaram uma imediata e abrupta alta nesse indicador, no entanto, logo em seguida, retornando aos níveis da estabilidade anterior.

Essa mudança indicaria uma ação imediata da empresa em realocar recursos ou reestruturar a dívida, porém, como logo no próximo período a situação retornou ao estado anterior, infere-se a ocorrência de algum fato atípico e isolado.

O próximo indicador é o de Liquidez Corrente, que engloba todos os ativos de curto prazo. Esse indicador demonstra quanto existe de ativo com expectativa de liquidação no curto prazo para cada real de dívida também de curto prazo e está representado na Figura 4, a seguir.

**Figura 4**  
Previsões para o indicador LC pós-operação Carne Fraca.



É possível destacar a semelhança dos gráficos apresentados na Figura 3, em relação aos gráficos apresentados no indicador anterior. Isso ocorre pelo fato de ambos terem as obrigações de curto prazo como representante do denominador, diferindo-se apenas nos valores do numerador. Assim, um aumento no valor deste indicador, em relação ao anterior, indicaria uma efetiva participação dos ativos excluídos naquele índice.

De maneira geral, o modelo *FFORMA* repetiu as características das previsões anteriores, alterando apenas em nível para o indicador LC, acompanhando o histórico das empresas. Todavia, a maioria das empresas passaram a estar a maior parte do período, se não todo ele, com mais potenciais recursos no ativo de curto prazo do que obrigações de mesmo período, oscilando seus valores quase sempre acima de 1.


A empresa Minupar é a única que destoa dessa condição, seguindo o apresentado anteriormente, manteve a, em tese, preocupante situação de valores próximos à zero no período pré-operação Carne Fraca, situação seguida pela projeção do modelo. Os dados observados voltaram a indicar a severa alta no valor do Q2 de 2017, que novamente retornou ao nível da estabilidade, sugerindo indiferença na participação dos ativos excluídos pelo indicador LS.

Ainda, diferindo-se das previsões do modelo para o indicador anterior, cabe destacar a previsão para a empresa JBS, que, dessa vez, captou um arco de subida, mas, ainda abaixo do observado nos dados.

Na sequência, estão os indicadores de composição da dívida, começando pela Proporção do Endividamento. Esse indicador demonstra quanto a empresa tem de recursos de terceiros, não levando em conta os prazos dessas obrigações, para cada recurso próprio. O indicador PE está representado na Figura 5, a seguir.

**Figura 5**

Previsões para o indicador PE pós-operação Carne Fraca.



A princípio, pode-se perceber na Figura 5 a falta da empresa Minupar, justificada pela constatação, na maior parte do período abordado, de PL negativo. Assim, seu PE seria quase sempre igual a 1, dado que, nessa condição, não existem capitais próprios financiando a empresa, desqualificando uma previsão. A mesma situação é encontrada na empresa Minerva, porém, apenas nos períodos finais, viabilizando previsão até o Q4 de 2017.

Todas as empresas passíveis de previsão, com exceção da Excelsior, apresentaram tendência de alta no valor absoluto do indicador, apontando uma reestruturação do capital de financiamento, com preferência para capitais de terceiros.

Como esse indicador é, em tese, um reflexo da decisão estratégica das empresas, as previsões efetuadas pelo modelo *FFORMA*, ao seguir a tendência mencionada, estiveram sempre muito próximas aos valores reais, que oscilaram em torno dos 80% de capitais de terceiros financiando as atividades empresariais.

Na contramão desse processo, a empresa Excelsior apresentava tendência de queda no valor absoluto do PE, indicando sair da situação de financiamento quase total por capitais de terceiros, para uma maior preferência por recursos próprios, sugerindo uma diminuição considerável em suas dívidas.


Quanto à previsão, possivelmente motivado pela relativa estabilidade nos períodos imediatamente anteriores à deflagração da operação, o modelo apresentou projeções em torno de 50%, indicando equilíbrio de financiamento, no entanto, os dados observados seguiram a tendência histórica anterior e demonstraram valores abaixo de 40% no Q1 de 2019.

Cabe ressaltar que, embora exista um maior risco na preferência de utilização por capitais de terceiros, quando seu custo de captação for menor do que a rentabilidade de um possível investimento, essa passa a ser a opção mais interessante. Além disso, outro ponto importante é a questão dos prazos dessas obrigações, observada no próximo indicador.

O índice de Composição do Endividamento demonstra qual a participação das obrigações de curto prazo, em relação à todas as obrigações com terceiros. Em tese, considera-se positivo menores valores para esse indicador, uma vez que indicaria que a maior parte da dívida contraída com terceiros é de longo prazo, ou seja, com maior prazo para ser quitada. Esse indicador está representado na Figura 6, a seguir.

**Figura 6**

Previsões para o indicador CE pós-operação Carne Fraca.



Observa-se, na maioria dos gráficos da Figura 6, bastante oscilação nos valores de uma mesma empresa, o que é natural, dado que as dívidas de longo prazo, com o passar do tempo, passam a ser de curto prazo. As empresas Excelsior e Minupar apresentam uma certa estabilidade em altos valores no indicador, com pequenas oscilações e maior suavidade, indicando preferência em trabalhar com obrigações de curto prazo.



O histórico da Excelsior indicava, antes da deflagração da operação, certa estabilidade com tendência de alta, chegando a quase 90% de dívidas de curto prazo, situação que se manteve nas previsões do modelo *FFORMA* e foram corroboradas pelas observações reais.

Embora seja estabelecido que dívidas de longo prazo são, por via de regra, melhores para a saúde financeira da empresa, a Excelsior apresentou bons níveis de liquidez, indicando conseguir arcar com as obrigações de curto prazo usando apenas os ativos de maior liquidez, mesmo que suas dívidas estejam em quase sua totalidade dispostas no curto prazo.

Em situação oposta está a empresa Minupar. Seu histórico também indicava certa estabilidade com tendência de alta em níveis próximos aos 80%, aumentando a preocupação demonstrada pelos baixos índices de liquidez. Essa tendência foi representada nas previsões do modelo, entretanto, novamente percebe-se, nos valores observados, o imediato rompimento da estabilidade no Q2 de 2017.

Nesse caso, complementando o sugerido pelos indicadores anteriores, houve de fato uma reestruturação das dívidas que saíram de 80% de curto prazo para abaixo de 10%, no entanto, isso se desfez logo no próximo trimestre, inferindo novamente uma situação atípica e isolada.

As demais empresas apresentaram um histórico de oscilações, possivelmente acompanhando seus ciclos operacionais, abaixo de 50%, indicando que a maior parte de suas dívidas estão alocadas no longo prazo. O modelo *FFORMA*, de forma geral, seguiu o histórico das empresas e estimou, para todas essas, uma continuação natural do que se era observado. Todavia, os dados reais observados quebram a constância, sugerindo decisões estratégicas.

As empresas BRF, Minerva e Marfrig demonstraram, após a deflagração da Operação Carne Fraca, um aumento na proporção das suas obrigações de curto prazo em relação às obrigações de longo prazo, chegando aos maiores níveis dessas empresas em todo o período trabalhado. Essa situação sugere, a princípio, um movimento de captação de recursos de terceiros de curto prazo, equilibrando a estrutura das obrigações entre curto e longo prazo.

Em contraponto ao mencionado, a empresa JBS demonstrou o processo inverso, com a proporção das obrigações de curto prazo diminuindo para os menores níveis observados no período, chegando a pouco mais de 20%. Nessa situação, a mudança pode indicar captação de recursos de terceiros de longo prazo e/ou


quitação/renegociação das dívidas de curto prazo, realocando grande parte dessas obrigações para o longo prazo.

Estabelecida a análise sobre a estrutura do endividamento, pode-se proceder à análise gráfica dos indicadores de rentabilidade: Retorno do Investimento e Retorno do PL. Cabe ressaltar que como alertado no indicador PE, a empresa Minupar teve a análise inviabilizada para os indicadores de rentabilidade. Além de, para a empresa Minerva, ser efetuado previsões apenas para três períodos após a operação.

O Retorno do Investimento evidencia quanto os investimentos realizados proporcionaram de resultado, relacionando todos os investimentos com o resultado efetivamente operacional. Os resultados para o RI estão demonstrados na Figura 7.

**Figura 7**

Previsões para o indicador RI pós-operação Carne Fraca.



Os gráficos da Figura 7 sugerem, a princípio, bastante oscilação de valores durante todo o período, no entanto, essa oscilação ocorre em níveis bem pequenos, com o valor pouco se alterando, sendo basicamente impressão de escala.

A pouca variação provavelmente influenciou as previsões do modelo *FFORMA*, que se mantiveram na média dos dados históricos. Para as empresas JBS e Excelsior, os dados observados corroboraram as estimativas do modelo, excetuando-se o Q1 de 2019 da Excelsior, que demonstra uma alta ao maior nível do período.


No caso das empresas BRF, Minerva e Marfrig, os dados observados também oscilaram relativamente próximos às previsões, todavia, demonstrando picos negativos superiores aos históricos do período trabalhado, indicando inclusive retornos negativos. De maneira geral, os valores desse indicador ficaram bem

próximos à zero, apontando baixos níveis de retorno do investimento, a partir da metodologia de cálculo utilizada por esta pesquisa.

Por fim, resta o Retorno do Patrimônio Líquido, que leva em consideração a forma de financiamento, evidenciando o quanto os capitais próprios da empresa proporcionaram de resultado. Os resultados desse indicador estão demonstrados na Figura 8, a seguir.

**Figura 8**

Previsões para o indicador RP pós-operação Carne Fraca.



Antes de proceder à análise, deve-se esclarecer uma limitação do modelo, visível na Figura 8. O modelo *FFORMA* padronizou o número zero como limite inferior, inviabilizando previsões com valores negativos e, assim, comprometendo as previsões das empresas BRF, Minerva e Marfrig para o indicador RP.

No entanto, em algumas das situações demonstradas, é razoável conceber que o modelo *FFORMA* não seria capaz de prever as profundas variações observadas nos dados reais. Por exemplo, a queda no valor do indicador apresentada pela empresa BRF, fugindo de todo o período histórico até então. Da mesma forma para a empresa Minerva, porém em menor escala, dada a limitação de períodos tratados. Já quanto à empresa Marfrig, essa demonstrou alta acima dos níveis históricos no Q4 de 2018, retornando à média no trimestre seguinte.

No caso da empresa JBS, os dados observados estiveram próximos às previsões do modelo, porém com oscilações negativas maiores, atingindo retornos negativos. Já, para a empresa Excelsior, repetiu-se a situação do indicador RI, com

os dados oscilando próximos aos previstos, com exceção do Q1 de 2019, que apresentou uma abrupta alta.

Finalizada a análise gráfica, pode-se quantificar o desempenho das previsões, observando os erros calculados. Como abordado anteriormente, o modelo *FFORMA* calcula os pesos dos seus métodos em seu modelo de previsão.

A partir desse modelo ponderado, para cada indicador, foram efetuadas as previsões, comparadas aos dados observados e, conseqüentemente, gerados os resultados de performance do modelo. Entre esses resultados, está a medida do erro do modelo ponderado – a medida real do desempenho da previsão, utilizada como critério de classificação na competição M4.

Esses valores de performance foram organizados, para cada indicador, no período de treino – previsões para o período anterior à deflagração da Operação Carne Fraca; e no período de teste – previsões após a Operação Carne Fraca. Esses erros do modelo ponderado podem ser observados na Tabela 2, a seguir.

**Tabela 2**

Valores da performance (OWA) para cada indicador nos períodos de Treino e Teste.

| Indicador | Treino    | Teste     |
|-----------|-----------|-----------|
| LS        | 0.5534094 | 1.0727886 |
| LC        | 0.4779656 | 1.0210639 |
| PE        | 0.8062408 | 0.7837534 |
| CE        | 0.6265432 | 0.9823430 |
| RI        | 0.6338588 | 0.8328615 |
| RP        | 0.9007917 | 0.9551770 |

De maneira geral, é possível perceber que os valores na coluna de Treino são quase em sua totalidade, exceto para o indicador PE, menores que os valores na coluna de Teste, indicando, a princípio, uma melhor performance do modelo *FFORMA* nas previsões anteriores à deflagração da Operação Carne Fraca.

Com o intuito de verificar se essa diferença tem significância estatística, foi efetuado o *t-test* pareado (ver Apêndice B) nos dados encontrados, admitindo um intervalo de confiança de 95% e tendo como hipótese nula que a diferença entre as médias seria igual a zero. Os resultados desse teste podem ser verificados na Figura 9, a seguir.

**Figura 9**

*t-test* nos erros de previsão do treino e do teste.

|                                                                    |
|--------------------------------------------------------------------|
| <b>Paired t-test</b>                                               |
| data: treino and teste                                             |
| t = -2.8397, df = 5, p-value = 0.03626                             |
| alternative hypothesis: true difference in means is not equal to 0 |
| 95 percent confidence interval                                     |

A partir do resultado para o *p-value* no *t-test* efetuado, verificado na Figura 8, rejeita-se a hipótese nula. Portanto, pode-se afirmar que a média dos erros encontrados pela aplicação do modelo *FFORMA* nos dados anteriores à deflagração da Operação Carne Fraca variou com significância estatística da média dos erros encontrados nas previsões posteriores, admitindo um intervalo de confiança de 95%, indicando a influência da deflagração da operação na performance do modelo.

No entanto, essa análise demonstra a influência da Operação Carne Fraca de uma forma geral, pois trata de forma conjunta todos os indicadores. Assim, para aprofundar essa investigação, os erros de previsão foram organizados por empresa, para cada indicador, nos dados antes e depois da deflagração da Operação Carne Fraca, podendo ser observados na Tabela 3, a seguir.

**Tabela 3**

Valores da performance (*OWA*) para cada indicador de cada empresa.

|        |           | LS       | LC       | PE       | CE       | RI       | RP       |
|--------|-----------|----------|----------|----------|----------|----------|----------|
| Treino | BRF       | 0.568116 | 0.712489 | 0.578820 | 1.312607 | 0.903685 | 0.848920 |
|        | JBS       | 0.358522 | 0.203579 | 0.824351 | 0.719807 | 0.353667 | 1.288093 |
|        | Excelsior | 0.239476 | 0.266501 | 1.655308 | 0.570981 | 0.480356 | 0.562841 |
|        | Minerva   | 0.587069 | 0.552630 | 0.806232 | 0.453148 | 0.631479 | 0.838690 |
|        | Marfrig   | 0.771100 | 0.462740 | 1.020108 | 0.546238 | 0.666454 | 0.446465 |
|        | Minupar   | 0.825443 | 0.784042 | -        | 0.577742 | -        | -        |
| Teste  | BRF       | 1.188845 | 1.129715 | 0.508668 | 0.875562 | 0.807517 | 1.049277 |
|        | JBS       | 0.936189 | 0.644026 | 2.050782 | 0.997983 | 0.730726 | 0.690024 |
|        | Excelsior | 0.930695 | 1.084034 | 1.158941 | 0.445050 | 0.933294 | 0.910072 |
|        | Minerva   | 0.921273 | 1.068557 | 0.684502 | 0.944567 | 0.796550 | 1.012184 |
|        | Marfrig   | 1.750836 | 1.546535 | 0.609937 | 1.066644 | 0.831807 | 0.931703 |
|        | Minupar   | 1.028500 | 1.069856 | -        | 1.062803 | -        | -        |

Com base nos dados da Tabela 3, efetuou-se novamente o *t-test*, para cada indicador, a fim de verificar em quais indicadores pode-se observar, com significância estatística, variações na média dos erros antes e depois da deflagração da Operação Carne Fraca.

Os novos testes efetuados seguem o mesmo padrão do teste observado na Figura 9, entretanto, para melhor disposição dos dados, destacou-se apenas os valores referente ao *p-value*, demonstrando-os na Tabela 4, a seguir.

**Tabela 4**

Resultados do *t-test* para cada indicador.

| Indicador | <i>p-value</i> | Significância |
|-----------|----------------|---------------|
| LS        | 0.003849       | Sim           |
| LC        | 0.004599       | Sim           |
| PE        | 0.9384         | Não           |
| CE        | 0.2675         | Não           |
| RI        | 0.09109        | Não*          |
| RP        | 0.5537         | Não           |

Nota. Não\* = apresenta significância apenas admitindo intervalo de confiança de 90%.

