

# CARACTERIZAÇÃO DO COMPORTAMENTO SAZONAL DE SÉRIES MACROECONÔMICAS POR SETOR NO BRASIL NO CONTEXTO DA PANDEMIA DA COVID-19: UMA ANÁLISE A PARTIR DO MÉTODO DE AJUSTE SAZONAL ARIMA X-13 SEATS

Áydano Ribeiro Leite<sup>1</sup>

**RESUMO:** O ano de 2020 pode ser considerado um ponto de inflexão em função do choque da pandemia da Covid-19 e seus impactos sobre os diversos setores da economia brasileira. A necessidade de controlar e evitar a proliferação do vírus, fez com que governos em todo mundo adotassem medidas de isolamento social, o que levou a paralisação parcial dos setores da economia resultando numa forte retração da atividade econômica. O propósito deste trabalho foi investigar e caracterizar no contexto da pandemia da Covid-19, o comportamento sazonal das séries macroeconômicas dos setores industrial, comercial e de serviços, além do nível de atividade expresso no IBC-br. Para tanto, utilizou-se o método analítico de ajuste sazonal ARIMA X-13 SEATS, buscando identificar os processos Autorregressivos (AR) e de Médias Móveis (MA), além dos possíveis efeitos de calendário como os dias da semana, datas comemorativas e os *outliers* level shift (LS) ou additive *outliers* (AO) associados aos possíveis impactos referentes à pandemia da Covid-19. Os resultados apontaram significativos efeitos dos *outliers* em relação à pandemia sobre os setores analisados e o nível de atividade da economia no Brasil. Neste sentido, os efeitos negativos mais relevantes foram identificados, principalmente, no segundo trimestre do ano 2020.

**Palavras-chaves:** Pandemia; Choque exógeno; Setores da Economia; Modelo Arima.

## CHARACTERIZATION OF SEASONAL BEHAVIOR OF MACROECONOMIC SERIES BY SECTOR IN BRAZIL IN THE CONTEXT OF THE COVID-19 PANDEMIC: AN ANALYSIS FROM THE ARIMA X-13 SEATS SEASONAL ADJUSTMENT METHOD

**ABSTRACT:** The year of 2020 can be considered a turning point in function of the shock of the Covid-19 pandemic and its impacts on the various sectors of the Brazilian economy. In order to control and prevent the proliferation of viruses, it is common that governments all over the world adopt measures of social isolation, or that lead to a partial paralysis of two sectors of the economy, resulting in a severe retraction of economic activity. The purpose of this work was to investigate and characterize the context of the Covid-19 pandemic, or the seasonal behavior of macroeconomic series in two industrial, commercial and service sectors, at the same time as the non-IBC-br express activity level. For this, we used the ARIMA X-13 SEATS seasonal adjustment analytical method, seeking to identify the Autoregressive (AR) and Moving Average (MA) processes, also two possible calendar effects such as days of the week, commemorative data and os outliers level shift (LS) or additive outliers (AO) associated with possible impacts related to the Covid-19 pandemic. The results show significant effects of two outliers in relation to the pandemic on the sectors analyzed and the level of economic activity in Brazil. In this sense, the most relevant negative effects were identified, mainly, not in the second quarter of 2020.

**Keywords:** Pandemic; Exogenous shocks; Sectors of the Economy; Arima model.

Data da submissão: 13-02-2021

Data do aceite: 30-12-2021

## INTRODUÇÃO

O ano de 2020 foi marcado quase que exclusivamente pela pandemia da Covid-19 e seus efeitos adversos sobre a dinâmica de economia em todo o mundo. Oficialmente, o mês de março marca o início do

<sup>1</sup> Professor Adjunto do Departamento de Economia da URCA e Doutor em economia aplicada pela UFBA.

problema, especificamente, o Brasil esteve entre os países com os maiores números de casos e mortes, o que levou a definição de um conjunto de medidas precaucionais mais rígidas de controle por parte das autoridades.

De acordo com Dell'Araccia *et al.* (2020), o início da pandemia pareceu impor aos governos um *trade-off* com o objetivo de conter o contágio da doença, a partir da imposição de medidas, como a quarentena e o isolamento social, que impactaram rapidamente sobre o nível de atividade econômica. Assim, inevitavelmente tais medidas a fim conter o avanço e o contágio da doença ocasionaram restrições parciais sobre a economia com consequente retração do produto interno bruto e da produção em vários setores. Neste contexto, o problema de saúde pública se transformou também, em um problema econômico e social, na medida em que se observam impactos de curto prazo sobre a dinâmica da economia, sobretudo, nos níveis de produto e emprego.

Diante deste cenário, a expectativa *a priori* de crescimento da economia brasileira de 2,3% para o ano de 2020 reverteu-se rapidamente, e já no segundo trimestre registrou-se a maior queda da atividade econômica desde 1980, com o recuo do produto em 9,7% em comparação ao primeiro trimestre do corrente ano, puxado principalmente pela retração da indústria (-12,7%), comércio (-13%) e serviços (-9,7%). Assim, de acordo com Cavalcanti *et al.* (2020), o comportamento negativo do PIB no segundo trimestre reflete a forte retração do nível de atividade econômica no mês de abril.

Destarte, a maioria das séries macroeconômicas geralmente apresenta algum comportamento sazonal, que se caracteriza como movimento intra-anual e de mesma periodicidade, que ao não serem tratadas poderão levar à análises enviesadas sobre a dinâmica de uma série temporal ao longo do tempo. Posto isto, o presente trabalho teve por objetivo não identificar efeitos causais, mas investigar e caracterizar as irregularidades decorrente dos efeitos da pandemia sobre a componente sazonal dos setores da indústria, comércio, serviços e do nível agregado de atividade referenciada através do IBC-*br*. O estudo do comportamento das séries a partir do ajuste sazonal permite comparações mais eficientes ao longo do tempo, especialmente, quando ocorrem choques inesperados na economia.

Neste sentido, para fins de análise empírica e identificação das irregularidades sobre as variáveis consideradas, utilizou-se o método de ajuste sazonal ARIMA X-13 SEATS desenvolvido pelo US Census Bureau<sup>2</sup>, que apresenta um conjunto de vantagens no processo de dessazonalização de séries temporais. Entre estas, o método propõe *a priori* um pré-ajuste e a correção das séries, antes de ser efetivamente realizado o ajuste sazonal.

Os resultados apontam efeitos negativos e significativos da pandemia da Covid-19 sobre os setores investigados e o nível de atividade explicitado pelo IBC-*br*. Mais precisamente, o aprofundamento dos impactos da pandemia ocorre, sobretudo, entre os meses de março e abril do ano de 2020. Por outro lado, nos meses de junho e julho é possível identificar um ensaio de uma possível recuperação no curto prazo.

Além da introdução e conclusão, este trabalho está dividido em mais três seções. Na primeira, foi exposta a revisão da literatura e trabalhos que utilizaram a metodologia para os mesmos fins. Na segunda, será apresentada a metodologia empregada neste estudo e, por fim, na última seção serão expostos os principais resultados empíricos com base no modelo ARIMA X-13 SEATS.

## 2. REVISÃO DA LITERATURA

### 2.1 ABORDAGENS E MÉTODOS DE AJUSTE SAZONAL

A maioria das séries macroeconômicas no Brasil apresenta um considerável grau de sazonalidade, entre estas, a das taxas de desemprego, dos setores da economia, índices de preços, moeda e crédito e a do produto interno bruto (PIB). No entanto, estas mesmas séries, estão sujeitas a fortes irregularidades como choques inesperados e mudanças estruturais, o que requer cautela e parcimônia nas análises de suas componentes sazonais.

