



UNIVERSIDADE DE BRASÍLIA
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE
DEPARTAMENTO DE ECONOMIA
MESTRADO EM ECONOMIA DO SETOR PÚBLICO

JORGE HENRIQUE BARROS LEMOS

**ANÁLISE DE SÉRIES TEMPORAIS PARA PREVISÃO DA
ARRECADAÇÃO DO ICMS DO ESTADO DE GOIÁS COM O
SOFTWARE 'R'**

GOIÂNIA

2023



UNIVERSIDADE DE BRASÍLIA
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE
DEPARTAMENTO DE ECONOMIA
MESTRADO EM ECONOMIA DO SETOR PÚBLICO

JORGE HENRIQUE BARROS LEMOS

**ANÁLISE DE SÉRIES TEMPORAIS PARA PREVISÃO DA
ARRECAÇÃO DO ICMS DO ESTADO DE GOIÁS COM O
SOFTWARE 'R'**

Dissertação de Mestrado apresentada ao Departamento
Economia da Universidade de Brasília, como parte dos
requisitos necessários à obtenção do título de Mestre em
Economia do Setor Público.

Orientador: RAFAEL TERRA DE MENEZES, Prof., Dr.

GOIÂNIA

2023

JORGE HENRIQUE BARROS LEMOS

ANÁLISE DE SÉRIES TEMPORAIS PARA PREVISÃO DA ARRECADAÇÃO DO ICMS
DO ESTADO DE GOIÁS COM O SOFTWARE 'R'

Trabalho final de Curso apresentado no Mestrado Profissional em Economia do Setor Público –
MESP do Departamento de Economia – FACE da Universidade de Brasília – UnB.

BANCA EXAMINADORA

Prof. Dr. Rafael Terra de Menezes

Orientador

Prof. Dr. Fábio Avila de Castro

Co-Orientador

Prof. Dr. Paulo Roberto Scalco

Profa. Dra Maria Eduarda Tannuri-Pianto

Lista de Tabelas

Tabela 1. Arrecadação Tributária do Estado de Goiás	15
Tabela 2. Arrecadação do ICMS por Tipo de Condição de Pagamento	16
Tabela 3. Relação ICMS / PIB - Região Centro-Oeste	17
Tabela 4. Componentes de uma Série Temporal	22
Tabela 5. Categorização da Série considerando Tendência e Sazonalidade.....	23
Tabela 6. Quadro Resumo de descrições estatísticas da série do ICMS	39
Tabela 7. Arrecadação do ICMS por Atividade Econômica Macro	40
Tabela 8. Alterações de alíquotas do ICMS decorrentes da LC 194/2022	41
Tabela 9. Comparativos de Informação – AIC e BIC entre modelos	45
Tabela 10. Previsões dos modelos - Partição I – IPCA	47
Tabela 11. Previsões dos modelos - Partição I - IGP-DI.....	48
Tabela 12. Previsões dos modelos - Partição I - Log IGP-DI	48
Tabela 13. Previsões dos modelos - Partição I - Nominal.....	49
Tabela 14. Resumo dos melhores modelos por Série	50
Tabela 15. Previsões dos modelos - Partição II – IPCA.....	54
Tabela 16. Previsões dos modelos - Partição II - IGP-DI.....	54
Tabela 17. Previsões dos modelos - Partição II - Log IGP-DI	55
Tabela 18. Previsões dos modelos - Partição II - Nominal.....	55
Tabela 19. Resumo dos melhores modelos por Série	56
Tabela 20. Previsões do modelo HWM - Partição I - IGP-DI.....	56
Tabela 21. Previsões dos modelos - Partição III – IPCA	57
Tabela 22. Previsões dos modelos - Partição III - IGP-DI	57
Tabela 23. Previsões dos modelos - Partição III - Log IGP-DI.....	58
Tabela 24. Previsões dos modelos - Partição III - Nominal	58
Tabela 25. Resumo dos melhores modelos por Série	59
Tabela 26. Previsões dos modelos - Partição IV – IPCA	60
Tabela 27. Previsões dos modelos - Partição IV - IGP-DI.....	60
Tabela 28. Previsões dos modelos - Partição IV - Log IGP-DI.....	61
Tabela 29. Previsões dos modelos - Partição IV - Nominal	61
Tabela 30. Resumo dos melhores modelos por Série	62
Tabela 31. Previsões do modelo ARIMA - Partição IV – IPCA	62
Tabela 32. Previsão I Semestre de 2022	63
Tabela 33. Previsão II Semestre de 2022.....	63
Tabela 34. Valor nominal da Arrecadação do ICMS - 2021 e 2022	64