A partir dos dados da Tabela 2, os resultados encontrados permitem afirmar que a média dos erros de previsão nos dados pré-operação Carne Fraca diferiu-se, com significância estatística, da média dos erros de previsão nos dados após a deflagração da Operação Carne Fraca para alguns indicadores.

Esse resultado sugere que a Operação Carne Fraca influenciou na previsão dos indicadores de Liquidez Seca e Liquidez Corrente, com um intervalo de confiança de 95%. Ainda, cabe destacar que, caso fosse estabelecido um intervalo de confiança menor, de 90%, também poderia ser destacado o indicador de Rentabilidade do Investimento entre os que apresentaram variação com significância estatística.

Para os demais indicadores, os resultados encontrados sugerem que a variação encontrada pode ser fruto do acaso, não sendo atribuída significância estatística.

Na sequência, complementarmente, efetuou-se novamente o *t-test* também para os erros de previsão em relação a cada empresa, demonstrado, no mesmo formato da tabela anterior, na Tabela 5, a seguir.

**Tabela 5**

Resultados do *t-test* para cada empresa.

| <b>Empresa</b> | <b><i>p-value</i></b> | <b>Significância</b> |
|----------------|-----------------------|----------------------|
| BRF            | 0.5297                | Não                  |
| JBS            | 0.1706                | Não                  |
| Excelsior      | 0.2285                | Não                  |
| Minerva        | 0.04507               | <b>Sim</b>           |
| Marfrig        | 0.08971               | Não*                 |
| Minupar        | 0.06049               | Não*                 |

*Nota.* Não\* = apresenta significância apenas admitindo intervalo de confiança de 90%.

Com base nos resultados da Tabela 5, é possível afirmar que, para um intervalo de confiança de 95%, a empresa Minerva é a única a apresentar variação geral da média de erros das previsões do modelo *FFORMA* para os indicadores com significância estatística. Esse resultado sugere a influência da Operação Carne Fraca no desempenho do modelo em prever os dados dessa empresa.

A empresa Minerva não era investigada pela Operação Carne Fraca, dessa forma, tal influência da operação sugere também a presença de efeito contágio. No mesmo sentido, para um intervalo de confiança de 90%, pode-se incluir as empresas Marfrig e Minupar na sugestão anterior.

Cabe destacar que as empresas investigadas pela Operação Carne Fraca, BRF e JBS, não demonstraram variação com significância estatística na média dos erros de previsão do modelo *FFORMA*.

Por fim, optou-se por agrupar os indicadores de acordo com suas características, a fim de melhor entender em quais grupos podem ser observadas as variações com significância estatística. Assim, para cada empresa, efetuou-se novamente o *t-test* em cada grupo, demonstrados na Tabela 6, a seguir.

**Tabela 6**

Resultados do *t-test* para cada empresa.

| Empresa   | Liquidez       |               | Endividamento  |               | Rentabilidade  |               |
|-----------|----------------|---------------|----------------|---------------|----------------|---------------|
|           | <i>p-value</i> | Significância | <i>p-value</i> | Significância | <i>p-value</i> | Significância |
| BRF       | 0.1233         | Não           | 0.3987         | Não           | 0.7849         | Não           |
| JBS       | 0.08529        | Não*          | 0.358          | Não           | 0.8581         | Não           |
| Excelsior | 0.05317        | Não*          | 0.3418         | Não           | 0.08362        | Não*          |
| Minerva   | 0.1341         | Não           | 0.6546         | Não           | 0.01583        | <b>Sim</b>    |
| Marfrig   | 0.03208        | <b>Sim</b>    | 0.9249         | Não           | 0.2909         | Não           |
| Minupar   | 0.1068         | Não           | -              | -             | -              | -             |

Nota. Não\* = apresenta significância apenas admitindo intervalo de confiança de 90%.

Os resultados observados na Tabela 6 indicam que, com um intervalo de confiança de 95%, o modelo *FFORMA* apresentou variação com significância estatística na performance de sua previsão para os indicadores de liquidez da empresa Marfrig e para os indicadores de rentabilidade da empresa Minerva, sugerindo que ambas sofreram influência da Operação Carne Fraca.

Ressalta-se novamente a não investigação das empresas Marfrig e Minerva, corroborando os resultados encontrados na Tabela 5 anterior, ou seja, inferindo indícios da presença de efeito contágio no caso estudado.

Complementarmente, admitindo-se um intervalo de confiança de 90%, pode-se destacar variação com significância estatística na performance do modelo *FFORMA* para os indicadores de liquidez da empresa JBS e para os indicadores de liquidez e rentabilidade da empresa Excelsior.

Nesses casos, não se poderia inferir efeito contágio, dado que a empresa JBS era uma das investigadas, sendo esperada essa influência; enquanto os efeitos encontrados na empresa Excelsior foram positivos, beneficiando sua saúde financeira, indo de encontro à essência do conceito de efeito contágio apresentado.

Por fim, justifica-se a inexistência de resultado nos dois últimos grupos de indicadores para a empresa Minupar, dada a inviabilidade de previsão de um dos indicadores de endividamento e dos dois indicadores de rentabilidade, impossibilitando o cálculo do *t-test*.

## 6 CONSIDERAÇÕES FINAIS

A presente pesquisa teve o objetivo de analisar os possíveis efeitos da Operação Carne Fraca observados, à luz da teoria do efeito contágio, na evolução dos indicadores contábeis das empresas do segmento de carnes e derivados listadas na B3, comparando as previsões do modelo *FFORMA* com os dados observados.

O estudo avança em relação a literatura existente ao propor o uso de uma metodologia que possibilita a obtenção de resultados, em tese, mais acurados, em detrimento da análise convencional, dado seu retrospecto na *M4 Competition* que, no período de realização do estudo, é considerada a principal competição de previsões de séries temporais.

A partir dos resultados obtidos na aplicação do modelo, realizou-se inicialmente uma análise gráfica, destacando os aspectos referentes às particularidades dos indicadores e às variações encontradas entre os cenários hipotético e real. Na sequência, efetuou-se o *t-test* nos resultados das performances do modelo para os períodos de treino e teste, como forma de quantificar estatisticamente as variações.

Como resultado do *t-test* realizado, foi constatado que, dado um intervalo de confiança de 95%, houve variação com significância estatística entre a performance do modelo no período pré-operação e a performance do modelo no período após a deflagração da operação.

Esse resultado sugere a influência da Operação Carne Fraca na precisão do modelo, corroborando a concepção de que a deflagração influenciou no desempenho dos indicadores das empresas do segmento de carnes.

No entanto, como trata-se de um resultado geral para todos os indicadores, optou-se por realizar novos *t-tests* justamente com o intuito de aprofundar cada vez mais o estudo em questão, aprimorando a percepção dos resultados.

Nesse sentido, o último *t-test* foi realizado agrupando-se os indicadores de acordo com suas características, o que permitiu individualizar os resultados por grupo de indicadores e separá-los por empresas, complementando a análise proposta.

Com esse último teste, pode-se afirmar, com um intervalo de confiança de 95%, que a performance do modelo *FFORMA* variou com significância estatística nos indicadores de rentabilidade da empresa Minerva e nos indicadores de liquidez da empresa Marfrig.



Tais empresas não foram investigadas pela operação Carne Fraca, contudo é nítido como a análise gráfica demonstra piora em seus indicadores após a deflagração, inferindo, portanto, a presença de efeito contágio.

Dessa forma, a partir da metodologia proposta e aplicada, os resultados dos testes estatísticos realizados corroboram a percepção da existência de efeito contágio nos casos mencionados.

Assim, o presente estudo contribuiu com a área da pesquisa científica em contabilidade financeira ao propor o uso de uma metodologia pouco explorada para a análise empírica de resultados, especificamente, os modelos de previsões de séries temporais.

Outra contribuição do estudo é a de incentivar pesquisadores a olhar não apenas para as empresas atingidas diretamente pelos eventos objetos da análise, mas também buscar indícios da existência de efeito contágio em outras entidades do mesmo setor, enriquecendo os resultados.

Cabe ressaltar que, para este estudo, durante a aplicação do modelo FFORMA, especificamente na previsão do indicador de rentabilidade do investimento, único a apresentar valores negativos, o modelo padronizou o limite inferior como sendo o número zero, ou seja, considerando apenas valores positivos na projeção. Assim, inviabilizou a previsão de dados negativos, o que pode ser considerada uma limitação.

No decorrer do presente estudo, preocupou-se com a escolha de caminhos que ressaltem a importância do tema e levem a reflexões acerca da utilização de metodologias alternativas com enfoque na acurácia dos resultados e proporcionem desenvolvimento empírico da pesquisa científica.

Neste sentido, como agenda de pesquisa, novos estudos podem utilizar da metodologia proposta para projetar dados transcorridos, comparando os cenários hipotéticos gerados, com o cenário real observado de outros eventos objetos de análise. Portanto, sugere-se a expansão do estudo em questão, trabalhando no cenário da pandemia de covid-19, verificando sua possível influência nos dados.

Adicionalmente, sugere-se que ao utilizar a metodologia proposta, o pesquisador atente-se à robustez de sua base de dados, com o intuito de considerar um maior universo de dados possível, aprimorando o ajuste do modelo de previsão e melhorando, em tese, a sua precisão.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABIEC (2021). *Beef report: Perfil da pecuária no Brasil 2021*. <http://abiec.com.br/publicacoes/beef-report-2021/>
- ABPA (2021). *Relatório anual 2021*. [https://abpa-br.org/wp-content/uploads/2021/04/ABPA\\_Relatorio\\_Anual\\_2021\\_web.pdf](https://abpa-br.org/wp-content/uploads/2021/04/ABPA_Relatorio_Anual_2021_web.pdf)
- Anvisa (2017). *Nota da Anvisa sobre a Operação “Carne Fraca”*. Recuperado de [http://portal.anvisa.gov.br/noticias/-/asset\\_publisher/FXrpx9qY7FbU/content/nota-da-anvisa-sobre-a-operacao-carne-fraca-/219201/pop\\_up?inheritRedirect=false](http://portal.anvisa.gov.br/noticias/-/asset_publisher/FXrpx9qY7FbU/content/nota-da-anvisa-sobre-a-operacao-carne-fraca-/219201/pop_up?inheritRedirect=false)
- Assaf Neto, A. (2020). *Estrutura e análise de balanços: Um enfoque econômico-financeiro* (12a ed.). São Paulo, SP: Atlas.
- B3. (2018). *Regulamento para listagem de emissores e admissão à negociação de valores mobiliários*. Recuperado de <http://www.b3.com.br/data/files/78/37/2D/70/DEAD261031540D26790D8AA8/Regulamento-para-Listagem-de-Emissores-e-Admissao-a-Negociacao-de-Valores-Mobiliarios-02.05.2018.pdf>
- Barros, C. M. E., Lopes, I. F., & Almeida, L. B. (2017). Efeito contágio da Operação Carne Fraca sobre o valor das ações dos principais players do mercado de proteínas do Brasil e do México. *Enfoque: Reflexão Contábil*, 38(1), 105-122.
- Bastos, E. S., Rosa, M. P., & Pimenta, M. M. (2016). Os impactos da Operação Lava Jato e da crise internacional do petróleo nos retornos anormais e indicadores contábeis da Petrobras 2012-2015. *Pensar Contábil*, 18(67), 49-56.
- Coelho, A. S. (2017). *Impacto da Operação Carne Fraca nas exportações de carne brasileira* (Trabalho de conclusão de curso). Insper – Instituto de Ensino e Pesquisa, São Paulo, SP, Brasil.
- Corsetti, G., Pericoli, M., & Sbracia, M. (2005). Some contagion, some interdependence: More pitfalls in tests of financial contagion. *Journal of International Money and Finance*, 24(8), 1177-1199.
- Costa, A. V., Souza, E. N., Duval, L. D., Pimenta, M. M., & Rosa, M. P. (2017). Um estudo sobre os impactos da Operação Carne Fraca nos retornos anormais e nas demonstrações financeiras da BRF S.A. e JBS S.A. *Anais do Congresso Brasileiro de Administração e Contabilidade – AdCont*, Rio de Janeiro, RJ, Brasil, 8.
- Crotty, M. J. (1998). *The foundations of social research: Meaning and perspective in the research*. London, UK: SAGE Publications.
- DIEESE (2017). Impactos da Operação Carne Fraca sobre o setor pecuário e os empregos. *Nota Técnica n. 176*. Recuperado de <https://www.dieese.org.br/notatecnica/2017/notaTec176CarneFrac.pdf>
- Dornbusch, R., Park, Y. C., & Claessens, S. M. (2000). Contagion: Understanding how it spreads. *The World Bank Research Observer*, 15(2), 177-97.

- Ferreira, D. M. (2012). *O efeito contágio da crise do subprime no mercado acionário brasileiro* (Dissertação de Mestrado). Universidade Federal de Viçosa, Viçosa, MG, Brasil.
- Forbes, K., & Rigobon, R. (2000). Contagion in Latin America: Definitions, measurement, and policy implications. *National Bureau of Economic Research – NBER Working Paper*, 7885.
- Freire, A. P. F. (2017). *Índices contábeis e variáveis macroeconômicas como instrumento de mensuração do efeito contágio e do risco sistêmico* (Tese de Doutorado). Universidade Federal da Paraíba, João Pessoa, PB, Brasil.
- Freire, A. P. F., Silva, A. M. C., Medeiros, O. R., & Cavalcante, P. R. N. (2017). Risco sistêmico: Uma análise de quebras estruturais nos índices setoriais brasileiros através do modelo CoVaR. *Revista de Globalização, Competitividade e Governabilidade*, 11(3), 74-89.
- Gelbcke, E. R., Santos, A., Iudícibus, S., & Martins E. (2018). *Manual de contabilidade societária* (3a ed.). São Paulo: Atlas.
- Giehl, A. L. (2017). Importância do setor de carnes em Santa Catarina e potenciais efeitos da “Operação Carne Fraca”. *Boletim agropecuário: Edição especial “Operação Carne Fraca”*. Recuperado de [http://docweb.epagri.sc.gov.br/website\\_cepa/Boletim\\_agropecuário/Boletim\\_agropecuário\\_Edicao\\_especial\\_CA\\_RNES.pdf](http://docweb.epagri.sc.gov.br/website_cepa/Boletim_agropecuário/Boletim_agropecuário_Edicao_especial_CA_RNES.pdf)
- Gonçalves, E., & Campos, J. P. (2017). *Carne Fraca: Entenda o que pesa contra cada frigorífico*. [Portal] Veja. Recuperado de <https://veja.abril.com.br/politica/carne-fraca-entenda-o-que-pesa-contra-cada-frigorifico/>
- Gurgel, A. C. (2017). Qual parte da carne é fraca? *Agroanalysis*, 37(4), 19-21.
- Hergesel, J. P., & Silva, M. C. C. (2017). Carne Fraca via SBT: Como a emissora narrou o início dessa Operação? *Revista de Estudos Universitários – REU*, 43(1), 151-167.
- Hummel, L. F., & Volcan, T. O. (2017). Uma análise da cobertura jornalística do portal G1 na operação “Carne Fraca”. *Anais do Congresso de Ciências da Comunicação na Região Sul*, Caxias do Sul, RS, Brasil, 18.
- Hyndman, R. J. (2020). A brief history of forecasting competitions. *International Journal of Forecasting*, 36(1), 7-14.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). Melbourne, Australia: OTexts.
- IBGE (2019a). *Censo agropecuário 2017: Resultados definitivos*. Recuperado de [https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro\\_2017\\_resultados\\_definitivos.pdf](https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_definitivos.pdf)
- IBGE (2019b). *IBGE divulga as estimativas da população dos municípios para 2019*. Estatísticas Sociais. Recuperado de <https://agenciadenoticias.ibge.gov.br/>

agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/25278-ibge-divulga-as-estimativas-da-populacao-dos-municipios-para-2019

IBGE (2020). *IBGE atualiza dados geográficos de estados e municípios brasileiros*. Geociências. Recuperado de <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/27737-ibge-atualiza-dados-geograficos-de-estados-e-municipios-brasileiros>

*Instrução CVM n. 480, de 7 de dezembro de 2009*. Dispõe sobre o registro de emissores de valores mobiliários admitidos à negociação em mercados regulamentados de valores mobiliários. Recuperado de <http://www.cvm.gov.br/legislacao/instrucoes/inst480.html>.