Portanto, diversos métodos podem ser utilizados para a realização do ajuste sazonal em séries temporais. Entre os mais importantes, destaca-se: *Dummies* Sazonais, Holt- Winters, Modelos Estruturais, Dainties, TRAMO/SEATS e o ARIMA X13. Cada um destes métodos apresenta vantagens, desvantagens e

---

<sup>2</sup> Órgão dos EUA responsável por mensurar e divulgar dados da economia americana. Ademais, é responsável pelo método ARIMA X-13 em conjunto com o Bank of Spain.

sua aplicação pode ser direcionada a tratamentos específicos conforme seja o comportamento da série que se deseja avaliar.

A aplicação do método de variáveis *dummies* sazonais em modelo de regressão torna-se adequado em casos onde a série apresenta tendência sazonal determinística<sup>3</sup>, o que na realidade não se observa na maioria dos casos. Contudo, de acordo com Jorgenson (1964), por este método, consideram-se combinações lineares das componentes determinísticas sazonais e não sazonais, onde a partir do método de mínimos quadrados ordinários (MQO) podem-se obter os parâmetros de tendência e sazonalidade. Por outro lado, Lopes (2001), observa inconsistências neste método ao não se levar em consideração a presença de raízes unitária sazonais, o que frequentemente pode gerar a resultados enviesados.

Outra opção para a realização do ajuste sazonal pode ser verificada na definição dos chamados modelos estruturais ou modelo de espaço de estados. De acordo com Harvey (1989), este tipo de modelagem aplicado às séries univariadas, parte do pressuposto de que as mesmas podem ser decompostas em suas componentes determinísticas não observáveis como nível, tendência e sazonalidade a partir de equações de medida e de estado ou transição. Isto significa que no conjunto destas equações, as variáveis exploratórias e os parâmetros estimados são, respectivamente, função do tempo e variam ao longo do mesmo. Uma vantagem destes modelos é que eles permitem a realização dos cálculos de forma recursiva convergente aos métodos computacionais, o que permite grande flexibilidade e alterações no sistema por trás da modelagem. Ademais, este tipo de método, permite inferências com observações faltantes, podendo ser adequado ao tempo contínuo.

Outro método bastante utilizado no processo de dessazonalização é o de Holt-Winters, tratando-se de uma extensão do modelo de Holt (1957) desenvolvido por Winters (1960), quando as séries apresentam as componentes de tendência linear e sazonalidade, dividindo-se em modelos aditivo e multiplicativo. Segundo Morettin e Tolo (1987), este método se baseia em três equações com distintas constantes de suavização associadas ao nível, tendência e sazonalidade da série.

Ainda neste sentido, Ferreira, Gondim e Mattos (2015), mostram que a principal desvantagem do método de Holt-Winters está na dificuldade em se estudar estatísticas descritivas básica como, por exemplo, a média e a variância da previsão que por consequência determinam a estrutura do intervalo de confiança. Na mesma direção, observam-se dificuldades na definição de parâmetros importantes como as constantes de suavização. Em relação a isto, Gelper *et.al* (2010), apresentam mecanismos de solução de escolha dos parâmetros utilizando critérios como o erro médio, erro absoluto médio e erro quadrático médio. Por outro lado, Rasmussen (2004), utiliza o erro quadrado médio como mecanismo para minimizar e solucionar o método para estimação dos parâmetros que otimizam as previsões com base nos valores iniciais.

Na década de 1970, a Comunidade Econômica Europeia (E.C.C), desenvolveu o método de ajuste sazonal de Dainties, o que seria uma atualização do método Seabird<sup>4</sup>. Partindo-se da hipótese de que as componentes da série não podem ser modeladas totalmente, o método se baseia em modelos de regressão com janela móvel. De acordo com Fok *et.al* (2005), este método se ajusta bem aos dados que apresentam padrões de sazonalidade determinística.

Não obstante, o TRAMO-SEATS<sup>5</sup>, são programas que executam atividades conjuntamente, mas com atribuições específicas na realização do ajuste sazonal. Assim, o TRAMO prepara os dados e se necessário realiza a sua transformação, realizando o pré-ajuste, a correção e identificação de *outliers* e efeitos determinísticos, além de escolher o modelo ARIMA que melhor se ajusta aos dados. Além do mais, o SEATS decompõe a série e realiza de fato o ajuste sazonal. Na execução da opção automática do método, este se baseia no procedimento de Hannan e Rissanen (1982), onde a seleção do modelo ARIMA mais adequado ocorre por meio do critério BIC.

Contudo, atualmente um dos métodos de ajuste sazonal mais utilizado em escala global é o ARIMA X-13 SEATS. A sua origem está no desenvolvimento por parte do US Census Bureau em 1960 do ARIMA X-11, que posteriormente foi aprimorado pelo Statistic Canadá na década de 1980. Os avanços neste, deu origem a um programa mais sofisticado denominado de ARIMA X-12 (FINDLEY, *et.al* (1988)). Segundo Ferreira, Gondim e Mattos (2015), este programa inova ao incorporar variáveis regressoras que podem afetar

<sup>3</sup> Apresentam padrão sazonal regular e estável ao longo do tempo.

<sup>4</sup> Método desenvolvido por Bongard e Mesnage, no Statistical Office of the European Communities na década de 1960.

<sup>5</sup> Ambos os programas foram desenvolvidos por Victor Gomez e Agustin Maravall do Banco da Espanha. TRAMO (Time Series Regression with ARIMA Noise, Missing Observations and Outliers) e SEATS (Signal Extraction in ARIMA Time Series)

e gerar irregularidades sobre a dinâmica de uma série como, por exemplo, feriados, dias úteis semanais e a presença de *outlier*, que necessitam de tratamento.

O ARIMA X-13 SEATS representa a versão mais recente na sequência do desenvolvimento dos programas para a realização do ajuste sazonal. Este surgiu no ano de 2012, a partir da união do ARIMA X-13 e o TRAMO-SEATS. O programa propõe uma série de inovações a partir de um pré-ajuste através de um RegARIMA, que é uma combinação de um modelo de regressão linear com um modelo ARIMA. Este inclui variáveis regressoras ou controles como feriados, *working days* (Dias úteis), ano bissexto, *trading days* (Número de dias da semana em um mês) e *outliers*.

Destaca-se que o método de dessazonalização pode ser realizado pelos métodos direto ou indireto, onde o primeiro é aplicado diretamente sobre a série agregada e desagregada e o segundo ocorre indiretamente na série desagregada. Conforme apontaram Pedersen e Faeste (2006), há casos em que os dois métodos podem coincidir, quando não houver a necessidade de pré-ajuste e a decomposição do modelo for puramente aditiva. Ainda de acordo com os autores, o pesquisador deve seguir dois critérios de decisão sobre qual método escolher. O primeiro se refere ao processo de suavização das séries no sentido de que o ajuste esteja válido. O segundo critério complementar, observa que dada à dificuldade da análise mensal dos ajustes, estes devem ser o mais suave possível.

### 3. METODOLOGIA

A literatura que trata do ajuste sazonal de séries de tempo apresenta um conjunto de métodos alternativos de remoção da sazonalidade como, por exemplo, os métodos de *dummies* sazonais desenvolvido por Zellner (1979) e Aguirre e Aguirre (1991), o de Holt-Winters por Rasmussen (2004), além dos modelos estruturais de Plosser (1979) e Harvey e Shepard (1993). Contudo, esta pesquisa foi desenvolvida utilizando especificamente o método ARIMA X13-SEATS, desenvolvido de forma seminal por Shiskin *et al* (1967) no *U.S. Bureau of the Census* a partir da introdução do programa de ajuste sazonal X-11. A atual versão do método, denominado de X-13 ARIMA-SEATS é um *mix* aperfeiçoado entre o ARIMA X-12 e o TRAMO/SEATS.