Lista de Figuras

Figura 1. Gráfico da Série Temporal do ICMS com a Linha de Tendência	21
Figura 2. Arrecadação Espontânea do ICMS GO - 2003 a 2022.....	41
Figura 3. Testes ACF e PACF da Série Temporal.....	44
Figura 4. Decomposição da Série Temporal.....	46
Figura 5. Coeficientes do Modelo SARIMA	50
Figura 6. Gráfico do algoritmo SARIMA - Treino vs Validação	51
Figura 7. Teste ACF e PACF dos Resíduos	52

Lista de Siglas

ACF – Função de Autocorrelação

ACVF – Função de Autocovariância

AIC – Akaike Information Criterion/Critério de avaliação de Akaike

AR – Modelos Autorregressivos

ARIMA - Autoregressive Integrated Moving Average

ARMA - Autoregressive Moving Average

BIC – Bayesian Information Criterion/Critério de avaliação bayesiana

FACV - Função de Autocovariância

HW - Método Holt-Winters

HWA - Método Holt-Winters Aditivo

HWM - Método Holt-Winters Aditivo

ICMS – Imposto sobre Operações Relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação

IGPDI – Índice Geral de Preços Disponibilidade Interna

IGPM – Índice Geral de Preços do Mercado

INPC – Índice Nacional de Preços ao Consumidor

IPCA – Índice Nacional de Preços ao Consumidor Amplo

ITCD – Imposto sobre a Transmissão Causa Mortis e Doação de Quaisquer Bens ou Direitos

LDO - Lei de Diretrizes Orçamentárias

LOA - Lei Orçamentária Anual

LRF - Lei de Responsabilidade Fiscal

MA – Modelos de Média Móvel

MAE – Mean Absolute Error/Erro médio absoluto

MAPE – Mean Absolute Percentage Error/Erro percentual absoluto médio

MSE – Mean Squared Error/Erro quadrado médio

PACF – Função de Autocorrelação Parcial

PIB - Produto Interno Bruto

PROTEGE - Fundo de Proteção Social do Estado de Goiás

RMSE – Root Mean Squared Error/Raiz do erro quadrático médio

SARIMA - Seasonal Autoregressive Integrated Moving Average

SEH - Suavização Exponencial de Holt

SES - Suavização Exponencial Simples

Agradecimentos

Aos meus amados pais, José Lemos e Rosilda Barros, cujo amor, carinho e dedicação moldaram a pessoa que sou hoje. Sem o apoio incansável de vocês, eu não estaria aqui celebrando este marco em minha vida. Cada lição que me transmitiram e cada valor que compartilharam são a base do meu sucesso e felicidade.

Uma menção especial à Cristiane, cuja ajuda e compreensão se tornaram ainda mais preciosas durante os momentos desafiadores deste percurso. Sua presença foi um farol orientador que me ajudou a atravessar as adversidades com determinação.

Aos meus filhos e neto, Bruno, Artur e Ariel, expesso meu profundo agradecimento pelo incentivo constante e pela preocupação demonstrada ao longo desta jornada. Seus sorrisos e apoio foram o combustível que impulsionou minha busca pelo conhecimento.

Ao meu estimado orientador, Fábio Ávila de Castro, sou imensamente grato pela segurança que transmitiu, pela organização exemplar que trouxe ao nosso trabalho conjunto, pela disponibilidade incansável em orientar-me e, acima de tudo, pelo incentivo constante que me inspirou a superar desafios e alcançar novos patamares acadêmicos.