*IPL n. 0136/2015, de 15 de abril de 2017*. Operação Carne Fraca. Delegacia Regional de Combate ao Crime Organizado, Superintendência Regional no Paraná, Polícia Federal, Ministério da Justiça e da Segurança Pública. Recuperado de [https://politica.estadao.com.br/blogs/fausto-macedo/wp-content/uploads/sites/41/2017/04/246\\_REL\\_FINAL\\_IPL1.pdf](https://politica.estadao.com.br/blogs/fausto-macedo/wp-content/uploads/sites/41/2017/04/246_REL_FINAL_IPL1.pdf)

Ito, P. L. M., Altoé, S. M. L., & Suave, R. (2019). Influência do cenário econômico e Operação “Carne Fraca” nas demonstrações contábeis: Uma análise comparativa entre 2016 e 2017 em empresas do setor da carne. *Revista Conhecimento Contábil*, 9(2), 65-81.

Iudícibus, S. (2017). *Análise de balanços* (11a ed.). São Paulo, SP: Atlas.

Januschowski, T., Gasthaus, J., Wang, Y., Salinas, D., Flunkert, V., Bohlke-Schneider, M., & Callot, L. (2020). Criteria for classifying forecasting methods. *International Journal of Forecasting*, 36(1), 167-177.

*Lei n. 11.638, de 28 de dezembro de 2007*. Altera e revoga dispositivos da Lei n. 6.404, de 15 de dezembro de 1976, e da Lei n. 6.385, de 7 de dezembro de 1976, e estende às sociedades de grande porte disposições relativas à elaboração e divulgação de demonstrações financeiras. Recuperado de [http://www.planalto.gov.br/ccivil\\_03/\\_ato2007-2010/2007/lei/l11638.htm](http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2007/lei/l11638.htm)

*Lei n. 6.404, de 15 de dezembro de 1976*. Dispõe sobre as sociedades por ações. Recuperado de [http://www.planalto.gov.br/ccivil\\_03/leis/l6404consol.htm](http://www.planalto.gov.br/ccivil_03/leis/l6404consol.htm)

*Lei n. 11.941, de 27 de maio de 2009*. Altera a legislação tributária federal relativa ao parcelamento ordinário de débitos tributários; (. . .) e dá outras providências. Recuperado de [https://www.planalto.gov.br/ccivil\\_03/\\_ato2007-2010/2009/lei/l11941.htm](https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/lei/l11941.htm)

Lichtendahl Jr., K. C., & Winkler, R. L. (2020). Why do some combinations perform better than others? *International Journal of Forecasting*, 36(1), 142-149.

Link, C. P., & Ternus, C. (2018). Operação Carne Fraca: Análise do comportamento do consumidor. *Anais da Mostra Científica de Inovação e Empreendedorismo e Feira de Negócios Inovadores – INOVA*, Itapiranga, SC, Brasil, 3.

Maggi, B. (2017). O desafio da carne fraca e o mercado mundial. *Revista de Política Agrícola*, 26(1), 3-4.

- Magioli, C. A. (2017). Considerações sobre possíveis irregularidades em produtos de origem animal. *Revista VISA em debate*, 5(4), 2-8.
- Makridakis, S., & Petropoulos, F. (2020). The M4 competition: Conclusions. *International Journal of Forecasting*, 36(1), 224-227.
- Makridakis, S., Hyndman, R. J., & Petropoulos, F. (2020). Forecasting in social settings: The state of the art, *International Journal of Forecasting*, 36(1), 15-28.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020a). Predicting/hypothesizing the findings of the M4 Competition. *International Journal of Forecasting*, 36(1), 29-36.
- Makridakis, S., Spiliotis, E., Assimakopoulos, V. (2020b). The M4 Competition: 100,000 times series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54-74.
- MAPA (2017a). *Nota à imprensa – 18/03*. Brasília, DF. Recuperado de <http://antigo.agricultura.gov.br/noticias/nota-a-imprensa>
- MAPA (2017b). *Nota à imprensa*. Brasília, DF. Recuperado de <http://antigo.agricultura.gov.br/noticias/nota-a-imprensa-1>
- MAPA (2017c). *Maggi: Operação da PF é sobre fiscalização da parte burocrática dos produtos*. Brasília, DF. Recuperado de <http://antigo.agricultura.gov.br/noticias/maggi-operacao-da-pf-e-sobre-fiscalizacao-da-parte-burocratica-dos-produtos>
- MAPA (2017d). *MAPA apresenta ações contra fraudes em frigoríficos a embaixadas de 29 países e blocos*. Brasília, DF. Recuperado de <http://antigo.agricultura.gov.br/noticias/mapa-apresenta-a-representantes-de-embaixadas-de-29-paises-balanco-de-acoes-contra-fraudes-em-frigorificos/>
- MAPA (2017e). *Brasil já recuperou mercados de carne, garante Blairo Maggi*. Brasília, DF. Recuperado de <http://antigo.agricultura.gov.br/noticias/brasil-ja-recuperou-mercados-de-carne-garante-blairo-maggi>
- MAPA (2018). *Operação Carne Fraca: Relatório analítico de repercussão em mídia*. Recuperado de <http://antigo.agricultura.gov.br/publicacoes/operacao-carne-fraca.pdf/view>
- Marconi, M. A., & Lakatos, E. M. (2019). *Fundamentos de metodologia científica* (8a ed.). São Paulo, SP: Atlas.
- Marion, J. C. (2019). *Análise das demonstrações contábeis* (8a ed.). São Paulo, SP: Atlas.
- Martins, E., Miranda, G. J., & Diniz, J. A. (2018). *Análise avançada das demonstrações contábeis: Uma abordagem crítica* (2a ed.). São Paulo, SP: Atlas.
- Martins, E., Miranda, G. J., & Diniz, J. A. (2019). *Análise didática das demonstrações contábeis* (2a ed.). São Paulo, SP: Atlas.

- Matarazzo, D. C. (1998). *Análise financeira de balanços: Abordagem básica e gerencial* (5a ed.). São Paulo, SP: Atlas.
- Montero-Manso, P., Athanasopoulos, G., Hyndman, R. J., & Talagala, T. S. (2020). FFORMA: Feature-based forecast model averaging. *International Journal of Forecasting*, 36(1), 86-92.
- Niyama, J. K. (Org.). (2014). *Teoria avançada da contabilidade*. São Paulo: Atlas.
- Niyama, J. K., & Silva, C. A. T. (2013). *Teoria da Contabilidade* (3a ed.). São Paulo: Atlas.
- Padoveze, C. L., & Benedicto, G. C. (2010). *Análise das demonstrações financeiras* (3a ed.). São Paulo, SP: Cengage Learning.
- Pericoli, M., & Sbracia, M. (2003). A primer on financial contagion. *Journal of Economic Surveys*, 17(4), 571-608.
- Perobelli, F. F. C., Vidal, T. L., & Securato, J. R. (2013). Avaliando o efeito contágio entre economias durante crises financeiras. *Estudos Econômicos*, 43(3), 557-594.
- Petropoulos, F., & Makridakis, S. (2020). The M4 competition: Bigger, stronger, better. *International Journal of Forecasting*, 36(1), 3-6.
- Pinto, G. V. R. (2017). *Operação Carne Fraca: Uma análise da intervenção estatal no domínio econômico em sua modalidade fiscalizatória* (Trabalho de Conclusão de Curso). Universidade Federal do Rio Grande do Norte – UFRN, Natal, RN, Brasil.
- Polícia Federal (2017a). *PF desarticula esquema criminoso envolvendo agentes públicos e empresários*. Curitiba, PR. Recuperado de <http://www.pf.gov.br/agencia/noticias/2017/03/pf-desarticula-esquema-criminoso-envolvendo-agentes-publicos-e-empresarios>
- Polícia Federal (2017b). *PF deflagra 2ª fase da Operação Carne Fraca – Operação Antídoto*. Curitiba, PR. Recuperado de <http://www.pf.gov.br/agencia/noticias/2017/05/pf-deflagra-a-2a-fase-da-operacao-carne-fraca-2013-operacao-antidoto>
- Polícia Federal (2018). *PF deflagra 3ª fase da Operação Carne Fraca*. Curitiba, PR. Recuperado de <http://www.pf.gov.br/agencia/noticias/2018/03/pf-deflagra-3a-fase-da-operacao-carne-fraca>
- Polícia Federal (2019). *PF deflagra a 4ª fase da Operação Carne Fraca*. Curitiba, PR. Recuperado de <http://www.pf.gov.br/imprensa/noticias/2019/10/pf-deflagra-a-4a-fase-da-operacao-carne-fraca>
- Pronunciamento técnico CPC 00 (R2), 10 de dezembro de 2019*. Estrutura conceitual para relatório financeiro. Recuperado de [http://static.cpc.aatb.com.br/Documentos/573\\_CPC00\(R2\).pdf](http://static.cpc.aatb.com.br/Documentos/573_CPC00(R2).pdf)
- Pronunciamento técnico CPC 16 (R1), 08 de setembro de 2009*. Estoques. Recuperado de [http://static.cpc.aatb.com.br/Documentos/243\\_CPC\\_16\\_R1\\_rev%2013.pdf](http://static.cpc.aatb.com.br/Documentos/243_CPC_16_R1_rev%2013.pdf)

- Pronunciamento técnico CPC 26 (R1), 15 de dezembro de 2011. Apresentação das demonstrações contábeis. Recuperado de [http://static.cpc.aatb.com.br/Documentos/312\\_CPC\\_26\\_R1\\_rev%2014.pdf](http://static.cpc.aatb.com.br/Documentos/312_CPC_26_R1_rev%2014.pdf)*
- Pronunciamento técnico CPC 29, 16 de setembro de 2009. Ativo Biológico e Produto Agrícola. Recuperado de [http://static.cpc.aatb.com.br/Documentos/324\\_CPC\\_29\\_rev%2014.pdf](http://static.cpc.aatb.com.br/Documentos/324_CPC_29_rev%2014.pdf)*
- Pronunciamento técnico CPC 36 (R3), 20 de dezembro de 2012. Demonstrações consolidadas. Recuperado de [http://static.cpc.aatb.com.br/Documentos/448\\_CPC\\_36\\_R3\\_rev%2008.pdf](http://static.cpc.aatb.com.br/Documentos/448_CPC_36_R3_rev%2008.pdf)*
- Pronunciamento técnico CPC 37 (R1), 02 de dezembro de 2010. Adoção inicial das normas internacionais de contabilidade. Recuperado de [http://static.cpc.aatb.com.br/Documentos/402\\_CPC\\_37\\_R1\\_rev%2014.pdf](http://static.cpc.aatb.com.br/Documentos/402_CPC_37_R1_rev%2014.pdf)*
- Queiroz, B. S., & Leite, R. S. (2019). A carne é fraca! As experiências de vulnerabilidade vivenciadas pelos consumidores de carnes processadas. *Anais do Encontro Nacional da Associação Nacional de Pós-Graduação e Pesquisa em Administração – EnANPAD*, São Paulo, SP, Brasil, 43.
- Richarde, A. P. M., Silva, G. C., & Kaetsu, S. T. (2019). Carne fraca e marca forte: Um estudo sobre o impacto do marketing boca a boca no consumo de marcas de carnes e embutidos. *Revista Gestão & Conexões*, 8(1), 119-135.
- Richardson, R. J. (2017). *Pesquisa social: Métodos e técnicas* (4a ed.). São Paulo, SP: Atlas.
- Rigobon, R. (2002). *International financial contagion: Theory and evidence in evolution*. The Research Foundation of AIMR.
- Rocha, A. P., Borrero, M. A. V., & Saith, W. (2020). Análise das exportações de carne bovina dos estados de Rondônia e Paraná: O impacto da Operação Carne Fraca. *Revista Ciências da Sociedade – RCS*, 4(7), 48-68.
- Rocha, R. S. P., Coutinho, J. P., Coutinho, E. P., & Paraguassú, L. G. (2017). Impactos de recentes descobertas sobre fraudes na indústria de carnes nos hábitos de compra e consumo nas regiões do Vale do Mucuri, Jequitinhonha, norte e nordeste de Minas Gerais. *Anais do Seminário de Iniciação Científica do IFNMG – SIC*, Almenara, MG, Brasil, 6.
- Rodrigues, I. B. F. (2017). *Evidenciação contábil dos ativos biológicos no contexto da NBC TG 29* (Trabalho de Conclusão de Curso). Universidade do Extremo Sul Catarinense – UNESC, Criciúma, SC, Brasil.
- Ross, S. A., Westerfield, R. W., Jaffe, J., & Lamb, R. (2015). *Administração financeira* (10a ed.). Porto Alegre, RS: AMGH.
- Salomão, K. (2018). *Entenda o que é a Operação Carne Fraca e os impactos para a BRF*. [Portal] Exame. Recuperado de <https://exame.com/negocios/entenda-o-que-e-a-operacao-carne-fraca-e-os-impactos-para-a-brf/>

- Santos, M. M., & Silva, D. M. (2018). Análise dos inputs utilizados na mensuração do valor justo dos ativos biológicos das empresas listadas na B3. *Anais do Congresso Brasileiro de Custos*, Vitória, ES, Brasil, 25.
- Silva, A. A. (2019). *Estrutura, análise e interpretação das demonstrações contábeis* (5a ed.). São Paulo, SP: Atlas.
- Silva, A. F., Penedo, A. S. T., & Pereira, V. S. (2019). “A carne é fraca?” Reação do mercado acionário frente a escândalos corporativos. *Desenvolve: Revista de Gestão do Unilasalle*, 8(3), 9-28.
- Silva, D. R. (2016). Os efeitos da operação carne fraca na imagem do Brasil. *Revista Estratégia Organizacional*, 5(1-2), 49-58.
- Silva, F. H., & Melo, B. O. R. (2019). As construções argumentativas em notas de esclarecimento referente à Operação Carne Fraca. *Letras em Revista*, 10(1), 217-229.
- Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75-85.
- Soares, C. M. M. (2018). *Relação dos consumidores e das organizações nas mídias sociais em momentos de crise de imagem: Um estudo sobre a Carne Fraca* (Dissertação de Mestrado). Escola Superior de Propaganda e Marketing – ESPM, São Paulo, SP, Brasil.
- Talagala, T. S., Hyndman, R. J., & Athanasopoulos, G. (2018). Meta-learning how to forecast time series. *Working Paper 6/18*. Department of Econometrics & Business Statistics, Monash University.
- Taleb, N. N. (2020). Foreword to the M4 Competition. *International Journal of Forecasting*, 36(1), 1-2.
- Vartanian, P. R. (2012). Impactos do índice dow jones, commodities e câmbio sobre o ibovespa: Uma análise do efeito contágio. *Revista de Administração Contemporânea – RAC*, 16(4), 608-627.
- Vidal, T. L., & Securato, J. R. (2011). *Crises financeiras: Efeito contágio ou interdependência entre os países? Evidências utilizando uma abordagem multivariada* (Dissertação de Mestrado). Universidade de São Paulo, São Paulo, SP, Brasil.
- Vieira, E. S. S. (2017). Defesa agropecuária e inspeção de produtos de origem animal: Uma breve reflexão sobre a Operação Carne Fraca e possíveis contribuições ao aprimoramento dos instrumentos normativos aplicáveis ao setor. *Textos para Discussão*, Núcleo de Estudos e Pesquisas da Consultoria Legislativa, Brasília, DF, Brasil, 230.