Destarte, o método de ajuste sazonal ARIMA X-13 funciona em duas etapas, uma denominada de pré-ajuste e a outra chamada de fase de ajuste sazonal. A fase de pré-ajuste inclui a correção da série a partir da identificação de eventos atípicos que devem ser tratados antes do procedimento de ajuste. Ademais, é nesta fase que se define o modelo de decomposição com base nos modelos aditivo e multiplicativo. Assim, ambos os modelos, respectivamente, podem ser assim representados:

$$Y_t = T_t + S_t + C_t + I_t \quad (1)$$

$$Y_t = T_t \cdot S_t \cdot C_t \cdot I_t \quad (2)$$

Nas equações (1) e (2),  $Y_t$  representa a série univariada,  $T_t$  é a componente de tendência,  $S_t$  é a sazonalidade da série,  $C_t$  é o componente de calendário ou ciclo e  $I_t$  se refere a componente irregular. O modelo aditivo (1) deriva-se a partir da subtração dos componentes de calendário e sazonais da série original. Por outro lado, no modelo multiplicativo (2), os picos associados aos efeitos sazonais crescem à medida que o nível da série aumenta. Neste caso, as séries com sazonalidade e ajustadas pelo calendário são derivadas da razão entre a série original e a multiplicação das componentes sazonais ( $S_t$ ) e de calendário ( $C_t$ ). Portanto, o programa SEATS parte da hipótese de que os componentes não observados são aditivos e, por esta razão, o modelo multiplicativo não pode ser aplicado. Neste sentido, o ajuste é feito usando um modelo log aditivo da seguinte forma:

$$\log(Y_t) = \log(T_t \cdot S_t \cdot C_t \cdot I_t) \quad (3)$$

Resolvendo a equação (3), tem-se:

$$\log(Y_t) = \log(T_t) + \log(S_t) + \log(C_t) + \log(I_t) \quad (4)$$

Não obstante, uma inspeção inicial do gráfico da série pode apontar padrões do seu comportamento ao longo do tempo e auxiliar na escolha do modelo de decomposição. Contudo, uma etapa fundamental na fase de pré-ajuste é a identificação do modelo ARIMA para séries sazonais. Seguindo o método de estimação via programa TRAMO<sup>6</sup>, definido por Maravall *et.al* (2014), considerando o seguinte vetor de observações  $Y = (Y_{t1}, \dots, Y_{tm})$ , onde  $0 < t1 < \dots < tm$ , pode-se estimar a seguinte regressão:

$$Y_t = \psi_t' \beta + v_t \quad (5)$$

Onde  $\psi_t'$  é o conjunto de  $n$  variáveis na regressão,  $\beta'$  é o vetor de coeficientes estimados e  $v_t$  segue um processo ARIMA. Generalizado o modelo, chega-se a seguinte especificação:

$$\phi(B)\Phi(B^S)(1-B)^d(1-B^S)^D Y_t = \theta(B)\Theta(B^S)\varepsilon_t \quad (6)$$

Em que a série original é dada por  $Y_t$ ,  $B^S$  é o operador de defasagem com frequência sazonal  $S$  para séries mensais ou trimestrais e  $\phi(B)$  é um operador autoregressivo (AR) de ordem ( $p$ ). O operador regular de médias móveis (MA) é representado por  $\theta(B)$ . Ademais,  $\Phi(B)$  e  $\Theta(B)$  são, respectivamente, os operadores sazonais autoregressivo (AR) de ordem ( $p$ ) e de médias móveis (MA) de ordem ( $q$ ). Por fim, o resíduo do modelo  $\varepsilon_t$  segue um processo ruído branco não autocorrelacionado.

Como o processo de identificação do modelo tem por objetivo determinar as ordens dos operadores AR e MA, para um modelo com dados trimestrais e ordem de diferenciação ( $d$  e  $D$ ), tem-se os componentes  $(p, d, q)(P, D, Q)_4$  onde, respectivamente, os primeiros termos são as componentes da parte não sazonal e o segundo representa a parcela sazonal do modelo. Portanto, esta é a fase de identificação do modelo, pois a ordem e os respectivos coeficientes estimados apresentam estreita relação com o processo de decomposição que gera os filtros sazonais e de tendência, definindo o mecanismo de seleção automática dos efeitos de calendário e de *outliers*.

Em se tratando dos efeitos específicos que afetam a dinâmica das séries, os efeitos de calendário devem ser estimados e expurgados da série original, visto que impactam a eficiência do processo de decomposição. Neste caso, os efeitos determinísticos denominados de regressores de calendário, explicitam as mudanças na estrutura dinâmica do calendário. Os efeitos dos dias úteis (*Trading days*) são definidos a partir de seis regressores, que capturam a diferença entre o número de cada dia da semana e o número de domingos existentes em um mês. Ademais, os efeitos dos dias úteis (*Working days*), são estimados através de um único regressor, comparando o conjunto de dias úteis com o conjunto de dias que compõe o final de semana (sábado e domingo).

Quanto aos efeitos da data referente ao período de páscoa (*Easter date*) que se alternam a cada ano geralmente entre os meses de março e abril, o regressor busca captar a duração do impacto da páscoa, calculando os dias que caem antes deste período nos meses de março e abril, de acordo com a seguinte expressão:

$$e_t = \frac{W_t}{w} - \bar{W} \quad (7)$$

Na expressão (7), o número dias que caem no trimestre  $t$  é dado por  $W$ , enquanto que a proporção de dias no trimestre no longo prazo é representada por  $\bar{W}$ . Como usualmente  $\bar{W} \cong 0,5$ , isto implica que a distribuição dos efeitos dos dias que fazem parte do período da páscoa é simétrica entre dois momentos.

Posto isto, na etapa de especificação do modelo faz-se necessária à observação e identificação dos efeitos de *outliers* através do método desenvolvido por Tsay (1986) e Chen e Liu (1993). Estes são eventos atípicos relacionados aos choques que impactam a qualidade do ajuste em função de exercem efeitos sobre a componente sazonal da série. Estes são distribuídos em *additive outlier(AO)* que afeta uma observação específica na série, e o *level shift outlier(LS)*, cujo efeito gera uma alteração no nível da série.

<sup>6</sup> O TRAMO executa estimações de modelos ARIMA que podem ser identificado automaticamente na presença de *outliers*.

<sup>7</sup> Inclui os parâmetros de intervenção e *outliers* estimados por máxima verossimilhança.

Com o objetivo de avaliar a qualidade do ajuste sazonal proporcionado pelo modelo, em princípio, são realizados os testes de Shapiro para identificação de normalidade nos dados e o de Box-Ljung para autocorrelação. Além disso, a verificação da existência da sazonalidade pode ser feita através do teste *QS-Statistic*, cujas hipóteses são:

**Hipótese Nula  $H_0$ :** Não há evidência de sazonalidade na série;

**Hipótese Alternativa  $H_1$ :** há evidência de sazonalidade na série

De acordo com Ferreira, Gondim e Mattos (2015), o teste *QS-Statistic* é aplicado sobre a série original, nas séries dessazonalizada e corrigida por *outlier*, além dos resíduos e componente irregular do modelo na etapa de pré-ajuste. A evidência de um ajuste com boa aderência pode ser apontando quando se identifica a presença de sazonalidade na série original corrigida por *outliers*, descartando-se o mesmo comportamento em relação às demais. A tabela 1 descreve em linhas gerais os códigos e as séries sobre as quais o teste de sazonalidade é aplicado.

**Tabela 1.** *QS-Statistic* e Séries Temporais disponíveis para o diagnóstico.

Código	Série
<i>qsori</i>	Série Original
<i>qsorievadj</i>	Série corrigida por <i>outliers</i>
<i>qsrsd</i>	Resíduos do modelo SARIMA
<i>qssadj</i>	Série com ajuste sazonal
<i>qssadjevadj</i>	Série ajustada e corrigida por <i>outliers</i>
<i>qsirr</i>	Componente irregular
<i>qsirrevadj</i>	Componente irregular corrigida <i>outliers</i>

Fonte: Ferreira, Gondim e Mattos (2015)

Por fim, a análise visual dos gráficos gerados do *SI ratio* e de comparação das séries ajustadas e originais são relevantes e informativos no sentido de apontarem evidências sobre a dinâmica da sazonalidade em cada série analisada. Portanto, a visualização do *SI ratio*, mostra o quão adequado foi à decomposição da série a partir da comparação entre o comportamento da série sazonal e os componentes irregulares e sazonais em sua forma agregada. Por aqui, os fatores sazonais devem seguir a trajetória das componentes sazonais irregulares agregadas, de forma que a componente irregular não deve dominar a *SI*.