## APÊNDICE A – Rotinas utilizadas para o modelo FFORMA

# Pesquisa.R

Marcus

2021-07-28

```
#seed
set.seed(28-07-2021)
```

```
#carregando os pacotes a serem usados
library(M4metalearning)
library(dygraphs)
library(tsfeatures)
```

```
## Registered S3 method overwritten by 'quantmod':
##   method      from
##   as.zoo.data.frame zoo
```

```
#separando os dados da Liquidez Seca
```

```
LS = list()
LS$BRFS3[["x"]] = ts(c(1.24592, 1.17258, 1.00998, 0.91245, 0.83577, 0.94507, 0.87813, 0.96466, 0.93624, 1.00582, 0.96223, 1.05797, 1.13022, 1.14733, 1.22888, 1.40204, 1.39815, 1.27540, 1.31403, 1.18898, 1.10318, 0.89616, 0.89320, 0.98550, 1.01169, 1.13077, 1.05065, 0.85370, 0.71516, 0.71893, 0.73899, 0.94146, 0.82394), freq = 4, start = 2011)
LS$JBSS3[["x"]] = ts(c(1.12383, 1.24677, 1.21111, 1.17212, 1.20080, 1.25329, 1.16992, 1.14484, 1.20442, 1.11923, 0.94360, 1.15406, 1.08197, 1.16007, 1.16988, 1.11393, 1.11065, 1.02836, 1.15687, 0.89260, 0.75965, 0.70149, 0.65635, 0.64885, 0.68261, 0.78670, 0.84375, 0.81062, 0.79147, 1.20199, 1.15243, 1.03681, 0.90704), freq = 4, start = 2011)
LS$BAUH3[["x"]] = ts(c(1.24880, 1.14544, 1.27467, 0.64792, 0.68671, 0.70387, 0.73778, 0.67858, 0.79043, 0.82863, 0.90151, 1.06298, 1.19326, 1.28309, 1.36546, 1.36487, 1.40750, 1.43385, 1.47620, 0.96740, 0.96904, 1.00988, 1.11983, 1.04276, 1.06915, 1.18047, 1.21269, 1.18540, 1.23539, 1.26788, 1.40418, 1.26765, 1.31360), freq = 4, start = 2011)
LS$BEEF3[["x"]] = ts(c(1.74173, 1.58298, 1.55295, 1.51624, 2.28141, 2.19394, 1.71654, 1.90719, 1.88737, 1.82655, 1.80627, 1.84491, 1.79373, 1.78356, 2.22357, 1.85618, 1.75444, 1.83590, 1.82314, 1.43804, 1.50470, 1.42970, 1.87736, 1.80116, 1.78015, 1.75224, 1.33530, 1.62512, 1.43370, 1.47134, 1.32289, 1.21784, 1.29179), freq = 4, start = 2011)
LS$MRFG3[["x"]] = ts(c(0.90305, 1.09821, 0.99676, 0.91728, 0.87890, 0.84504, 0.82623, 0.85688, 0.91156, 1.43544, 1.42439, 1.44096, 1.48040, 1.57739, 1.60334, 1.28438, 1.13804, 1.35257, 1.97427, 1.51394, 1.07149, 1.05078, 1.07964, 1.07451, 1.68692, 1.40421, 1.27811, 1.30525, 1.67178, 0.98012, 0.95849, 1.14777, 1.05325), freq = 4, start = 2011)
LS$MNPR3[["x"]] = ts(c(0.34098, 0.30943, 0.65115, 0.40945, 0.57004, 0.64078, 0.62809, 0.18751, 0.18340, 0.17751, 0.16902, 0.15101, 0.09263, 0.09077, 0.10583, 0.08262, 0.09511, 0.10165, 0.09259, 0.08447, 0.08381, 0.06981, 0.07153, 0.05790, 0.06862, 0.71788, 0.10246, 0.06439, 0.07658, 0.08932, 0.09657, 0.07032, 0.09180), freq = 4, start = 2011)
#definindo o número de previsões
LS$BRFS3[["h"]] = as.integer(8)
LS$JBSS3[["h"]] = as.integer(8)
LS$BAUH3[["h"]] = as.integer(8)
LS$BEEF3[["h"]] = as.integer(8)
LS$MRFG3[["h"]] = as.integer(8)
LS$MNPR3[["h"]] = as.integer(8)
```

```
#separando os dados da Liquidez Corrente
```

```
LC = LS
LC$BRFS3[["x"]] = ts(c(1.86958, 1.71923, 1.57892, 1.39259, 1.40701, 1.51029, 1.52571, 1.55274, 1.59004, 1.59511, 1.60558, 1.56976, 1.67567, 1.64681, 1.78294, 1.82757, 1.87757, 1.76518, 1.82869, 1.65045, 1.62808, 1.38494, 1.40548, 1.49471, 1.53547, 1.62284, 1.51671, 1.28694, 1.08202, 1.08329, 1.19718, 1.31350, 1.20925), freq = 4, start = 2011)
LC$JBSS3[["x"]] = ts(c(1.72288, 1.84337, 1.79883, 1.72487, 1.79333, 1.90987, 1.77405, 1.68002, 1.77473, 1.63031, 1.41495, 1.63271, 1.58863, 1.65520, 1.65167, 1.50966, 1.57736, 1.45493, 1.58223, 1.24099, 1.12097, 1.10452, 1.07106, 1.01713, 1.09655, 1.17887, 1.22655, 1.23737, 1.26293, 1.92428, 1.87555, 1.70818, 1.65128), freq = 4, start = 2011)
LC$BAUH3[["x"]] = ts(c(1.53900, 1.42661, 1.52236, 0.79340, 0.82405, 0.83412, 0.85544, 0.87095, 1.01686, 1.07017, 1.08736, 1.26467, 1.43237, 1.57667, 1.67980, 1.67257, 1.71636, 1.83062, 1.79522, 1.25826, 1.26456, 1.32428, 1.42396, 1.31997, 1.34027, 1.44448, 1.50914, 1.39400, 1.53060, 1.57341, 1.68915, 1.53840, 1.60563), freq = 4, start = 2011)
LC$BEEF3[["x"]] = ts(c(2.10126, 1.90405, 1.83819, 1.73655, 2.63470, 2.49716, 1.94566, 2.14631, 2.20061, 2.10611, 2.09476, 2.12245, 2.09613, 2.09160, 2.65672, 2.18516, 2.03811, 2.14723, 2.04923, 1.64771, 1.69720, 1.67105, 2.16503, 2.01324, 2.05638, 1.95453, 1.54574, 1.86253, 1.66947, 1.69512, 1.53151, 1.35963, 1.48031), freq = 4, start = 2011)
LC$MRFG3[["x"]] = ts(c(1.38052, 1.61236, 1.52750, 1.40251, 1.34543, 1.32413, 1.31527, 1.33137, 1.39251, 1.68101, 2.01563, 2.03161, 2.07864, 2.18446, 2.18405, 1.79487, 1.59335, 1.57111, 2.27245, 1.82044, 1.26279, 1.23539, 1.26449, 1.26009, 1.96665, 1.65721, 1.58658, 1.61740, 1.79824, 1.12273, 1.09465, 1.36045, 1.30309), freq = 4, start = 2011)
LC$MNPR3[["x"]] = ts(c(0.47710, 0.42228, 0.74646, 0.59899, 0.83543, 0.88374, 0.82449, 0.23707, 0.22960, 0.22194, 0.21027, 0.18310, 0.10991, 0.10308, 0.12103, 0.09583, 0.11025, 0.11847, 0.10875, 0.10063, 0.10294, 0.08578, 0.08712, 0.07375, 0.08382, 0.89188, 0.12628, 0.07998, 0.09302, 0.10523, 0.11682, 0.08503, 0.10666), freq = 4, start = 2011)
```

```

#separando os dados da Proporção do Endividamento
PE = LS
PESBRFS3[["x"]] = ts(c(0.49727, 0.50791, 0.51922, 0.52941, 0.51496, 0.55121, 0.55054, 0.52633, 0.50580, 0.53838, 0.53455, 0.54606, 0.52587, 0.54545, 0.54508, 0.56542, 0.59352, 0.59105, 0.64408, 0.65743, 0.66621, 0.69050, 0.70564, 0.71546, 0.72509, 0.75579, 0.74026, 0.74103, 0.74194, 0.78878, 0.79244, 0.82229, 0.82981), freq = 4, start = 2011)
PESJBSS3[["x"]] = ts(c(0.56738, 0.51640, 0.53988, 0.54443, 0.54172, 0.57182, 0.56275, 0.56923, 0.57228, 0.60760, 0.65301, 0.66313, 0.66456, 0.67315, 0.67825, 0.68568, 0.70214, 0.70336, 0.73103, 0.75820, 0.77813, 0.76236, 0.74860, 0.75768, 0.76978, 0.76991, 0.76526, 0.75951, 0.74955, 0.75733, 0.75616, 0.75517, 0.75001), freq = 4, start = 2011)
PESBAUH3[["x"]] = ts(c(0.92678, 0.91153, 0.89839, 0.89176, 0.86860, 0.86099, 0.84274, 0.79228, 0.73556, 0.68515, 0.66624, 0.60850, 0.56126, 0.52337, 0.49898, 0.50847, 0.50210, 0.47797, 0.45483, 0.48223, 0.48635, 0.48003, 0.45807, 0.50978, 0.50606, 0.47792, 0.46095, 0.48851, 0.45366, 0.44283, 0.42649, 0.45155, 0.37909), freq = 4, start = 2011)
PESBEEF3[["x"]] = ts(c(0.81084, 0.82455, 0.78207, 0.82491, 0.85136, 0.88674, 0.88618, 0.82727, 0.81979, 0.89114, 0.88532, 0.91088, 0.88978, 0.90375, 0.93726, 0.93348, 1.00000, 0.97049, 1.00000, 1.00000, 0.94702, 0.92635, 0.92896, 0.94173, 0.94739, 0.96386, 0.96416, 0.99403), freq = 4, start = 2011)
PESMRFG3[["x"]] = ts(c(0.71246, 0.72780, 0.74967, 0.85648, 0.85654, 0.85253, 0.85481, 0.83176, 0.82962, 0.84153, 0.81987, 0.82504, 0.83356, 0.83599, 0.87339, 0.89737, 0.96305, 0.96115, 0.95691, 0.95967, 0.94979, 0.91590, 0.92768, 0.94566, 0.85240, 0.86982, 0.85874, 0.87632, 0.89621, 0.92496, 0.93273, 0.84864, 0.85187), freq = 4, start = 2011)
PESMNP3 = NULL
PESBEEF3[["h"]] = as.integer(3)

#separando os dados da Composição do Endividamento
CE = LS
CESBRFS3[["x"]] = ts(c(0.39433, 0.43559, 0.45899, 0.50322, 0.48639, 0.44479, 0.42807, 0.46086, 0.44887, 0.44136, 0.45036, 0.47719, 0.46433, 0.47921, 0.44981, 0.46876, 0.43441, 0.45499, 0.41282, 0.43767, 0.41452, 0.45429, 0.44598, 0.41140, 0.39219, 0.37053, 0.39810, 0.44480, 0.52577, 0.49649, 0.43219, 0.41574, 0.40807), freq = 4, start = 2011)
CESJBSS3[["x"]] = ts(c(0.34846, 0.38486, 0.39453, 0.40275, 0.38933, 0.36397, 0.39003, 0.40736, 0.38656, 0.41498, 0.44792, 0.38889, 0.39321, 0.38715, 0.40637, 0.44059, 0.39230, 0.42147, 0.39336, 0.43214, 0.43644, 0.41553, 0.41187, 0.42809, 0.39336, 0.38707, 0.37631, 0.35345, 0.34659, 0.23337, 0.23639, 0.25060, 0.24554), freq = 4, start = 2011)
CESBAUH3[["x"]] = ts(c(0.33365, 0.41996, 0.38524, 0.76408, 0.77208, 0.79286, 0.80083, 0.80738, 0.82545, 0.80923, 0.81855, 0.81202, 0.80407, 0.80251, 0.80345, 0.78011, 0.79022, 0.77491, 0.78943, 0.82586, 0.83694, 0.84309, 0.83121, 0.88390, 0.89171, 0.88603, 0.87228, 0.89372, 0.87674, 0.87333, 0.87419, 0.88585, 0.88315), freq = 4, start = 2011)
CESBEEF3[["x"]] = ts(c(0.27282, 0.31697, 0.35226, 0.33982, 0.21881, 0.21918, 0.29467, 0.30015, 0.27147, 0.28398, 0.29286, 0.29489, 0.29272, 0.31417, 0.24736, 0.28893, 0.30106, 0.28814, 0.29714, 0.35002, 0.38869, 0.39465, 0.31558, 0.33318, 0.31189, 0.35522, 0.38917, 0.33354, 0.36469, 0.33422, 0.37749, 0.45626, 0.39923), freq = 4, start = 2011)
CESMRFG3[["x"]] = ts(c(0.41801, 0.36640, 0.35444, 0.32704, 0.34070, 0.33145, 0.34490, 0.36117, 0.34963, 0.44285, 0.27360, 0.25078, 0.24814, 0.24072, 0.24349, 0.25739, 0.26881, 0.34290, 0.24975, 0.26936, 0.38517, 0.39089, 0.41034, 0.38537, 0.27375, 0.31754, 0.31806, 0.32256, 0.39992, 0.53652, 0.54599, 0.38441, 0.38972), freq = 4, start = 2011)
CESMNP3[["x"]] = ts(c(0.36505, 0.45557, 0.41402, 0.42108, 0.39268, 0.42768, 0.44740, 0.78030, 0.77769, 0.77292, 0.76974, 0.76778, 0.80762, 0.81096, 0.75671, 0.73287, 0.73645, 0.75645, 0.75570, 0.75241, 0.76374, 0.77452, 0.78348, 0.78195, 0.78755, 0.07736, 0.65778, 0.75689, 0.76138, 0.73894, 0.73810, 0.77086, 0.78329), freq = 4, start = 2011)

#separando os dados do Retorno do Investimento
RI = PE
RISBRFS3[["x"]] = ts(c(0.02460, 0.02994, 0.02898, 0.01891, 0.01737, 0.01933, 0.01000, 0.03229, 0.02288, 0.02715, 0.02375, 0.02479, 0.02642, 0.02736, 0.04467, 0.04866, 0.06329, 0.02124, 0.07716, 0.05993, 0.03515, 0.02931, 0.01172, 0.00884, 0.01051, 0.00971, 0.02198, -0.00454, 0.01487, -0.01166, -0.00282, 0.01979, 0.01288), freq = 4, start = 2011)
RISJBSS3[["x"]] = ts(c(0.01472, 0.01276, 0.00323, 0.00429, 0.01288, 0.01796, 0.01972, 0.01408, 0.01643, 0.03495, 0.03487, 0.02699, 0.02600, 0.02677, 0.04645, 0.01354, 0.08333, 0.01670, 0.13102, -0.05231, 0.02018, 0.03367, 0.02347, 0.01719, 0.01258, 0.02507, 0.02102, 0.01246, 0.01624, 0.02746, 0.01478, 0.01671, 0.02463), freq = 4, start = 2011)
RISBAUH3[["x"]] = ts(c(0.05408, 0.09108, 0.05842, 0.06276, 0.07973, 0.04857, 0.06754, 0.12635, 0.21423, 0.09328, 0.08329, 0.15997, 0.16135, 0.11888, 0.09080, 0.09350, 0.07067, 0.04071, 0.05841, 0.04937, 0.05815, 0.05707, 0.06218, 0.07328, 0.05268, 0.10765, 0.04031, 0.05167, 0.05756, 0.03904, 0.08522, 0.04258, 0.28520), freq = 4, start = 2011)
RISBEEF3[["x"]] = ts(c(0.03382, 0.02386, 0.04247, 0.03712, 0.01242, 0.02201, 0.03174, 0.01774, 0.02137, 0.00681, 0.02986, 0.01022, 0.03775, 0.03093, 0.00941, 0.00324, 0.00324, 0.04319, 0.04319, 0.05016, 0.05016, 0.05322, 0.03137, 0.02755, 0.02777, 0.02323, 0.03251, -0.00087), freq = 4, start = 2011)
RISMRFG3[["x"]] = ts(c(0.01978, 0.01173, 0.03421, 0.01867, 0.02572, 0.03114, 0.02248, 0.01302, 0.02190, 0.01608, 0.02861, 0.02862, 0.02985, 0.02091, 0.03104, 0.02656, 0.02933, 0.05278, 0.05752, 0.04413, 0.05201, 0.05245, 0.02771, 0.03652, 0.03630, 0.03044, 0.02637, 0.03199, 0.01788, 0.01269, 0.05136, -0.01356, 0.03510), freq = 4, start = 2011)

#separando os dados do Retorno do Patrimônio Líquido
RP = PE
RPSBRFS3[["x"]] = ts(c(0.02763, 0.03512, 0.02496, 0.00862, 0.01067, 0.00079, 0.00623, 0.03908, 0.02385, 0.01403, 0.01987, 0.01394, 0.02117, 0.01751, 0.04044, 0.06504, 0.02977, 0.02412, 0.05947, 0.10076, 0.00295, 0.00127, 0.00127, -0.03537, -0.02356, -0.01404, 0.01130, -0.06430, -0.00972, -0.14678, -0.00585, -0.25290, -0.13548), freq = 4, start = 2011)
RPSJBSS3[["x"]] = ts(c(0.00492, -0.01029, -0.00839, -0.00106, 0.00595, 0.00859, 0.01803, 0.00287, 0.01112, 0.01832, 0.01131, 0.00900, 0.00515, 0.01509, 0.05053, 0.02749, 0.05618, 0.00906, 0.11695, -0.00661, -0.09563, 0.06609, 0.03848, 0.02936, 0.01697, 0.01935, 0.01879, -0.01322, 0.02206, -0.02954, -0.00353, 0.01930, 0.04042), freq = 4, start = 2011)
RPSBAUH3[["x"]] = ts(c(0.13986, 0.30500, 0.13324, 0.15146, 0.20708, 0.09083, 0.14587, 0.24082, 0.35175, 0.12888, 0.10829, 0.18197, 0.15527, 0.11424, 0.08676, 0.08974, 0.06800, 0.03836, 0.05656, 0.04061, 0.05417, 0.05416, 0.05915, 0.07194, 0.04938, 0.10645, 0.03781, 0.04949, 0.05552, 0.03704, 0.08342, 0.04097, 0.28394), freq = 4, start = 2011)
RPSBEEF3[["x"]] = ts(c(0.02667, -0.00628, 0.02392, 0.02201, -0.11548, -0.27345, 0.04767, -0.03619, 0.00699, -0.32027, 0.00277, -0.25120, 0.13947, 0.03368, -0.40781, -0.71072, 1.67926, 1.67926, 1.29028, 1.29028, 0.16387, 0.07563, 0.02117, 0.00507, -0.13757, 0.22545, -1.32930), freq = 4, start = 2011)
RPSMRFG3[["x"]] = ts(c(0.00478, -0.01362, -0.00741, -0.02961, 0.00854, 0.00262, 0.00286, -0.07123, -0.01846, -0.09643, -0.08827, -0.02472, -0.02956, -0.01656, -0.10670, -0.11954, -0.37912, 0.00370, 0.20347, -0.18488, -0.09786, -0.08682, -0.09708, -0.19802, -0.10770, -0.05416, -0.01884, -0.00618, -0.07900, -0.15527, 0.13299, 0.77303, 0.03463), freq = 4, start = 2011)

```

```

#separando os dados a serem previstos
LS = temp_holdout(LS)
LC = temp_holdout(LC)
PE = temp_holdout(PE)
CE = temp_holdout(CE)
RI = temp_holdout(RI)
RP = temp_holdout(RP)

#separando apenas os dados pré operação
treino = LS
treino$BRFS3[["h"]] = as.integer(4)
treino$JBSS3[["h"]] = as.integer(4)
treino$BAUH3[["h"]] = as.integer(4)
treino$BEEF3[["h"]] = as.integer(4)
treino$MRFG3[["h"]] = as.integer(4)
treino$MNPR3[["h"]] = as.integer(4)
#retirando as últimas 4 observações de cada série pré operação
treino = temp_holdout(treino)
#aplicando cada método de previsão em cada série pré operação
treino = calc_forecasts(treino, forec_methods(), n.cores = 6)
#calculando os erros de cada método de previsão de cada série pré operação
treino = calc_errors(treino)
#extraíndo as características de cada série pré operação
treino = THA_features(treino)
#organizando as características extraídas e os erros calculados
treino_feat = create_feat_classif_problem(treino)
#ajustando o modelo de acordo com as características e erros
modelo = train_selection_ensemble(treino_feat$data, treino_feat$errors)
#ajustando o modelo nos dados pré operação
preds_treino = predict_selection_ensemble(modelo, treino_feat$data)

```

```

## Warning in if (class(newdata) != "xgb.DMatrix") newdata <-
## xgb.DMatrix(newdata, : a condição tem comprimento > 1 e somente o primeiro
## elemento será usado


```

```


#fazendo a previsão dos dados pré operação
treino = ensemble_forecast(preds_treino, treino)
#separando as previsões dos dados pré operação
BRFS3_p = ts(treino$BRFS3$y_hat, freq = 4, start = 2016.25)
JBSS3_p = ts(treino$JBSS3$y_hat, freq = 4, start = 2016.25)
BAUH3_p = ts(treino$BAUH3$y_hat, freq = 4, start = 2016.25)
BEEF3_p = ts(treino$BEEF3$y_hat, freq = 4, start = 2016.25)
MRFG3_p = ts(treino$MRFG3$y_hat, freq = 4, start = 2016.25)
MNPR3_p = ts(treino$MNPR3$y_hat, freq = 4, start = 2016.25)
#separando os dados reais observados pré operação
BRFS3_r = ts(treino$BRFS3$xx, freq = 4, start = 2016.25)
JBSS3_r = ts(treino$JBSS3$xx, freq = 4, start = 2016.25)
BAUH3_r = ts(treino$BAUH3$xx, freq = 4, start = 2016.25)
BEEF3_r = ts(treino$BEEF3$xx, freq = 4, start = 2016.25)
MRFG3_r = ts(treino$MRFG3$xx, freq = 4, start = 2016.25)
MNPR3_r = ts(treino$MNPR3$xx, freq = 4, start = 2016.25)
#separando os dados históricos pré previsão e pré operação
BRFS3_h = ts(treino$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(treino$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(treino$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(treino$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(treino$MRFG3$x, freq = 4, start = 2011)
MNPR3_h = ts(treino$MNPR3$x, freq = 4, start = 2011)

```


```
#plotando as comparações entre estimado e observado pré operação
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "LS - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Histórico") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelloc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "LS - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Histórico") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelloc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "LS - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Histórico") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "LS - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Histórico") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```






```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "LS - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Histórico") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MNPR3_p, MNPR3_h, MNPR3_r), main = "LS - MINUPAR", ylab = "índice") %>% dySeries(c("MNPR3_h"), label = "Histórico") %>% dySeries(c("MNPR3_r"), label = "Observado") %>% dySeries(c("MNPR3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
#separando o ajuste do modelo pro indicador corrente
modelo_LS = modelo
#salvando a performance do modelo no treino
treino_LS = summary_performance(preds_treino, treino, print.summary = FALSE)
BRFS3_LS_1 = summary_performance(preds_treino, treino[1], print.summary = FALSE)
JBSS3_LS_1 = summary_performance(preds_treino, treino[2], print.summary = FALSE)
BAUH3_LS_1 = summary_performance(preds_treino, treino[3], print.summary = FALSE)
BEEF3_LS_1 = summary_performance(preds_treino, treino[4], print.summary = FALSE)
MRFG3_LS_1 = summary_performance(preds_treino, treino[5], print.summary = FALSE)
MNPR3_LS_1 = summary_performance(preds_treino, treino[6], print.summary = FALSE)
```


```

###repetindo o processo pro novo indicador


#separando apenas os dados pr  opera  o
treino = LC
treino$BRFS3[["h"]] = as.integer(4)
treino$JBSS3[["h"]] = as.integer(4)
treino$BAUH3[["h"]] = as.integer(4)
treino$BEEF3[["h"]] = as.integer(4)
treino$MRFG3[["h"]] = as.integer(4)
treino$MNPR3[["h"]] = as.integer(4)
#retirando as  ltimas 4 observa  es de cada s rie pr  opera  o
treino = temp_holdout(treino)
#aplicando cada m todo de previs  o em cada s rie pr  opera  o
treino = calc_forecasts(treino, forec_methods(), n.cores = 6)
#calculando os erros de cada m todo de previs  o de cada s rie pr  opera  o
treino = calc_errors(treino)
#extra ndo as caracter sticas de cada s rie pr  opera  o
treino = THA_features(treino)
#organizando as caracter sticas extra das e os erros calculados
treino_feat = create_feat_classif_problem(treino)
#ajustando o modelo de acordo com as caracter sticas e erros
modelo = train_selection_ensemble(treino_feat$data, treino_feat$errors)
#ajustando o modelo nos dados pr  opera  o
preds_treino = predict_selection_ensemble(modelo, treino_feat$data)

#fazendo a previs  o dos dados pr  opera  o
treino = ensemble_forecast(preds_treino, treino)
#separando as previs  es dos dados pr  opera  o
BRFS3_p = ts(treino$BRFS3$y_hat, freq = 4, start = 2016.25)
JBSS3_p = ts(treino$JBSS3$y_hat, freq = 4, start = 2016.25)
BAUH3_p = ts(treino$BAUH3$y_hat, freq = 4, start = 2016.25)
BEEF3_p = ts(treino$BEEF3$y_hat, freq = 4, start = 2016.25)
MRFG3_p = ts(treino$MRFG3$y_hat, freq = 4, start = 2016.25)
MNPR3_p = ts(treino$MNPR3$y_hat, freq = 4, start = 2016.25)
#separando os dados reais observados pr  opera  o
BRFS3_r = ts(treino$BRFS3$xx, freq = 4, start = 2016.25)
JBSS3_r = ts(treino$JBSS3$xx, freq = 4, start = 2016.25)
BAUH3_r = ts(treino$BAUH3$xx, freq = 4, start = 2016.25)
BEEF3_r = ts(treino$BEEF3$xx, freq = 4, start = 2016.25)
MRFG3_r = ts(treino$MRFG3$xx, freq = 4, start = 2016.25)
MNPR3_r = ts(treino$MNPR3$xx, freq = 4, start = 2016.25)
#separando os dados hist ricos pr  previs  o e pr  opera  o
BRFS3_h = ts(treino$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(treino$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(treino$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(treino$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(treino$MRFG3$x, freq = 4, start = 2011)
MNPR3_h = ts(treino$MNPR3$x, freq = 4, start = 2011)
#plotando as compara  es entre estimado e observado pr  opera  o
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "LC - BRF", ylab = " ndice") %>% dySeries(c("BRFS3_h"), label = "Hist rico") %>% dySeries(c("BRFS3_p"), label = "Previs  o") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Opera   o Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)


```