#### 4. ANÁLISE DOS RESULTADOS

Para fins de análise e inferência consideraram-se neste trabalho as séries temporais de dados dos setores da indústria de bens intermediários, comércio varejista e serviços, além da série do índice de atividade econômica do BACEN (*IBC-br*<sup>8</sup>). Todas as séries em nível apresentam um conjunto de informações com distribuição mensal que se estende de janeiro de 2011 a agosto de 2020, totalizando cento e quatro observações. Os dados foram obtidos a partir da pesquisa mensal por setor no IBGE, com exceção da série do *IBC-br* extraída no sistema de séries temporais do Banco Central do Brasil.

A tabela 2 apresenta a primeira etapa da análise dos resultados com a descrição das principais estatísticas das séries consideradas no estudo. Na primeira coluna da tabela estão dispostas as variáveis e nas demais, respectivamente, encontram-se os valores para média, mediana, desvio-padrão e a volatilidade dos setores em relação ao nível da atividade econômica. Nota-se que a média e a mediana entre os setores apresenta valores relativamente aproximados, enquanto que para o *IBC-br*, o valor médio foi superior em comparação aos demais, justificada pela diferença da base de cálculo para a média e mediana de cada setor.

**Tabela 2.** Estatísticas descritivas das Séries.

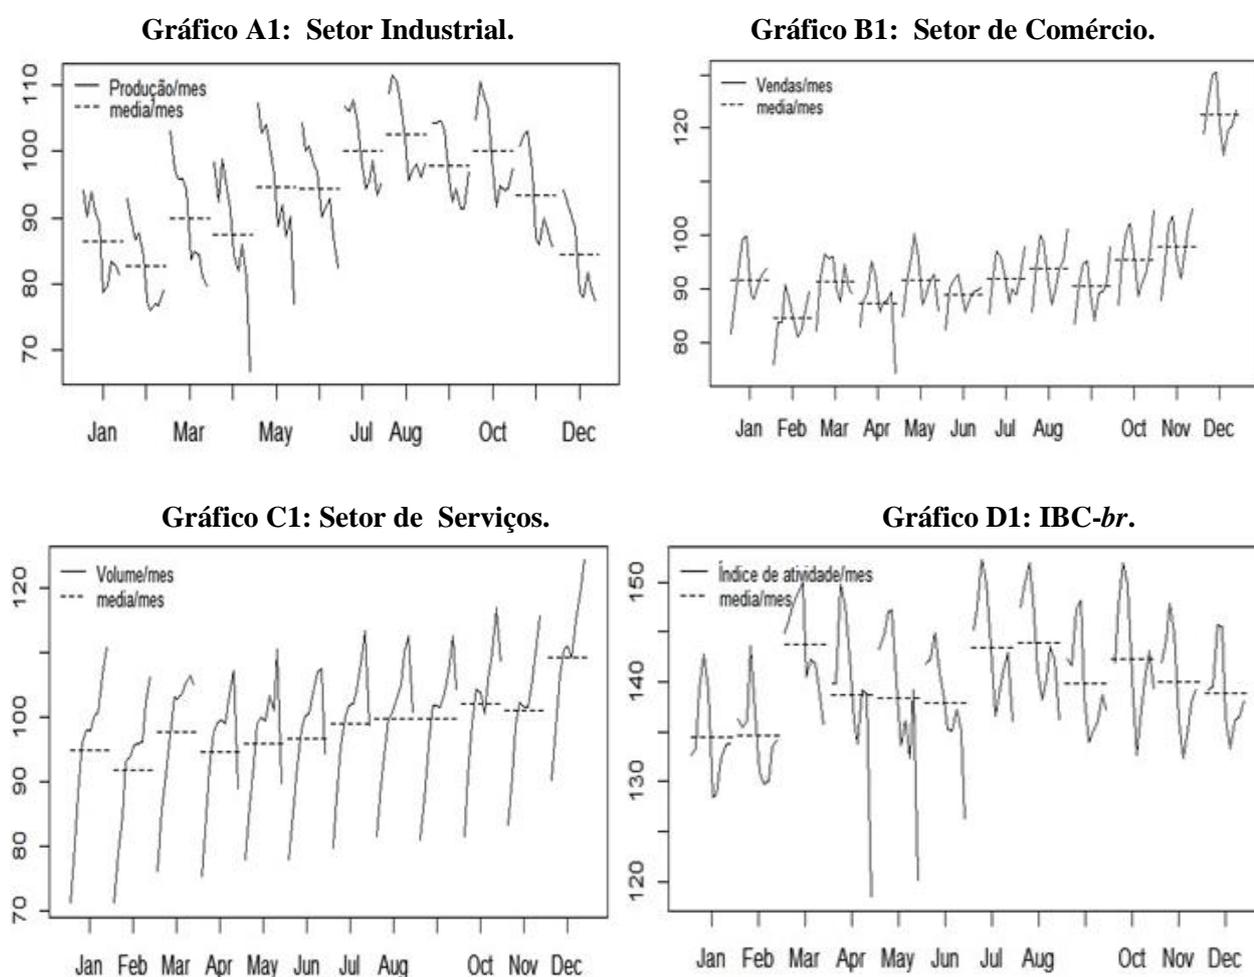
Variável	Média	Mediana	Desvio-Padrão	Volatilidade Relativa ao <i>IBC-br</i>
<i>IBC-br</i>	139.7	139.3	6.290	1.000
Indústria	92.95	94.00	9.308	1.499
Comércio	93.68	91.55	10.135	1.611
Serviços	98.48	100.05	10.401	1.653

Fonte: Elaboração Própria.

<sup>8</sup> Índice mensal que indica a tendência do PIB a partir da avaliação dos setores da economia brasileira e da produção agregada de bens e serviços.

O desvio-padrão absoluto disposto na terceira coluna reflete a dispersão dos dados em relação a cada valor médio. Como se observa, o desvio-padrão de 9.308 para indústria aponta a menor dispersão entre todas as séries, enquanto que os desvios para os setores de comércio e serviços foram aproximados e mais dispersos em comparação a indústria. Ademais, a volatilidade cíclica de cada setor em relação ao IBC-*br* verificada na quarta coluna, denota uma maior flutuação do crescimento médio dos setores de comércio e serviços em relação ao nível de atividade da economia, o que implica uma maior sensibilidade dos mesmos às mudanças da trajetória de crescimento da economia brasileira.

Posto isto, avaliação da dinâmica das séries por setores da economia e a identificação de possíveis comportamentos sazonais, podem ser visualizados nos gráficos da figura 1 a partir da conjunção da média (linhas horizontais) e a variação dos dados ao longo dos meses. Como se observa, as mudanças nas médias e variações de todas as séries por setor apontaram indícios de sazonalidade. Especificamente, os setores de comércio e serviços, respectivamente, os gráficos B1 e C1 apresentaram mudanças na média, principalmente, nos meses de outubro, novembro e dezembro em função da proximidade das festas de final de ano que impactam positivamente sobre as vendas e a prestação de serviços.



**Figura 1.** Comportamento das Séries por Setores da Economia em Nível.

Fonte: Elaboração Própria.

Ainda em relação à figura 1, aparentemente o setor industrial apresenta características de sazonalidade, visto que entre os meses de maio e outubro observa-se o crescimento do índice, seguido de uma retração nos meses subsequentes que se repete a cada ano. Por outro lado, o nível de atividade econômica expresso pelo IBC-*br* apontou um índice com média variável e sazonal ao longo do tempo. A expansão do indicador no mês de março foi seguida por uma queda entre os meses de abril e junho com consequente recuperação em julho e agosto.