```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "LC - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Histórico") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "LC - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Histórico") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```







```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "LC - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Histórico") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "LC - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Histórico") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MNPR3_p, MNPR3_h, MNPR3_r), main = "LC - MINUPAR", ylab = "índice") %>% dySeries(c("MNPR3_h"), label = "Histórico") %>% dySeries(c("MNPR3_r"), label = "Observado") %>% dySeries(c("MNPR3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
#separando o ajuste do modelo pro indicador corrente
modelo_LC = modelo


#salvando a performance do modelo no treino
treino_LC = summary_performance(preds_treino, treino, print.summary = FALSE)
BRFS3_LC_1 = summary_performance(preds_treino, treino[1], print.summary = FALSE)
JBSS3_LC_1 = summary_performance(preds_treino, treino[2], print.summary = FALSE)
BAUH3_LC_1 = summary_performance(preds_treino, treino[3], print.summary = FALSE)
BEEF3_LC_1 = summary_performance(preds_treino, treino[4], print.summary = FALSE)
MRFG3_LC_1 = summary_performance(preds_treino, treino[5], print.summary = FALSE)
MNPR3_LC_1 = summary_performance(preds_treino, treino[6], print.summary = FALSE)
```

```
###repetindo o processo pro novo indicador
```


```
#separando apenas os dados pré operação
treino = PE
treino$BRFS3[["h"]] = as.integer(4)
treino$JBSS3[["h"]] = as.integer(4)
treino$BAUH3[["h"]] = as.integer(4)
treino$BEEF3[["h"]] = as.integer(4)
treino$MRFG3[["h"]] = as.integer(4)
#retirando as últimas 4 observações de cada série pré operação
treino = temp_holdout(treino)
#aplicando cada método de previsão em cada série pré operação
treino = calc_forecasts(treino, forec_methods(), n.cores = 6)
#calculando os erros de cada método de previsão de cada série pré operação
treino = calc_errors(treino)
#extraíndo as características de cada série pré operação
treino = THA_features(treino)
#organizando as características extraídas e os erros calculados
treino_feat = create_feat_classif_problem(treino)
#ajustando o modelo de acordo com as características e erros
modelo = train_selection_ensemble(treino_feat$data, treino_feat$errors)
#ajustando o modelo nos dados pré operação
preds_treino = predict_selection_ensemble(modelo, treino_feat$data)
```

```
#fazendo a previsão dos dados pré operação
treino = ensemble_forecast(preds_treino, treino)
#separando as previsões dos dados pré operação
BRFS3_p = ts(treino$BRFS3$y_hat, freq = 4, start = 2016.25)
JBSS3_p = ts(treino$JBSS3$y_hat, freq = 4, start = 2016.25)
BAUH3_p = ts(treino$BAUH3$y_hat, freq = 4, start = 2016.25)
BEEF3_p = ts(treino$BEEF3$y_hat, freq = 4, start = 2016.25)
MRFG3_p = ts(treino$MRFG3$y_hat, freq = 4, start = 2016.25)
```


```
#separando os dados reais observados pré operação
BRFS3_r = ts(treino$BRFS3$xx, freq = 4, start = 2016.25)
JBSS3_r = ts(treino$JBSS3$xx, freq = 4, start = 2016.25)
BAUH3_r = ts(treino$BAUH3$xx, freq = 4, start = 2016.25)
BEEF3_r = ts(treino$BEEF3$xx, freq = 4, start = 2016.25)
MRFG3_r = ts(treino$MRFG3$xx, freq = 4, start = 2016.25)
#separando os dados históricos pré previsão e pré operação
BRFS3_h = ts(treino$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(treino$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(treino$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(treino$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(treino$MRFG3$x, freq = 4, start = 2011)
#plotando as comparações entre estimado e observado pré operação
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "PE - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Histórico") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "PE - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Histórico") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "PE - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Histórico") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "PE - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Histórico") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "PE - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Histórico") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
#separando o ajuste do modelo pro indicador corrente
modelo_PE = modelo

#salvando a performance do modelo no treino
treino_PE = summary_performance(preds_treino, treino, print.summary = FALSE)
BRFS3_PE_1 = summary_performance(preds_treino, treino[1], print.summary = FALSE)
JBSS3_PE_1 = summary_performance(preds_treino, treino[2], print.summary = FALSE)
BAUH3_PE_1 = summary_performance(preds_treino, treino[3], print.summary = FALSE)
BEEF3_PE_1 = summary_performance(preds_treino, treino[4], print.summary = FALSE)
MRFG3_PE_1 = summary_performance(preds_treino, treino[5], print.summary = FALSE)

###repetindo o processo pro novo indicador

#separando apenas os dados pré operação
treino = CE
treino$BRFS3[["h"]] = as.integer(4)
treino$JBSS3[["h"]] = as.integer(4)
treino$BAUH3[["h"]] = as.integer(4)
treino$BEEF3[["h"]] = as.integer(4)
treino$MRFG3[["h"]] = as.integer(4)
treino$MNPR3[["h"]] = as.integer(4)

#retirando as últimas 4 observações de cada série pré operação
treino = temp_holdout(treino)

#aplicando cada método de previsão em cada série pré operação
treino = calc_forecasts(treino, forec_methods(), n.cores = 6)

#calculando os erros de cada método de previsão de cada série pré operação
treino = calc_errors(treino)

#extraíndo as características de cada série pré operação
treino = THA_features(treino)

#organizando as características extraídas e os erros calculados
treino_feat = create_feat_classif_problem(treino)


#ajustando o modelo de acordo com as características e erros
modelo = train_selection_ensemble(treino_feat$data, treino_feat$errors)

#ajustando o modelo nos dados pré operação
preds_treino = predict_selection_ensemble(modelo, treino_feat$data)
```


```
#fazendo a previsão dos dados pré operação
treino = ensemble_forecast(preds_treino, treino)

#separando as previsões dos dados pré operação
BRFS3_p = ts(treino$BRFS3$y_hat, freq = 4, start = 2016.25)
JBSS3_p = ts(treino$JBSS3$y_hat, freq = 4, start = 2016.25)
BAUH3_p = ts(treino$BAUH3$y_hat, freq = 4, start = 2016.25)
BEEF3_p = ts(treino$BEEF3$y_hat, freq = 4, start = 2016.25)
MRFG3_p = ts(treino$MRFG3$y_hat, freq = 4, start = 2016.25)
MNPR3_p = ts(treino$MNPR3$y_hat, freq = 4, start = 2016.25)
```


```
#separando os dados reais observados pré operação
BRFS3_r = ts(treino$BRFS3$xx, freq = 4, start = 2016.25)
JBSS3_r = ts(treino$JBSS3$xx, freq = 4, start = 2016.25)
BAUH3_r = ts(treino$BAUH3$xx, freq = 4, start = 2016.25)
BEEF3_r = ts(treino$BEEF3$xx, freq = 4, start = 2016.25)
MRFG3_r = ts(treino$MRFG3$xx, freq = 4, start = 2016.25)
MNPR3_r = ts(treino$MNPR3$xx, freq = 4, start = 2016.25)
#separando os dados históricos pré previsão e pré operação
BRFS3_h = ts(treino$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(treino$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(treino$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(treino$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(treino$MRFG3$x, freq = 4, start = 2011)
MNPR3_h = ts(treino$MNPR3$x, freq = 4, start = 2011)
#plotando as comparações entre estimado e observado pré operação
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "CE - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Histórico") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "CE - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Histórico") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "CE - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Histórico") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "CE - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Histórico") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "CE - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Histórico") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MNPR3_p, MNPR3_h, MNPR3_r), main = "CE - MINUPAR", ylab = "índice") %>% dySeries(c("MNPR3_h"), label = "Histórico") %>% dySeries(c("MNPR3_r"), label = "Observado") %>% dySeries(c("MNPR3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
#separando o ajuste do modelo pro indicador corrente
modelo_CE = modelo


#salvando a performance do modelo no treino
treino_CE = summary_performance(preds_treino, treino, print.summary = FALSE)
BRFS3_CE_1 = summary_performance(preds_treino, treino[1], print.summary = FALSE)
JBSS3_CE_1 = summary_performance(preds_treino, treino[2], print.summary = FALSE)
BAUH3_CE_1 = summary_performance(preds_treino, treino[3], print.summary = FALSE)
BEEF3_CE_1 = summary_performance(preds_treino, treino[4], print.summary = FALSE)
MRFG3_CE_1 = summary_performance(preds_treino, treino[5], print.summary = FALSE)
MNPR3_CE_1 = summary_performance(preds_treino, treino[6], print.summary = FALSE)
```




```
###repetindo o processo pro novo indicador
```

```
#separando apenas os dados pré operação
treino = RI
treino$BRFS3[["h"]] = as.integer(4)
treino$JBSS3[["h"]] = as.integer(4)
treino$BAUH3[["h"]] = as.integer(4)
treino$BEEF3[["h"]] = as.integer(4)
treino$MRFG3[["h"]] = as.integer(4)
#retirando as últimas 4 observações de cada série pré operação
treino = temp_holdout(treino)
#aplicando cada método de previsão em cada série pré operação
treino = calc_forecasts(treino, forec_methods(), n.cores = 6)
#calculando os erros de cada método de previsão de cada série pré operação
treino = calc_errors(treino)
#extraíndo as características de cada série pré operação
treino = lHA_features(treino)
#organizando as características extraídas e os erros calculados
treino_feat = create_feat_classif_problem(treino)
#ajustando o modelo de acordo com as características e erros
modelo = train_selection_ensemble(treino_feat$data, treino_feat$errors)
#ajustando o modelo nos dados pré operação
preds_treino = predict_selection_ensemble(modelo, treino_feat$data)
```


```
#fazendo a previsão dos dados pré operação
treino = ensemble_forecast(preds_treino, treino)
#separando as previsões dos dados pré operação
BRFS3_p = ts(treino$BRFS3$y_hat, freq = 4, start = 2016.25)
JBSS3_p = ts(treino$JBSS3$y_hat, freq = 4, start = 2016.25)
BAUH3_p = ts(treino$BAUH3$y_hat, freq = 4, start = 2016.25)
BEEF3_p = ts(treino$BEEF3$y_hat, freq = 4, start = 2016.25)
MRFG3_p = ts(treino$MRFG3$y_hat, freq = 4, start = 2016.25)
#separando os dados reais observados pré operação
BRFS3_r = ts(treino$BRFS3$xx, freq = 4, start = 2016.25)
JBSS3_r = ts(treino$JBSS3$xx, freq = 4, start = 2016.25)
BAUH3_r = ts(treino$BAUH3$xx, freq = 4, start = 2016.25)
BEEF3_r = ts(treino$BEEF3$xx, freq = 4, start = 2016.25)
MRFG3_r = ts(treino$MRFG3$xx, freq = 4, start = 2016.25)
#separando os dados históricos pré previsão e pré operação
BRFS3_h = ts(treino$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(treino$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(treino$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(treino$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(treino$MRFG3$x, freq = 4, start = 2011)
#plotando as comparações entre estimado e observado pré operação
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "RI - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Histórico") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "RI - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Histórico") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "RI - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Histórico") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "RI - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Histórico") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "RI - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Histórico") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
#separando o ajuste do modelo pro indicador corrente
modelo_RI = modelo

#salvando a performance do modelo no treino
treino_RI = summary_performance(preds_treino, treino, print.summary = FALSE)
BRFS3_RI_1 = summary_performance(preds_treino, treino[1], print.summary = FALSE)
JBSS3_RI_1 = summary_performance(preds_treino, treino[2], print.summary = FALSE)
BAUH3_RI_1 = summary_performance(preds_treino, treino[3], print.summary = FALSE)
BEEF3_RI_1 = summary_performance(preds_treino, treino[4], print.summary = FALSE)
MRFG3_RI_1 = summary_performance(preds_treino, treino[5], print.summary = FALSE)
```


```
###repetindo o processo pro novo indicador
```

```
#separando apenas os dados pré operação
treino = RP
treino$BRFS3[["h"]] = as.integer(4)
treino$JBSS3[["h"]] = as.integer(4)
treino$BAUH3[["h"]] = as.integer(4)
treino$BEEF3[["h"]] = as.integer(4)
treino$MRFG3[["h"]] = as.integer(4)
#retirando as últimas 4 observações de cada série pré operação
treino = temp_holdout(treino)
#aplicando cada método de previsão em cada série pré operação
treino = calc_forecasts(treino, forec_methods(), n.cores = 6)
#calculando os erros de cada método de previsão de cada série pré operação
treino = calc_errors(treino)
#extraíndo as características de cada série pré operação
treino = THA_features(treino)
#organizando as características extraídas e os erros calculados
treino_feat = create_feat_classif_problem(treino)
#ajustando o modelo de acordo com as características e erros
modelo = train_selection_ensemble(treino_feat$data, treino_feat$errors)
#ajustando o modelo nos dados pré operação
preds_treino = predict_selection_ensemble(modelo, treino_feat$data)
```


```
#fazendo a previsão dos dados pré operação
treino = ensemble_forecast(preds_treino, treino)
#separando as previsões dos dados pré operação
BRFS3_p = ts(treino$BRFS3$y_hat, freq = 4, start = 2016.25)
JBSS3_p = ts(treino$JBSS3$y_hat, freq = 4, start = 2016.25)
BAUH3_p = ts(treino$BAUH3$y_hat, freq = 4, start = 2016.25)
BEEF3_p = ts(treino$BEEF3$y_hat, freq = 4, start = 2016.25)
MRFG3_p = ts(treino$MRFG3$y_hat, freq = 4, start = 2016.25)
#separando os dados reais observados pré operação
BRFS3_r = ts(treino$BRFS3$xx, freq = 4, start = 2016.25)
JBSS3_r = ts(treino$JBSS3$xx, freq = 4, start = 2016.25)
BAUH3_r = ts(treino$BAUH3$xx, freq = 4, start = 2016.25)
BEEF3_r = ts(treino$BEEF3$xx, freq = 4, start = 2016.25)
MRFG3_r = ts(treino$MRFG3$xx, freq = 4, start = 2016.25)
#separando os dados históricos pré previsão e pré operação
BRFS3_h = ts(treino$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(treino$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(treino$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(treino$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(treino$MRFG3$x, freq = 4, start = 2011)
#plotando as comparações entre estimado e observado pré operação
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "RP - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Histórico") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "RP - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Histórico") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "RP - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Histórico") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "RP - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Histórico") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "RP - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Histórico") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```



```
#separando o ajuste do modelo pro indicador corrente
modelo_RP = modelo


#salvando a performance do modelo no treino
treino_RP = summary_performance(preds_treino, treino, print.summary = FALSE)
BRFS3_RP_1 = summary_performance(preds_treino, treino[1], print.summary = FALSE)
JBSS3_RP_1 = summary_performance(preds_treino, treino[2], print.summary = FALSE)
BAUH3_RP_1 = summary_performance(preds_treino, treino[3], print.summary = FALSE)
BEEF3_RP_1 = summary_performance(preds_treino, treino[4], print.summary = FALSE)
MRFG3_RP_1 = summary_performance(preds_treino, treino[5], print.summary = FALSE)
```

```
### testando os modelos para prever os dados
```

```
teste = LS
#aplicando cada método de previsão em cada série dos dados
teste = calc_forecasts(teste, forec_methods(), n.cores=6)
#extrair as características de cada série dos dados
teste = THA_features(teste, n.cores=6)
#organizando as características extraídas e os erros calculados
teste_feat = create_feat_classif_problem(teste)
#ajustando novamente o modelo com as características dos dados
preds_teste = predict_selection_ensemble(modelo_LS, teste_feat$data)
```


```
#gerando as previsões dos dados com base no modelo ajustado
```

```
teste = ensemble_forecast(preds_teste, teste)
#separando as previsões para cada série dos dados
BRFS3_p = ts(teste$BRFS3$y_hat, freq = 4, start = 2017.25)
JBSS3_p = ts(teste$JBSS3$y_hat, freq = 4, start = 2017.25)
BAUH3_p = ts(teste$BAUH3$y_hat, freq = 4, start = 2017.25)
BEEF3_p = ts(teste$BEEF3$y_hat, freq = 4, start = 2017.25)
MRFG3_p = ts(teste$MRFG3$y_hat, freq = 4, start = 2017.25)
MNPR3_p = ts(teste$MNPR3$y_hat, freq = 4, start = 2017.25)
#separando os dados pré operação
BRFS3_h = ts(teste$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(teste$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(teste$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(teste$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(teste$MRFG3$x, freq = 4, start = 2011)
MNPR3_h = ts(teste$MNPR3$x, freq = 4, start = 2011)
#separando os dados reais observados
BRFS3_r = ts(teste$BRFS3$xx, freq = 4, start = 2017.25)
JBSS3_r = ts(teste$JBSS3$xx, freq = 4, start = 2017.25)
BAUH3_r = ts(teste$BAUH3$xx, freq = 4, start = 2017.25)
BEEF3_r = ts(teste$BEEF3$xx, freq = 4, start = 2017.25)
MRFG3_r = ts(teste$MRFG3$xx, freq = 4, start = 2017.25)
MNPR3_r = ts(teste$MNPR3$xx, freq = 4, start = 2017.25)
#plotando os resultados
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "LS - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Pré Carne Fraca") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```






```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "LS - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "LS - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```







```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "LS - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "LS - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MNPR3_p, MNPR3_h, MNPR3_r), main = "LS - MINUPAR", ylab = "índice") %>% dySeries(c("MNPR3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MNPR3_r"), label = "Observado") %>% dySeries(c("MNPR3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
#salvando a performance do modelo no teste
teste_LS = summary_performance(preds_teste, teste, print.summary = FALSE)
BRFS3_LS_2 = summary_performance(preds_teste, teste[1], print.summary = FALSE)
JBSS3_LS_2 = summary_performance(preds_teste, teste[2], print.summary = FALSE)
BAUH3_LS_2 = summary_performance(preds_teste, teste[3], print.summary = FALSE)
BEEF3_LS_2 = summary_performance(preds_teste, teste[4], print.summary = FALSE)
MRFG3_LS_2 = summary_performance(preds_teste, teste[5], print.summary = FALSE)
MNPR3_LS_2 = summary_performance(preds_teste, teste[6], print.summary = FALSE)
```

```
## repetindo o teste para os outros indicadores
```


```
teste = LC
#aplicando cada método de previsão em cada série dos dados
teste = calc_forecasts(teste, forec_methods(), n.cores=6)
#extraíndo as características de cada série dos dados
teste = THA_features(teste, n.cores=6)
#organizando as características extraídas e os erros calculados
teste_feat = create_feat_classif_problem(teste)
#ajustando novamente o modelo com as características dos dados
preds_teste = predict_selection_ensemble(modelo_LC, teste_feat$data)
```

```
#gerando as previsões dos dados com base no modelo ajustado
```


```
teste = ensemble_forecast(preds_teste, teste)
#separando as previsões para cada série dos dados
BRFS3_p = ts(teste$BRFS3$y_hat, freq = 4, start = 2017.25)
JBSS3_p = ts(teste$JBSS3$y_hat, freq = 4, start = 2017.25)
BAUH3_p = ts(teste$BAUH3$y_hat, freq = 4, start = 2017.25)
BEEF3_p = ts(teste$BEEF3$y_hat, freq = 4, start = 2017.25)
MRFG3_p = ts(teste$MRFG3$y_hat, freq = 4, start = 2017.25)
MNPR3_p = ts(teste$MNPR3$y_hat, freq = 4, start = 2017.25)
#separando os dados pré operação
BRFS3_h = ts(teste$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(teste$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(teste$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(teste$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(teste$MRFG3$x, freq = 4, start = 2011)
MNPR3_h = ts(teste$MNPR3$x, freq = 4, start = 2011)
#separando os dados reais observados
BRFS3_r = ts(teste$BRFS3$xx, freq = 4, start = 2017.25)
JBSS3_r = ts(teste$JBSS3$xx, freq = 4, start = 2017.25)
BAUH3_r = ts(teste$BAUH3$xx, freq = 4, start = 2017.25)
BEEF3_r = ts(teste$BEEF3$xx, freq = 4, start = 2017.25)
MRFG3_r = ts(teste$MRFG3$xx, freq = 4, start = 2017.25)
MNPR3_r = ts(teste$MNPR3$xx, freq = 4, start = 2017.25)
```

```
#plotando os resultados
```


```
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "LC - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "LC - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "LC - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "LC - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "LC - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MNPR3_p, MNPR3_h, MNPR3_r), main = "LC - MINUPAR", ylab = "índice") %>% dySeries(c("MNPR3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MNPR3_r"), label = "Observado") %>% dySeries(c("MNPR3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
#salvando a performance do modelo no teste
teste_LC = summary_performance(preds_teste, teste, print.summary = FALSE)
BRFS3_LC_2 = summary_performance(preds_teste, teste[1], print.summary = FALSE)
JBSS3_LC_2 = summary_performance(preds_teste, teste[2], print.summary = FALSE)
BAUH3_LC_2 = summary_performance(preds_teste, teste[3], print.summary = FALSE)
BEEF3_LC_2 = summary_performance(preds_teste, teste[4], print.summary = FALSE)
MRFG3_LC_2 = summary_performance(preds_teste, teste[5], print.summary = FALSE)
MNPR3_LC_2 = summary_performance(preds_teste, teste[6], print.summary = FALSE)
```

```
## repetindo o teste para os outros indicadores
```


```
teste = PE
#aplicando cada método de previsão em cada série dos dados
teste = calc_forecasts(teste, forec_methods(), n.cores=6)
#extraíndo as características de cada série dos dados
teste = THA_features(teste, n.cores=6)
#organizando as características extraídas e os erros calculados
teste_feat = create_feat_classif_problem(teste)
#ajustando novamente o modelo com as características dos dados
preds_teste = predict_selection_ensemble(modelo_PE, teste_feat$data)
```

```
#gerando as previsões dos dados com base no modelo ajustado
```


```
teste = ensemble_forecast(preds_teste, teste)
#separando as previsões para cada série dos dados
BRFS3_p = ts(teste$BRFS3$y_hat, freq = 4, start = 2017.25)
JBSS3_p = ts(teste$JBSS3$y_hat, freq = 4, start = 2017.25)
BAUH3_p = ts(teste$BAUH3$y_hat, freq = 4, start = 2017.25)
BEEF3_p = ts(teste$BEEF3$y_hat, freq = 4, start = 2017.25)
MRFG3_p = ts(teste$MRFG3$y_hat, freq = 4, start = 2017.25)
#separando os dados pré operação
BRFS3_h = ts(teste$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(teste$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(teste$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(teste$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(teste$MRFG3$x, freq = 4, start = 2011)
#separando os dados reais observados
BRFS3_r = ts(teste$BRFS3$xx, freq = 4, start = 2017.25)
JBSS3_r = ts(teste$JBSS3$xx, freq = 4, start = 2017.25)
BAUH3_r = ts(teste$BAUH3$xx, freq = 4, start = 2017.25)
BEEF3_r = ts(teste$BEEF3$xx, freq = 4, start = 2017.25)
MRFG3_r = ts(teste$MRFG3$xx, freq = 4, start = 2017.25)
#plotando os resultados
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "PE - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Pré Carne Fraca") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "PE - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "PE - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "PE - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "PE - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
#salvando a performance do modelo no teste
teste_PE = summary_performance(preds_teste, teste, print.summary = FALSE)
BRFS3_PE_2 = summary_performance(preds_teste, teste[1], print.summary = FALSE)
JBSS3_PE_2 = summary_performance(preds_teste, teste[2], print.summary = FALSE)
BAUH3_PE_2 = summary_performance(preds_teste, teste[3], print.summary = FALSE)
BEEF3_PE_2 = summary_performance(preds_teste, teste[4], print.summary = FALSE)
MRFG3_PE_2 = summary_performance(preds_teste, teste[5], print.summary = FALSE)
```




```
## repetindo o teste para os outros indicadores
```


```
teste = CE
#aplicando cada método de previsão em cada série dos dados
teste = calc_forecasts(teste, forec_methods(), n.cores=6)
#extraíndo as características de cada série dos dados
teste = THA_features(teste, n.cores=6)
#organizando as características extraídas e os erros calculados
teste_feat = create_feat_classif_problem(teste)
#ajustando novamente o modelo com as características dos dados
preds_teste = predict_selection_ensemble(modelo_CE, teste_feat$data)
```

```
#gerando as previsões dos dados com base no modelo ajustado
```


```
teste = ensemble_forecast(preds_teste, teste)
#separando as previsões para cada série dos dados
BRFS3_p = ts(teste$BRFS3$y_hat, freq = 4, start = 2017.25)
JBSS3_p = ts(teste$JBSS3$y_hat, freq = 4, start = 2017.25)
BAUH3_p = ts(teste$BAUH3$y_hat, freq = 4, start = 2017.25)
BEEF3_p = ts(teste$BEEF3$y_hat, freq = 4, start = 2017.25)
MRFG3_p = ts(teste$MRFG3$y_hat, freq = 4, start = 2017.25)
MNPR3_p = ts(teste$MNPR3$y_hat, freq = 4, start = 2017.25)
#separando os dados pré operação
BRFS3_h = ts(teste$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(teste$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(teste$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(teste$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(teste$MRFG3$x, freq = 4, start = 2011)
MNPR3_h = ts(teste$MNPR3$x, freq = 4, start = 2011)
#separando os dados reais observados
BRFS3_r = ts(teste$BRFS3$xx, freq = 4, start = 2017.25)
JBSS3_r = ts(teste$JBSS3$xx, freq = 4, start = 2017.25)
BAUH3_r = ts(teste$BAUH3$xx, freq = 4, start = 2017.25)
BEEF3_r = ts(teste$BEEF3$xx, freq = 4, start = 2017.25)
MRFG3_r = ts(teste$MRFG3$xx, freq = 4, start = 2017.25)
MNPR3_r = ts(teste$MNPR3$xx, freq = 4, start = 2017.25)
#plotando os resultados
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "CE - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Pré Carne Fraca") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x", drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, strokeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "CE - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "CE - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "CE - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "CE - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MNPR3_p, MNPR3_h, MNPR3_r), main = "CE - MINUPAR", ylab = "índice") %>% dySeries(c("MNPR3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MNPR3_r"), label = "Observado") %>% dySeries(c("MNPR3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
#salvando a performance do modelo no teste
teste_CE = summary_performance(preds_teste, teste, print.summary = FALSE)
BRFS3_CE_2 = summary_performance(preds_teste, teste[1], print.summary = FALSE)
JBSS3_CE_2 = summary_performance(preds_teste, teste[2], print.summary = FALSE)
BAUH3_CE_2 = summary_performance(preds_teste, teste[3], print.summary = FALSE)
BEEF3_CE_2 = summary_performance(preds_teste, teste[4], print.summary = FALSE)
MRFG3_CE_2 = summary_performance(preds_teste, teste[5], print.summary = FALSE)
MNPR3_CE_2 = summary_performance(preds_teste, teste[6], print.summary = FALSE)
```

```
## repetindo o teste para os outros indicadores
```


```
teste = RI
#aplicando cada método de previsão em cada série dos dados
teste = calc_forecasts(teste, forec_methods(), n.cores=6)
#extraíndo as características de cada série dos dados
teste = THA_features(teste, n.cores=6)
#organizando as características extraídas e os erros calculados
teste_feat = create_feat_classif_problem(teste)
#ajustando novamente o modelo com as características dos dados
preds_teste = predict_selection_ensemble(modelo_RI, teste_feat$data)
```

```
#gerando as previsões dos dados com base no modelo ajustado
```


```
teste = ensemble_forecast(preds_teste, teste)
#separando as previsões para cada série dos dados
BRFS3_p = ts(teste$BRFS3$y_hat, freq = 4, start = 2017.25)
JBSS3_p = ts(teste$JBSS3$y_hat, freq = 4, start = 2017.25)
BAUH3_p = ts(teste$BAUH3$y_hat, freq = 4, start = 2017.25)
BEEF3_p = ts(teste$BEEF3$y_hat, freq = 4, start = 2017.25)
MRFG3_p = ts(teste$MRFG3$y_hat, freq = 4, start = 2017.25)
#separando os dados pré operação
BRFS3_h = ts(teste$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(teste$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(teste$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(teste$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(teste$MRFG3$x, freq = 4, start = 2011)
#separando os dados reais observados
BRFS3_r = ts(teste$BRFS3$xx, freq = 4, start = 2017.25)
JBSS3_r = ts(teste$JBSS3$xx, freq = 4, start = 2017.25)
BAUH3_r = ts(teste$BAUH3$xx, freq = 4, start = 2017.25)
BEEF3_r = ts(teste$BEEF3$xx, freq = 4, start = 2017.25)
MRFG3_r = ts(teste$MRFG3$xx, freq = 4, start = 2017.25)
```

```
#plotando os resultados
```


```
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "RI - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "RI - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "RI - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "RI - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "RI - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
#salvando a performance do modelo no teste
teste_RI = summary_performance(preds_teste, teste, print.summary = FALSE)
BRFS3_RI_2 = summary_performance(preds_teste, teste[1], print.summary = FALSE)
JBSS3_RI_2 = summary_performance(preds_teste, teste[2], print.summary = FALSE)
BAUH3_RI_2 = summary_performance(preds_teste, teste[3], print.summary = FALSE)
BEEF3_RI_2 = summary_performance(preds_teste, teste[4], print.summary = FALSE)
MRFG3_RI_2 = summary_performance(preds_teste, teste[5], print.summary = FALSE)
```

```
## repetindo o teste para os outros indicadores
```


```
teste = RP
#aplicando cada método de previsão em cada série dos dados
teste = calc_forecasts(teste, forec_methods(), n.cores=6)
#extraíndo as características de cada série dos dados
teste = THA_features(teste, n.cores=6)
#organizando as características extraídas e os erros calculados
teste_feat = create_feat_classif_problem(teste)
#ajustando novamente o modelo com as características dos dados
preds_teste = predict_selection_ensemble(modelo_RP, teste_feat$data)
```

```
#gerando as previsões dos dados com base no modelo ajustado
```


```
teste = ensemble_forecast(preds_teste, teste)
#separando as previsões para cada série dos dados
BRFS3_p = ts(teste$BRFS3$y_hat, freq = 4, start = 2017.25)
JBSS3_p = ts(teste$JBSS3$y_hat, freq = 4, start = 2017.25)
BAUH3_p = ts(teste$BAUH3$y_hat, freq = 4, start = 2017.25)
BEEF3_p = ts(teste$BEEF3$y_hat, freq = 4, start = 2017.25)
MRFG3_p = ts(teste$MRFG3$y_hat, freq = 4, start = 2017.25)
#separando os dados pré operação
BRFS3_h = ts(teste$BRFS3$x, freq = 4, start = 2011)
JBSS3_h = ts(teste$JBSS3$x, freq = 4, start = 2011)
BAUH3_h = ts(teste$BAUH3$x, freq = 4, start = 2011)
BEEF3_h = ts(teste$BEEF3$x, freq = 4, start = 2011)
MRFG3_h = ts(teste$MRFG3$x, freq = 4, start = 2011)
#separando os dados reais observados
BRFS3_r = ts(teste$BRFS3$xx, freq = 4, start = 2017.25)
JBSS3_r = ts(teste$JBSS3$xx, freq = 4, start = 2017.25)
BAUH3_r = ts(teste$BAUH3$xx, freq = 4, start = 2017.25)
BEEF3_r = ts(teste$BEEF3$xx, freq = 4, start = 2017.25)
MRFG3_r = ts(teste$MRFG3$xx, freq = 4, start = 2017.25)
```

```
#plotando os resultados
```

```
dygraph(cbind(BRFS3_p, BRFS3_h, BRFS3_r), main = "RP - BRF", ylab = "índice") %>% dySeries(c("BRFS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BRFS3_r"), label = "Observado") %>% dySeries(c("BRFS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```




```
dygraph(cbind(JBSS3_p, JBSS3_h, JBSS3_r), main = "RP - JBS", ylab = "índice") %>% dySeries(c("JBSS3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("JBSS3_r"), label = "Observado") %>% dySeries(c("JBSS3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```







```
dygraph(cbind(BAUH3_p, BAUH3_h, BAUH3_r), main = "RP - EXCELSIOR", ylab = "índice") %>% dySeries(c("BAUH3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BAUH3_r"), label = "Observado") %>% dySeries(c("BAUH3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(BEEF3_p, BEEF3_h, BEEF3_r), main = "RP - MINERVA", ylab = "índice") %>% dySeries(c("BEEF3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("BEEF3_r"), label = "Observado") %>% dySeries(c("BEEF3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
dygraph(cbind(MRFG3_p, MRFG3_h, MRFG3_r), main = "RP - MARFRIG", ylab = "índice") %>% dySeries(c("MRFG3_h"), label = "Pré  
Carne Fraca") %>% dySeries(c("MRFG3_r"), label = "Observado") %>% dySeries(c("MRFG3_p"), label = "Previsão") %>% dyAxis("x",  
drawGrid = TRUE) %>% dyEvent("2017-01-02", "Operação Carne Fraca", labelLoc = "bottom") %>% dyOptions(drawPoints = TRUE, str  
okeWidth = 3, pointSize = 4)
```



```
#salvando a performance do modelo no teste
teste_RP = summary_performance(preds_teste, teste, print.summary = FALSE)
BRFS3_RP_2 = summary_performance(preds_teste, teste[1], print.summary = FALSE)
JBSS3_RP_2 = summary_performance(preds_teste, teste[2], print.summary = FALSE)
BAUH3_RP_2 = summary_performance(preds_teste, teste[3], print.summary = FALSE)
BEEF3_RP_2 = summary_performance(preds_teste, teste[4], print.summary = FALSE)
MRFG3_RP_2 = summary_performance(preds_teste, teste[5], print.summary = FALSE)

#performance do modelo ponderado para cada indicador
erro_i = matrix(c(treino_LS$weighted_error, teste_LS$weighted_error, treino_LC$weighted_error, teste_LC$weighted_error, treino_PE$weighted_error, teste_PE$weighted_error, treino_CE$weighted_error, teste_CE$weighted_error, treino_RI$weighted_error, teste_RI$weighted_error, treino_RP$weighted_error, teste_RP$weighted_error), ncol=2, byrow=TRUE)
colnames(erro_i) = c("Treino", "Teste")
rownames(erro_i) = c("LS", "LC", "PE", "CE", "RI", "RP")
erro_i
```

```
##      Treino  Teste
## LS 0.5534094 1.0727886
## LC 0.4779656 1.0210639
## PE 0.8062408 0.7837534
## CE 0.6265432 0.9823430
## RI 0.6338588 0.8328615
## RP 0.9007917 0.9551770
```

```
#performance do modelo ponderado para cada empresa
```

```
erro_e = matrix(c(BRFS3_LS_1$weighted_error, BRFS3_LS_2$weighted_error, JBSS3_LS_1$weighted_error, JBSS3_LS_2$weighted_error,
  BAUH3_LS_1$weighted_error, BAUH3_LS_2$weighted_error, BEEF3_LS_1$weighted_error, BEEF3_LS_2$weighted_error, MRFG3_LS_1$weighted_error, MRFG3_LS_2$weighted_error,
  MNPR3_LS_1$weighted_error, MNPR3_LS_2$weighted_error, BRFS3_LC_1$weighted_error, BRFS3_LC_2$weighted_error, JBSS3_LC_1$weighted_error, JBSS3_LC_2$weighted_error,
  BAUH3_LC_1$weighted_error, BAUH3_LC_2$weighted_error, BEEF3_LC_1$weighted_error, BEEF3_LC_2$weighted_error, MRFG3_LC_1$weighted_error, MRFG3_LC_2$weighted_error,
  MNPR3_LC_1$weighted_error, MNPR3_LC_2$weighted_error, BRFS3_PE_1$weighted_error, BRFS3_PE_2$weighted_error, JBSS3_PE_1$weighted_error, JBSS3_PE_2$weighted_error,
  BAUH3_PE_1$weighted_error, BAUH3_PE_2$weighted_error, BEEF3_PE_1$weighted_error, BEEF3_PE_2$weighted_error, MRFG3_PE_1$weighted_error, MRFG3_PE_2$weighted_error,
  0, 0, BRFS3_CE_1$weighted_error, BRFS3_CE_2$weighted_error, JBSS3_CE_1$weighted_error, JBSS3_CE_2$weighted_error, BAUH3_CE_1$weighted_error, BAUH3_CE_2$weighted_error,
  BEEF3_CE_1$weighted_error, BEEF3_CE_2$weighted_error, MRFG3_CE_1$weighted_error, MRFG3_CE_2$weighted_error, MNPR3_CE_1$weighted_error, MNPR3_CE_2$weighted_error,
  BRFS3_RI_1$weighted_error, BRFS3_RI_2$weighted_error, JBSS3_RI_1$weighted_error, JBSS3_RI_2$weighted_error, BAUH3_RI_1$weighted_error, BAUH3_RI_2$weighted_error,
  BEEF3_RI_1$weighted_error, BEEF3_RI_2$weighted_error, MRFG3_RI_1$weighted_error, MRFG3_RI_2$weighted_error, 0, 0, BRFS3_RP_1$weighted_error, BRFS3_RP_2$weighted_error,
  JBSS3_RP_1$weighted_error, JBSS3_RP_2$weighted_error, BAUH3_RP_1$weighted_error, BAUH3_RP_2$weighted_error, BEEF3_RP_1$weighted_error, BEEF3_RP_2$weighted_error,
  MRFG3_RP_1$weighted_error, MRFG3_RP_2$weighted_error, 0, 0), ncol=12, byrow=TRUE)
colnames(erro_e) = c("BRF-Pré", "BRF-Pós", "JBS-Pré", "JBS-Pós", "EXCS-Pré", "EXCS-Pós", "MNRV-Pré", "MNRV-Pós", "MRFG-Pré", "MRFG-Pós", "MNPR-Pré", "MNPR-Pós")
rownames(erro_e) = c("LS", "LC", "PE", "CE", "RI", "RP")
erro_e
```

```
##      BRF-Pré  BRF-Pós  JBS-Pré  JBS-Pós  EXCS-Pré  EXCS-Pós  MNRV-Pré
## LS 0.5681165 1.1888455 0.3585228 0.9361897 0.2394765 0.9306953 0.5870693
## LC 0.7124891 1.1297158 0.2035793 0.6440266 0.2665010 1.0840343 0.5526302
## PE 0.5788205 0.5086686 0.8243510 2.0507823 1.6553080 1.1589414 0.8062327
## CE 1.3126073 0.8755629 0.7198076 0.9979838 0.5709813 0.4450501 0.4531489
## RI 0.9036854 0.8075171 0.3536677 0.7307268 0.4803560 0.9332940 0.6314792
## RP 0.8489204 1.0492778 1.2880931 0.6900246 0.5628417 0.9100720 0.8386906
##      MNRV-Pós  MRFG-Pré  MRFG-Pós  MNPR-Pré  MNPR-Pós
## LS 0.9212737 0.7711005 1.7508365 0.8254433 1.028500
## LC 1.0685570 0.4627405 1.5465352 0.7840429 1.069856
## PE 0.6845021 1.0201080 0.6099374 0.0000000 0.000000
## CE 0.9445676 0.5462380 1.0666442 0.5777428 1.062803
## RI 0.7965505 0.6664547 0.8318074 0.0000000 0.000000
## RP 1.0121841 0.4464659 0.9317034 0.0000000 0.000000
```

## APÊNDICE B – Rotinas utilizadas para o t-test

### ttest.R

Marcus

2021-08-07