Assim, embora o comportamento das séries na figura 1 apontam indícios de sazonalidade, uma identificação mais robusta só é possível através de testes estatísticos complementares. Neste aspecto, segundo Ferreira e Mattos (2017), faz-se necessária a identificação da presença de sazonalidade nas séries que estão

sendo avaliadas, visto que as mesmas não podem ser ajustadas sem que haja evidências da presença do comportamento sazonal. Neste caso, recomenda-se a realização do teste *QS-Statistic* cuja hipótese nula é de que não há evidências de sazonalidade nas séries. Logo, o objetivo do teste é inferir a presença de padrões sazonais sobre as séries originais, corrigida por *outliers*, séries ajustadas, componente irregular e o resíduo do modelo ARIMA, de acordo com a tabela 3.

**Tabela 3.** Teste *QS* de sazonalidade para as Séries.

<b>Série Completa</b>	<b>Indústria <i>QS statistic</i></b>	<b>Comércio <i>QS statistic</i></b>	<b>Serviços <i>QS statistic</i></b>	<b>IBC-br <i>QS statistic</i></b>
Original	113.589 (0.000)	178.135 (0.000)	142.810 (0.000)	77.484 (0.000)
Corrigida por <i>Outliers</i>	165.315 (0.000)	192.613 (0.000)	180.215 (0.000)	144.657 (0.000)
Resíduos do Modelo	0.332 (0.846)	0.0038 (0.998)	0.000 (1.000)	0.023 (0.988)
Séries com Ajuste Sazonal	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)
Ajuste Sazonal Corrigida por <i>Outliers</i>	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)
Componente Irregular	0.000 (1.000)	0.012 (0.993)	0.000 (1.000)	0.091 (0.955)
Componente Irregular Corrigida por <i>Outliers</i>	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)
<b>Últimos Oito anos</b>	<b><i>QS statistic</i></b>	<b><i>QS statistic</i></b>	<b><i>QS statistic</i></b>	<b><i>QS statistic</i></b>
Original	81.942 (0.000)	137.070 (0.000)	115.491 (0.000)	59.093 (0.000)
Corrigida por <i>Outliers</i>	120.963 (0.000)	147.994 (0.000)	144.464 (0.000)	112.787 (0.000)
Resíduos do Modelo	0.288 (0.865)	0.000 (1.000)	0.000 (1.000)	0.007 (0.996)
Séries com Ajuste Sazonal	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)
Ajuste Sazonal Corrigida por <i>Outliers</i>	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)
Componente Irregular	0.000 (1.000)	0.009 (0.999)	0.000 (1.000)	0.096 (0.952)
Componente Irregular Corrigida por <i>Outliers</i>	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)	0.000 (1.000)

Fonte: Elaboração Própria, 2020.

Como a série temporal apresenta observações para mais de oito anos, o teste é aplicado na série completa e nos últimos oito anos que a compõem. Conforme resultados reportados na tabela 3, há evidências com um nível de 95% de confiança da presença de sazonalidade em todas as séries originais e corrigidas por *outlier*. Por outro lado, não foram encontradas evidências do comportamento sazonal nas séries com ajuste sazonal, ajustada e corrigida por *outlier*, nos resíduos do modelo e nas componentes irregulares, o que sugere um ajuste sazonal adequado. Neste sentido, como forma complementar, na figura A1 do anexo A deste trabalho, estão expostos os gráficos que comparam a agregação dos componentes sazonais e irregulares (SI ratio) aos fatores sazonais (FS). Como explicitado, a SI ratio acompanha os FS em todos os casos, indicando a estabilidade das componentes irregulares, exceto na presença dos *outliers* identificados.

Posto isto, uma etapa importante na fase do pré-ajuste é a estimação dos modelos ARIMA para cada série, com a identificação eventos atípicos relacionados aos efeitos de calendário<sup>9</sup> e os *outliers level shift* (LS) ou *additive outliers* (AO), decorrentes dos choques que afetam a economia. Neste sentido, um *additive outliers* reflete uma alteração exógena em uma única observação no conjunto de dados, mas não afeta as observações subsequentes. Por outro lado, um *outliers level shift* (LS) expressa uma alteração no nível médio dos dados, afetando observações subsequentes, o que pode gerar efeitos persistentes ao longo da série.

Na tabela 4 estão expostos os resultados dos modelos estimados para cada série temporal no pré-ajuste. Na primeira coluna têm-se os coeficientes (AR) autoregressivo e de médias móveis (MA), distribuídos em sazonais e não sazonais. Na mesma coluna se encontram os efeitos de calendário e os parâmetros dos *outliers*, além das estatísticas *QS*, Box-Ljung e de Shapiro que, respectivamente, indicam as hipóteses de sazonalidade,

<sup>9</sup> Referem-se aos feriados, dias úteis da semana, efeitos de páscoa, entre outros.

não autocorrelação e distribuição normal dos resíduos. Como observado em todos os modelos, os testes apontam ao nível de 5%, que não há evidência de autocorrelação e os resíduos são normalmente distribuídos. Além disso, não houve a necessidade de realizar nenhuma transformação no conjunto dados e consideraram-se somente os parâmetros com nível de significância entre 1% e 10%.

Não obstante, observam-se efeitos AR-Não Sazonal negativo apenas para o IBC-*br*, enquanto que a indústria e comércio são afetados pelo MA-Não Sazonal. No entanto, todas as séries contem efeitos MA-Sazonal significativos. Como se observa, os dias úteis da semana impactam positivamente a indústria e o nível de atividade econômica. Contudo, não foram identificados efeitos significativos de dias específicos da semana sobre estas mesmas séries.

**Tabela 4.** Modelos Estimados para cada Série no Pré-Ajuste.

<b>Coefficientes</b>	<b>Indústria</b>	<b>Comércio</b>	<b>Serviços</b>	<b>IBC-br</b>
	<b>Parâmetros</b>	<b>Parâmetros</b>	<b>Parâmetros</b>	<b>Parâmetros</b>
AR- Não Sazonal				-0.316***
MA- Não Sazonal	0.340***	0,245**		
MA-Sazonal	0.425***	0.189 *	0.633 ***	0.997***
Dias úteis da Semana	0.202***			0.352***
Outros dias da semana				
Terça-feira			0.539**	
Sexta-feira		0.476*	0.687***	
Sábado		0.587**	-0.535**	
Efeito da Páscoa	-1.927***	2.999**		-1.299*
<b>Coefficientes para os Outliers</b>	<b>Parâmetros</b>	<b>Parâmetros</b>	<b>Parâmetros</b>	<b>Parâmetros</b>
Março 2020			-7.699*** (AO)	-8.824*** (AO)
Abril 2020	-11.503*** (LS)	-15.970*** (AO)	-22.333*** (LS)	-21.476*** (LS)
Maio 2020		-7.837*** (AO)		
Junho 2020				8.002*** (LS)
Julho 2020	10.646*** (LS)			
<b>ARIMA</b>	(0 1 1)(0 1 1)	(0 1 1)(0 1 1)	(0 1 0)(0 1 1)	(1 1 0)(0 1 1)
<b>Teste QS</b>	0,00	0,00	0,00	0,00
<b>Teste Box-Ljung</b>	26.06	15.34	19.50	34.09
<b>Teste Shapiro</b>	0.986	0.987	0.980	0.987

Significância dos Parâmetros \*\*\*1% - \*\*5% - \*10%.

Fonte: Elaboração Própria, 2020.

Ainda em relação a tabela 4, quando se olha para as atividades associadas aos setores de comércio e serviços, este são afetados por dias específicos da semana. Por exemplo, o parâmetro positivo associado ao dia de terça feira, indica impactos positivos deste dia sobre o setor de serviço. Contudo, podem-se destacar os efeitos dos dias de sexta-feira e sábado sobre estas atividades econômicas. O primeiro, afeta positivamente ambos os setores, enquanto que o segundo impacta negativamente o setor de serviços. Além disso, o período de páscoa apresentou um parâmetro estimado positivo e significativo em relação ao comércio, o que significa que o período estimula às atividades comerciais.

Os parâmetros estimados e relacionados aos *outliers* captaram os efeitos das medidas de isolamento social e da paralisação parcial da economia em decorrência da pandemia da covid-19. Todos os parâmetros apresentaram significância estatística ao nível de 5% e estão distribuídos entre *outliers level shift* (LS) e *additive outliers* (AO).

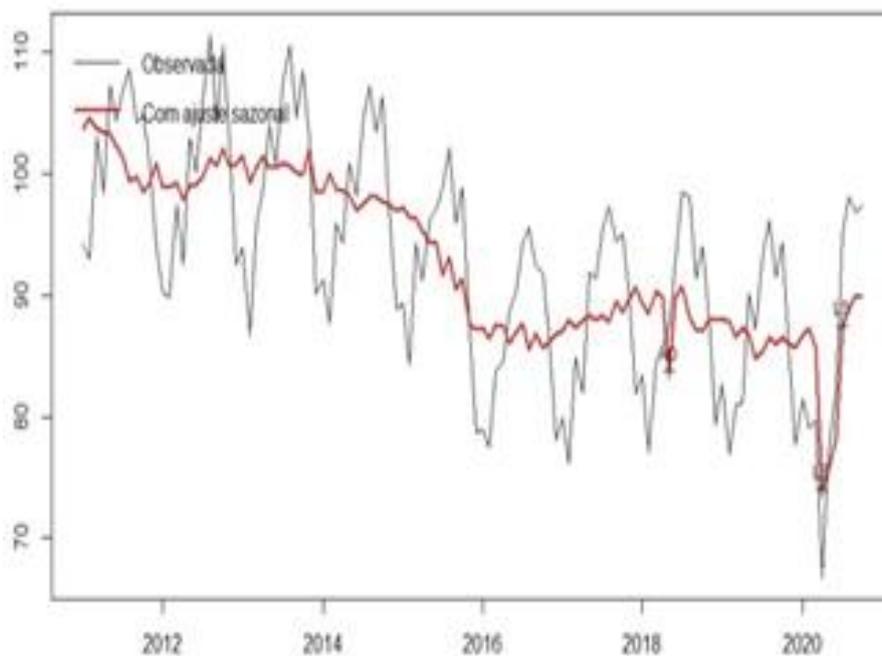
Neste sentido, a identificação de parâmetros *additive outliers* (AO) ainda no mês de março impactando negativamente o setor de serviço e o nível de atividade econômica expresso no IBC-*br*, já apontavam os efeitos iniciais da pandemia sobre a economia brasileira. Contudo, os efeitos mais expressivos ocorreram no terceiro trimestre do ano de 2020, mais precisamente no mês de abril. Nota-se que os setores da indústria, os serviços e a o nível de atividade econômica (IBC-*br*) apresentaram *outliers level shift* (LS) significativos, o que implica uma mudança no nível médio da série, afetando observações subsequentes nos dados de forma persistente.

De fato, todos os setores da economia foram fortemente afetados neste período. De acordo com o IBGE (2020), a retração do PIB da economia foi de aproximadamente 9,7% em relação ao primeiro trimestre do mesmo ano, a indústria retraiu 12,3%, o comércio 13,0% e os serviços reduziram suas atividades em 9,7%. Tal cenário adverso e os efeitos da pandemia da covid-19 sobre o desempenho da economia foram captados pelos parâmetros estimados para a indústria, comércio, serviços e IBC-br que apresentaram, respectivamente, os valores de -11.503 (LS), -15.970 (AO), -22.333(LS) e -21.476 (LS).

Por outro lado, nos meses de junho e julho foram identificados parâmetros *outliers* com efeitos positivos e significativos que sinalizaram uma mudança no nível médio (LS) das séries do setor industrial e do indicador de atividade econômica (IBC-br), com respectivos valores estimados de 10.646 (LS) e 8.002(LS). Estes, refletiram o ensaio de uma recuperação da economia no terceiro trimestre frente à flexibilização do isolamento social e a reabertura parcial das atividades econômicas, explícitos no crescimento da indústria de 14,8%, do setor de serviços em 6,3% e da economia em 7,7%.

Ao avaliar as séries, destacam-se os efeitos da pandemia da Covid-19 através da identificação dos *outliers level shift* (LS) e *additive outliers* (AO), que são os mesmos estimados nos modelos ARIMA na fase de pré-ajuste. De acordo com os gráficos na figura 2, o segundo trimestre do ano de 2020 foi o período de maior impacto negativo sobre os setores avaliados e o nível de atividade econômica. O setor de serviços (Gráfico C2) e o IBC-br (Gráfico D2) foram os primeiros a serem afetados, especialmente, entre os meses de março e abril, enquanto que a fase de maior deterioração sobre a indústria e o comércio, respectivamente, gráficos A2 e B2 ocorreu principalmente no mês de abril. Contudo, ressalta-se a presença de *outliers level shift* (LS), no nível de atividade econômica e nos setores da indústria e serviço, o que indica uma mudança de nível da série destes setores.

**Gráfico A2: Setor industrial.**



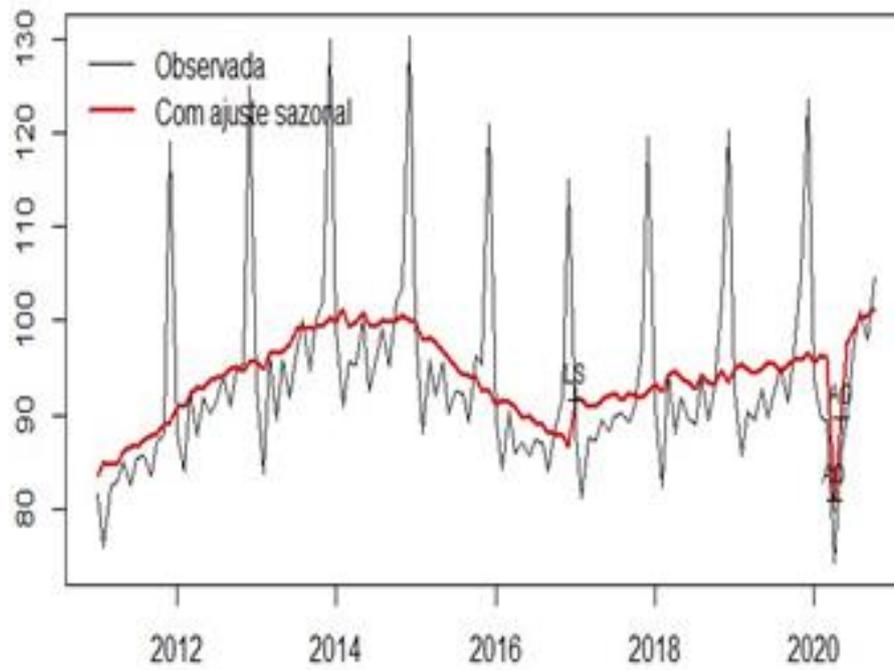
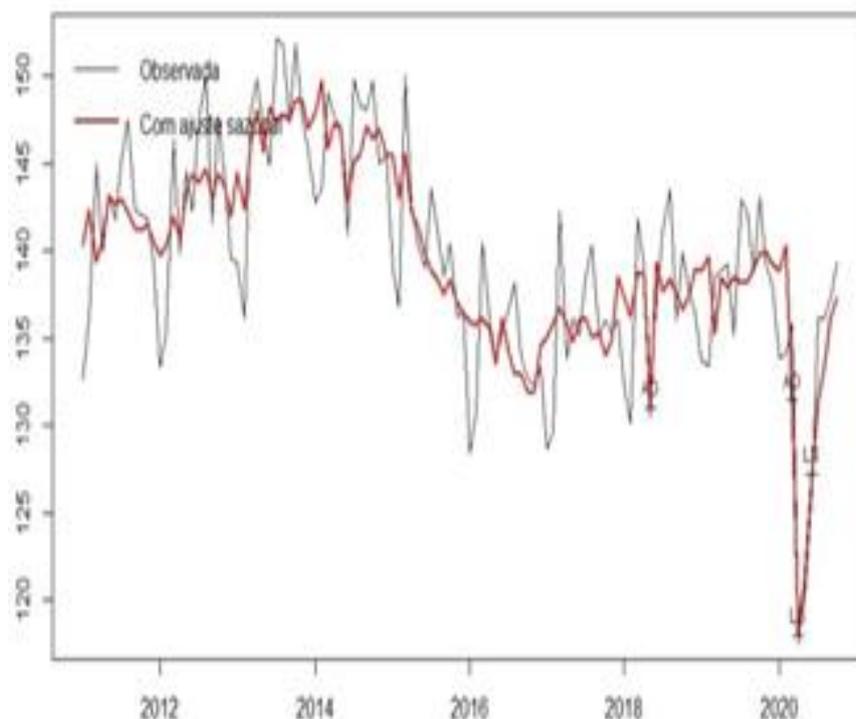
**Gráfico B2: Setor de Comércio.****Gráfico C2: Setor de Serviços**