```
##           Treino      Teste
## LS 0.5534094 1.0727886
## LC 0.4779656 1.0210639
## PE 0.8062408 0.7837534
## CE 0.6265432 0.9823430
## RI 0.6338588 0.8328615
## RP 0.9007917 0.9551770

#separando os dados em conjuntos para treino e teste
treino = c(0.5534094, 0.4779656, 0.8062408, 0.6265432, 0.6338588, 0.9007917)
teste  = c(1.0727886, 1.0210639, 0.7837534, 0.9823430, 0.8328615, 0.9551770)
#efetuando o t test para dados pareados
t.test(treino, teste, paired=T)
```

```
##
## Paired t-test
##
## data: treino and teste
## t = -2.8397, df = 5, p-value = 0.03626
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.52367954 -0.02604643
## sample estimates:
## mean of the differences
## -0.274863
```

```
##           BRF-Pré   BRF-Pós   JBS-Pré   JBS-Pós   EXCS-Pré   EXCS-Pós   MNRV-Pré   MNRV-Pós   MRFG-Pré   MRFG-Pós   MNPR-Pré   MNPR-Pós
## LS 0.5681165 1.1888455 0.3585228 0.9361897 0.2394765 0.9306953 0.5870693 0.9212737 0.7711005 1.7508365 0.8254433 1.028500
## LC 0.7124891 1.1297158 0.2035793 0.6440266 0.2665010 1.0840343 0.5526302 1.0685570 0.4627405 1.5465352 0.7840429 1.069856
## PE 0.5788205 0.5086686 0.8243510 2.0507823 1.6553080 1.1589414 0.8062327 0.6845021 1.0201080 0.6099374 0.0000000 0.000000
## CE 1.3126073 0.8755629 0.7198076 0.9979838 0.5709813 0.4450501 0.4531489 0.9445676 0.5462380 1.0666442 0.5777428 1.062803
## RI 0.9036854 0.8075171 0.3536677 0.7307268 0.4803560 0.9332940 0.6314792 0.7965505 0.6664547 0.8318074 0.0000000 0.000000
## RP 0.8489204 1.0492778 1.2880931 0.6900246 0.5628417 0.9100720 0.8386906 1.0121841 0.4464659 0.9317034 0.0000000 0.000000

#separando os dados em conjuntos por indicadores
LS_tr = c(0.5681165, 0.3585228, 0.2394765, 0.5870693, 0.7711005, 0.8254433)
LS_ts = c(1.1888455, 0.9361897, 0.9306953, 0.9212737, 1.7508365, 1.028500)
LC_tr = c(0.7124891, 0.2035793, 0.2665010, 0.5526302, 0.4627405, 0.7840429)
LC_ts = c(1.1297158, 0.6440266, 1.0840343, 1.0685570, 1.5465352, 1.069856)
PE_tr = c(0.5788205, 0.8243510, 1.6553080, 0.8062327, 1.0201080)
PE_ts = c(0.5086686, 2.0507823, 1.1589414, 0.6845021, 0.6099374)
CE_tr = c(1.3126073, 0.7198076, 0.5709813, 0.4531489, 0.5462380, 0.5777428)
CE_ts = c(0.8755629, 0.9979838, 0.4450501, 0.9445676, 1.0666442, 1.062803)
RI_tr = c(0.9036854, 0.3536677, 0.4803560, 0.6314792, 0.6664547)
RI_ts = c(0.8075171, 0.7307268, 0.9332940, 0.7965505, 0.8318074)
RP_tr = c(0.8489204, 1.2880931, 0.5628417, 0.8386906, 0.4464659)
RP_ts = c(1.0492778, 0.6900246, 0.9100720, 1.0121841, 0.9317034)
#efetuando o t test para dados pareados
t.test(LS_tr, LS_ts, paired=T)
```

```
##
## Paired t-test
##
## data: LS_tr and LS_ts
## t = -5.0754, df = 5, p-value = 0.003849
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.8553320 -0.2802053
## sample estimates:
## mean of the differences
## -0.5677686
```

```
t.test(LC_tr, LC_ts, paired=T)
```

```
##
## Paired t-test
##
## data: LC_tr and LC_ts
## t = -4.8685, df = 5, p-value = 0.004599
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.9068031 -0.2801109
## sample estimates:
## mean of the differences
## -0.593457
```

```
t.test(PE_tr, PE_ts, paired=T)
```

```
##
## Paired t-test
##
## data: PE_tr and PE_ts
## t = -0.082306, df = 4, p-value = 0.9384
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.8892543 0.8380497
## sample estimates:
## mean of the differences
## -0.02560232
```

```
t.test(CE_tr, CE_ts, paired=T)
```

```
##
## Paired t-test
##
## data: CE_tr and CE_ts
## t = -1.2473, df = 5, p-value = 0.2675
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.6183608 0.2143322
## sample estimates:
## mean of the differences
## -0.2020143
```

```
t.test(RI_tr, RI_ts, paired=T)
```

```
##
## Paired t-test
##
## data: RI_tr and RI_ts
## t = -2.2153, df = 4, p-value = 0.09109
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.47961910 0.05391798
## sample estimates:
## mean of the differences
## -0.2128506
```

```
t.test(RP_tr, RP_ts, paired=T)
```

```
##
## Paired t-test
##
## data: RP_tr and RP_ts
## t = -0.64567, df = 4, p-value = 0.5537
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.6447575 0.4014574
## sample estimates:
## mean of the differences
## -0.12165
```

```
#separando os dados em conjuntos por empresas
BRFS3_tr = c(0.5681165, 0.7124891, 0.5788205, 1.3126073, 0.9036854, 0.8489204)
BRFS3_ts = c(1.1888455, 1.1297158, 0.5086686, 0.8755629, 0.8075171, 1.0492778)
JBSS3_tr = c(0.3585228, 0.2035793, 0.8243510, 0.7198076, 0.3536677, 1.2880931)
JBSS3_ts = c(0.9361897, 0.6440266, 2.0507823, 0.9979838, 0.7307268, 0.6900246)
BAUH3_tr = c(0.2394765, 0.2665010, 1.6553080, 0.5709813, 0.4803560, 0.5628417)
BAUH3_ts = c(0.9306953, 1.0840343, 1.1589414, 0.4450501, 0.9332940, 0.9100720)
BEEF3_tr = c(0.5870693, 0.5526302, 0.8062327, 0.4531489, 0.6314792, 0.8386906)
BEEF3_ts = c(0.9212737, 1.0685570, 0.6845021, 0.9445676, 0.7965505, 1.0121841)
MRFG3_tr = c(0.7711005, 0.4627405, 1.0201080, 0.5462380, 0.6664547, 0.4464659)
MRFG3_ts = c(1.7508365, 1.5465352, 0.6099374, 1.0666442, 0.8318074, 0.9317034)
MNPR3_tr = c(0.8254433, 0.7840429, 0.5777428)
MNPR3_ts = c(1.028500, 1.069856, 1.062803)
#efetuando o t test para dados pareados
t.test(BRFS3_tr, BRFS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: BRFS3_tr and BRFS3_ts
## t = -0.67494, df = 5, p-value = 0.5297
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.5088709 0.2972214
## sample estimates:
## mean of the differences
## -0.1058248
```

```
t.test(JBSS3_tr, JBSS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: JBSS3_tr and JBSS3_ts
## t = -1.5993, df = 5, p-value = 0.1706
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.0002170 0.2329795
## sample estimates:
## mean of the differences
## -0.3836187
```

```
t.test(BAUH3_tr, BAUH3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: BAUH3_tr and BAUH3_ts
## t = -1.3717, df = 5, p-value = 0.2285
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.8079138 0.2457063
## sample estimates:
## mean of the differences
## -0.2811038
```

```
t.test(BEEF3_tr, BEEF3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: BEEF3_tr and BEEF3_ts
## t = -2.6565, df = 5, p-value = 0.04507
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.511057738 -0.008403628
## sample estimates:
## mean of the differences
## -0.2597307
```

```
t.test(MRFG3_tr, MRFG3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: MRFG3_tr and MRFG3_ts
## t = -2.1004, df = 5, p-value = 0.08971
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.0468375 0.1053854
## sample estimates:
## mean of the differences
## -0.4707261
```

```
t.test(MNPR3_tr, MNPR3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: MNPR3_tr and MNPR3_ts
## t = -3.8791, df = 2, p-value = 0.06049
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.68473479 0.03544812
## sample estimates:
## mean of the differences
## -0.3246433
```

```
#separando os dados da liquidez para cada empresa
```

```
L_BRFS3_tr = c(0.5681165, 0.7124891)
L_BRFS3_ts = c(1.1888455, 1.1297158)
L_JBSS3_tr = c(0.3585228, 0.2035793)
L_JBSS3_ts = c(0.9361897, 0.6440266)
L_BAUH3_tr = c(0.2394765, 0.2665010)
L_BAUH3_ts = c(0.9306953, 1.0840343)
L_BEEF3_tr = c(0.5870693, 0.5526302)
L_BEEF3_ts = c(0.9212737, 1.0685570)
L_MRFG3_tr = c(0.7711005, 0.4627405)
L_MRFG3_ts = c(1.7508365, 1.5465352)
L_MNPR3_tr = c(0.8254433, 0.7840429)
L_MNPR3_ts = c(1.028500, 1.069856)
#efetuando o t test para dados pareados
t.test(L_BRFS3_tr, L_BRFS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: L_BRFS3_tr and L_BRFS3_ts
## t = -5.1005, df = 1, p-value = 0.1233
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.8118488 0.7738931
## sample estimates:
## mean of the differences
## -0.5189778
```

```
t.test(L_JBSS3_tr, L_JBSS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: L_JBSS3_tr and L_JBSS3_ts
## t = -7.4196, df = 1, p-value = 0.08529
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.3808273 0.3627131
## sample estimates:
## mean of the differences
## -0.5090571
```

```
t.test(L_BAUH3_tr, L_BAUH3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: L_BAUH3_tr and L_BAUH3_ts
## t = -11.944, df = 1, p-value = 0.05317
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.5568650 0.0481129
## sample estimates:
## mean of the differences
## -0.754376
```

```
t.test(L_BEEF3_tr, L_BEEF3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: L_BEEF3_tr and L_BEEF3_ts
## t = -4.6782, df = 1, p-value = 0.1341
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.5795666 0.7294354
## sample estimates:
## mean of the differences
## -0.4250656
```

```
t.test(L_MRFG3_tr, L_MRFG3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: L_MRFG3_tr and L_MRFG3_ts
## t = -19.83, df = 1, p-value = 0.03208
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.6928609 -0.3706698
## sample estimates:
## mean of the differences
## -1.031765
```

```
t.test(L_MNPR3_tr, L_MNPR3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: L_MNPR3_tr and L_MNPR3_ts
## t = -5.9073, df = 1, p-value = 0.1068
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.7701948 0.2813250
## sample estimates:
## mean of the differences
## -0.2444349
```



```
#separando os dados da estrutura para cada empresa
```

```
E_BRFS3_tr = c(0.5788205, 1.3126073)
```

```
E_BRFS3_ts = c(0.5086686, 0.8755629)
```

```
E_JBSS3_tr = c(0.8243510, 0.7198076)
```

```
E_JBSS3_ts = c(2.0507823, 0.9979838)
```

```
E_BAUH3_tr = c(1.6553080, 0.5709813)
```

```
E_BAUH3_ts = c(1.1589414, 0.4450501)
```

```
E_BEEF3_tr = c(0.8062327, 0.4531489)
```

```
E_BEEF3_ts = c(0.6845021, 0.9445676)
```

```
E_MRFG3_tr = c(1.0201080, 0.5462380)
```

```
E_MRFG3_ts = c(0.6099374, 1.0666442)
```

```
#efetuando o t test para dados pareados
```

```
t.test(E_BRFS3_tr, E_BRFS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: E_BRFS3_tr and E_BRFS3_ts
## t = 1.3824, df = 1, p-value = 0.3987
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -2.077307 2.584504
## sample estimates:
## mean of the differences
## 0.2535981
```

```
t.test(E_JBSS3_tr, E_JBSS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: E_JBSS3_tr and E_JBSS3_ts
## t = -1.5867, df = 1, p-value = 0.358
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -6.776665 5.272058
## sample estimates:
## mean of the differences
## -0.7523037
```

```
t.test(E_BAUH3_tr, E_BAUH3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: E_BAUH3_tr and E_BAUH3_ts
## t = 1.6799, df = 1, p-value = 0.3418
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -2.042265 2.664563
## sample estimates:
## mean of the differences
## 0.3111489
```

```
t.test(E_BEEF3_tr, E_BEEF3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: E_BEEF3_tr and E_BEEF3_ts
## t = -0.60293, df = 1, p-value = 0.6546
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -4.080244 3.710556
## sample estimates:
## mean of the differences
## -0.184844
```

```
t.test(E_MRF3_tr, E_MRF3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: E_MRF3_tr and E_MRF3_ts
## t = -0.11846, df = 1, p-value = 0.9249
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -5.967167 5.856932
## sample estimates:
## mean of the differences
## -0.0551178
```

```
#separando os dados da rentabilidade para cada empresa
```

```
R_BRFS3_tr = c(0.9036854, 0.8489204)
R_BRFS3_ts = c(0.8075171, 1.0492778)
R_JBSS3_tr = c(0.3536677, 1.2880931)
R_JBSS3_ts = c(0.7307268, 0.6900246)
R_BAUH3_tr = c(0.4803560, 0.5628417)
R_BAUH3_ts = c(0.9332940, 0.9100720)
R_BEEF3_tr = c(0.6314792, 0.8386906)
R_BEEF3_ts = c(0.7965505, 1.0121841)
R_MRF3_tr = c(0.6664547, 0.4464659)
R_MRF3_ts = c(0.8318074, 0.9317034)
```

```
#efetuando o t test para dados pareados
```

```
t.test(R_BRFS3_tr, R_BRFS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: R_BRFS3_tr and R_BRFS3_ts
## t = -0.35137, df = 1, p-value = 0.7849
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.935953 1.831764
## sample estimates:
## mean of the differences
## -0.05209455
```

```
t.test(R_JBSS3_tr, R_JBSS3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: R_JBSS3_tr and R_JBSS3_ts
## t = 0.22665, df = 1, p-value = 0.8581
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -6.084581 6.305590
## sample estimates:
## mean of the differences
## 0.1105047
```

```
t.test(R_BAUH3_tr, R_BAUH3_ts, paired=T)
```

```
##
## Paired t-test
##
## data: R_BAUH3_tr and R_BAUH3_ts
## t = -7.5696, df = 1, p-value = 0.08362
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -1.0716560 0.2714877
## sample estimates:
## mean of the differences
## -0.4000841
```

```
t.test(R_BEEF3_tr, R_BEEF3_ts, paired=T)
```

```
##  
## Paired t-test  
##  
## data: R_BEEF3_tr and R_BEEF3_ts  
## t = -40.199, df = 1, p-value = 0.01583  
## alternative hypothesis: true difference in means is not equal to 0  
## 95 percent confidence interval:  
## -0.2227895 -0.1157753  
## sample estimates:  
## mean of the differences  
## -0.1692824
```

```
t.test(R_MRFG3_tr, R_MRFG3_ts, paired=T)
```

```
##  
## Paired t-test  
##  
## data: R_MRFG3_tr and R_MRFG3_ts  
## t = -2.0338, df = 1, p-value = 0.2909  
## alternative hypothesis: true difference in means is not equal to 0  
## 95 percent confidence interval:  
## -2.357556 1.706966  
## sample estimates:  
## mean of the differences  
## -0.3252951
```