Gráfico D2: IBC-br



**Figura 2.** Séries Originais e Ajustadas Sazonalmente pelo ARIMA X13-SEATS.

Fonte: Elaboração Própria.

Não obstante, embora os resultados apontem evidências de uma forte deterioração da atividade econômica nas séries originais e ajustadas sazonalmente nos gráficos apresentados na figura 2, fica evidente o ensaio de uma possível recuperação do nível de atividade econômica ainda no quarto trimestre de 2020. No entanto, somente o setor de serviços não apresentou qualquer tipo de *outlier* estimado que aponte tal comportamento, embora a série ajustada claramente sinalize uma tendência de crescimento do setor. Por outro lado, o nível de atividade da economia expresso no IBC-br apontou significativo *outliers level shift* (LS) de mudança permanente no nível da série no mês de junho acompanhado pelo setor industrial, o que é um forte indicativo de uma possível recuperação da economia no curto prazo.

Em suma, todas as evidências apresentadas neste trabalho expõem a dinâmica do comportamento sazonal das séries e a gravidade dos efeitos da pandemia sobre setores específicos e o nível de atividade da economia brasileira. Portanto, os impactos relevantes foram capturados pela estimação e identificação dos efeitos de *outliers* de forma transitória ou permanente, o que sugere impactos relevantes e convergentes aos objetivos desta pesquisa.

## 5. CONCLUSÃO

O presente trabalho teve por objetivo, descrever e caracterizar a dinâmica sazonal de séries macroeconômicas associadas aos setores da indústria, comércio, serviços e do nível de atividade da economia através do IBC-br frente ao choque exógeno proporcionado pela pandemia da covid-19 no ano de 2020. Portanto, pretendeu-se identificar os efeitos do choque a partir da estimação de *outliers* e possíveis tendências de recuperação da economia através da mesma estratégia metodológica.

Posto isto, o ano de 2020 ficou marcado quase que exclusivamente pela pandemia da covid-19 e seus efeitos dinâmicos adversos sobre a economia e a sociedade. Associado a isto, as medidas de isolamento social e *lockdowns*<sup>10</sup>, podem ser considerados os causadores diretos da retração do nível de atividade econômica e dos efeitos adversos específicos sobre cada setor que compõe a economia.

<sup>10</sup> Confinamento ou bloqueio social em sua versão mais rígida, determinado pelo Estado. No caso da pandemia da covid-19, o objetivo foi promover a desaceleração do contágio e propagação do vírus.

Dado este cenário, o Fundo Monetário Internacional projeta uma forte retração da economia mundial no ano de 2020 em torno de 3,0%, portanto, considerada a maior desde a grande depressão dos anos de 1930. Por outro lado, a mesma instituição espera uma rápida recuperação da economia mundial e projeta um crescimento de aproximadamente 5,8% no ano de 2021. Em relação à economia brasileira, a Instituição Fiscal Independente (IFI), estima uma queda de 5,0% do PIB em 2020, mas observa a possibilidade de uma rápida recuperação da economia no ano de 2021, cujo crescimento estimado gira em torno de 2,8%, de acordo com as últimas projeções.

Destarte, as evidências apresentadas nesta pesquisa parecem corroborar todos os cenários *ex-ante* e *ex-post*, ou seja, os resultados expressaram a forte retração da economia no terceiro trimestre de 2020, ao passo que, a partir do quarto trimestre do mesmo ano, observa-se uma tendência de recuperação do nível de atividade de economia e dos setores analisados. Portanto, embora se perceba o ensaio de uma recuperação econômica no curto prazo, nada se pode afirmar em relação à taxa de crescimento sustentada da economia no longo prazo, que naturalmente depende de diversos fatores além do choque exógeno da pandemia.

Em suma, a identificação dos *outliers* nas estimativas dos modelos ARIMA, mostra a sensibilidade dos setores da economia brasileira e da sua capacidade de crescimento em resposta ao choque da pandemia. Como observado, os setores da indústria e de serviços, além do comportamento do IBC-br, apresentaram mudança no nível de suas séries com persistência ao longo do tempo. Além disso, os *outliers* estimados para o setor industrial e a própria atividade econômica indicam uma mudança no nível de suas séries ainda no quarto trimestre do ano de 2020.

## REFERÊNCIAS

- AGUIRRE, A.; AGUIRRE, L. A. Modelos estatísticos e econométricos para estudo da sazonalidade de preços: o caso do preço da carne de boi. **Nova Economia**, [S. l.], v. 9, n. 1, 2013. Disponível em: <https://revistas.face.ufmg.br/index.php/novaeconomia/article/view/2196>. Acesso em: 21 jul. 2021.
- CAVALCANTI, M.A.F.H, *et al.* Atividade Econômica: PIB no Segundo Trimestre de 2020. **Carta de Conjuntura. Número 8**. Terceiro Trimestre de 2020. IPEA.
- CHEN, C.; LIU, L. Joint Estimation of Model Parameters and Outlier Effects in Times Series. **Journal of the American Statistical Association**, n. 88, p. 284-297, 1993.
- DELL'ARICCIA, G, *et al.* (2020) Economic policies for the COVID-19 war, IMFBlog. Disponível em: <https://blogs.imf.org/2020/04/01/economic-policies-for-the-covid-19-war/>
- FERREIRA, P. C., GONDIM, J. L., MATTOS, D. M. (2015). Métodos de ajuste sazonal para séries de Business Tendency: um estudo de caso para a Sondagem da Indústria utilizando o método X13-ARIMASEATS. Rio de Janeiro: IBRE/FGV (Nota Técnica).
- FERREIRA, P.; MATTOS, D.M. Usando o R para ensinar Ajuste Sazonal. São Paulo:FGV,2017.18p.Disponível em: <http://portalibre.fgv.br/lumis/portal/file/fileDownload.jsp?fileId=8A7C82C5519A547801533DF7BE5E2D0D>
- FINDLEY, D.F. *et al.* New Capabilities and Methods of the X-12-ARIMA Seasonal-Adjustment Program. **Journal of Business and Economic Statistics**, n.16(2).p. 127–152, 1998.
- FOK, D. *et.al.* Performance of Seasonal Adjustment Procedures: Simulation and Empirical Results. **Econometric Institute Research Papers**. EI 2005-30, Erasmus University Rotterdam, Erasmus School of Economics (ESE), Econometric Institute. 2005.
- GELPER, S, *et.al.* C. Robust forecasting with exponential and Holt-Winters smoothing. **Journal of Forecasting**, v. 29, p. 285-300, 2010.
- HANNAN, E. J.; RISSANEN, J. Recursive estimation of mixed autoregressive-moving average order. **Biometrika**, v. 69, n. 1, p. 81-94, 1982.
- HARVEY, A. **Forecasting, Structural Time Series Models and the Kalman Filter**. Cambridge: Cambridge University Press. doi:10.1017/CBO9781107049994. 1989.
- HARVEY, A., & SHEPHARD, N. (1993). **Structural Time Series Models**. In: Handbook of Statistics (Vol. 11). Elsevier Science Publishers B.V.

HOLT, C.C. **Forecasting Seasonals and Trends by Exponentially Weighted Moving Averages**. ONR Memorandum, vol. 52, Carnegie Institute of Technology, Pittsburgh. 1957.

IBGE. **Pesquisa Industrial Mensal Produção Física - Brasil**. Retrieved in 2020, from <http://ibge.gov.br/home/estatistica/indicadores/industria/pimpf/br/default.shtm>.

JORGENSON, D. W. Minimum variance, linear, unbiased seasonal adjustment of economic time series. **Journal of the American Statistical Association**, n. 59, p. 681-724, 1964.

LOPES, A. C. B. The Robustness of Test for Seasonal Differencing to Structural Breaks. **Economic Letters**, n.71, p.173-179, 2001.

MARAVALL, A. *et al.* Reg-Arima Model Identification: Empirical Evidence. **Statística Sinica**, vol. 26, no. 4, 2016, p. 1365–1388., [www.jstor.org/stable/44114338](http://www.jstor.org/stable/44114338). Accessed 21 July 2021.

MORETTIN, P. A.; TOLI, C. M. C. Previsão de Séries Temporais. Instituto de Matemática Pura e Aplicada (IMPA), (1987), 400p.

PEDERSEN, M. K., FAESTE, C. F. Seasonal adjust of Danish financial time series using the X12-ARIMA procedure. Danmarks Nationalbank, 2006.

PLOSSER, C. I. **A time series analysis of seasonality in econometric models**. In Arnold Zellner (Ed.), *Seasonal analysis of economic time series*. Washington, D.C.: U.S. Department of Commerce. p. 365-397., 1979.

RASMUSSEN, R. (2004). On time series data and optimal parameters. **The International Journal of Management Science**, v 32, n. 2. P 11-120, 2004.

SHISKIN, J., YOUNG, A. H., Musgrave J.C. (1967). The X-11 Variant of the Census Method II Seasonal Adjustment Program. Technical Report 15, U.S. Bureau of the Census, Washington, DC.

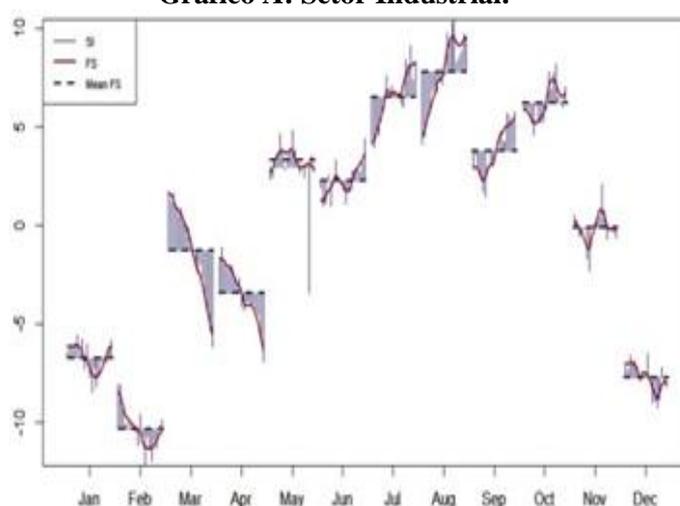
TSAY, R. S. Time Series Model Specification in the Presence of Outliers. **Journal of the American Statistical Association**, n. 81, p. 132-141, 1986.

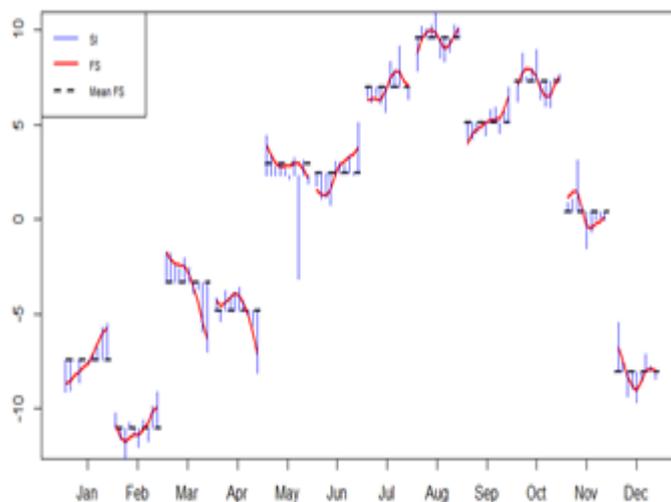
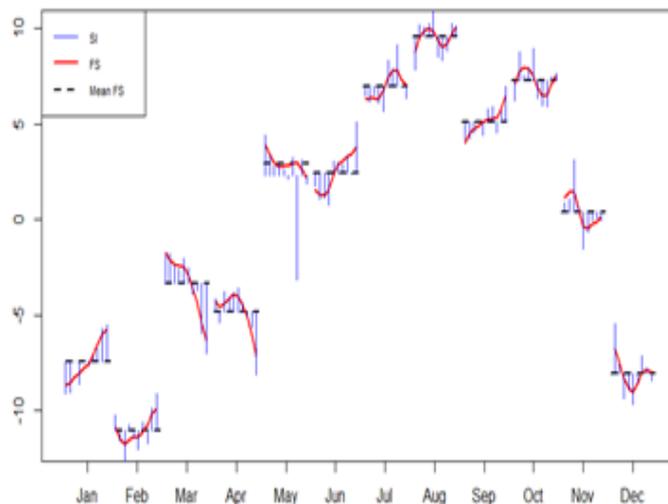
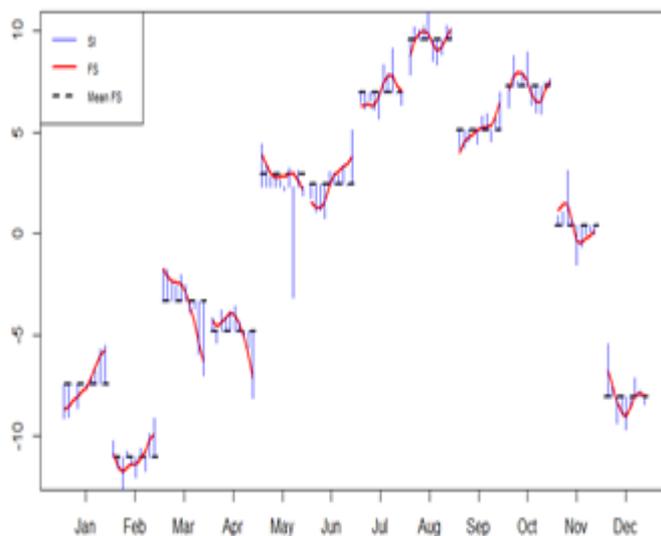
WINTERS, P. R. Forecasting sales by exponentially weighted moving averages, **Management Science**, 6, 324-342, 1960.

ZELLNER, A. **Seasonal Analysis of Economic Time Series**, Washington, D.C.: U.S. Dept. of Commerce - Bureau of the Census, 1979.

## ANEXO A

**Gráfico A: Setor Industrial.**



**Gráfico B: Setor de Comércio.****Gráfico C: Setor de Serviços.****Gráfico D: IBC-br.****Figura A1.** Comparação dos Componentes Sazonais (FS) e do SI Ratio por Setores da Economia.

Fonte: Elaboração Própria.