Não posso deixar de estender minha gratidão aos notáveis professores do Programa de Mestrado do MESP da UnB, cuja ajuda e atenção foram fundamentais para meu crescimento intelectual. Suas orientações e conhecimentos compartilhados enriqueceram meu percurso acadêmico.

Aos colegas da minha turma de mestrado, sou grato pelas horas enriquecedoras de estudo e aprendizado que compartilhamos juntos. Nossas discussões e colaborações foram um catalisador para meu desenvolvimento acadêmico e pessoal.

Resumo

A dissertação tem como objetivo central aprofundar a avaliação de estratégias univariadas de modelagem e previsão da arrecadação do ICMS no Estado de Goiás, utilizando o *software* R como ferramenta principal de análise, de modo a fornecer aos gestores estaduais um modelo de previsão consistente, que possibilite uma gestão financeira eficaz do Estado.

Uma das principais ênfases deste trabalho é o estudo detalhado do algoritmo de alisamento exponencial de Holt-Winters, suas variações e adaptações específicas para a previsão do ICMS. Serão analisadas as características e eficácia dessas técnicas em relação aos dados históricos disponíveis, a fim de identificar suas capacidades e limitações. Também foi utilizada a metodologia de Box-Jenkins, utilizando os modelos autorregressivos integrados de médias móveis (SARIMA). Esses modelos são amplamente reconhecidos por sua habilidade em lidar com séries temporais complexas e fornecer previsões precisas.

Após realizar simulações em quatro conjuntos distintos de dados, considerando horizontes de previsão de doze meses, foram obtidos resultados significativos. Para o ano fiscal 2019, caracterizado por uma arrecadação dentro dos padrões usuais, a combinação da série {LOG IGP-DI} com o modelo SARIMA (2,1,1)(1,0,0)[12] demonstrou o desempenho mais destacado. Já para o ano subsequente, 2020, o modelo Holt-Winters Multiplicativo aplicado à série {LOG IGP-DI} revelou-se o mais eficaz.

Ao avançar para o ano de 2021, a série {IGP-DI} em conjunto com o modelo Holt-Winters Multiplicativo apresentou os melhores resultados. E, por fim, considerando o ano de 2022, a combinação que proporcionou as previsões mais acuradas foi a série {NOMINAL} associada ao modelo ARIMA[1,1,1].

Nesse contexto, conclui-se que não existe um modelo univariado único capaz de abarcar todas as variações econômicas intrínsecas a eventos inesperados, a exemplo da pandemia de Covid. Dessa forma, torna-se claro que investigações subsequentes devem ampliar seu escopo para abranger modelos multivariados.

Palavras-chave: Previsão de Arrecadação de ICMS; Holt-Winters; ARIMA; SARIMA.

Abstract

This master's dissertation aims to delve into the evaluation of univariate strategies for modeling and forecasting the ICMS revenue in the State of Goiás, utilizing the R software as the primary analytical tool. The central objective is to provide state managers with a robust forecasting model that enables effective financial management.

A key focus of this work is the in-depth study of the Holt-Winters exponential smoothing algorithm, its variations, and specific adaptations for ICMS forecasting. The characteristics and effectiveness of these techniques will be analyzed concerning available historical data to identify their capabilities and limitations. Additionally, the Box-Jenkins methodology, employing Seasonal Autoregressive Integrated Moving Average (SARIMA) models, renowned for handling complex time series and providing accurate forecasts, was also employed.

Significant results were obtained through simulations on four distinct datasets, considering a twelve-month forecasting horizon. For the fiscal year 2019, characterized by revenue within typical patterns, the combination of the {LOG IGP-DI} series with the SARIMA (2,1,1)(1,0,0)[12] model exhibited the most outstanding performance. Conversely, for the subsequent year, 2020, the Multiplicative Holt-Winters model applied to the {LOG IGP-DI} series proved to be the most effective.

Moving to the year 2021, the {IGP-DI} series in conjunction with the Multiplicative Holt-Winters model yielded the best results. Finally, considering the year 2022, the combination that provided the most accurate predictions was the {NOMINAL} series associated with the ARIMA[1,1,1] model.

In this context, it is concluded that there is no single univariate model capable of encompassing all intrinsic economic variations in unexpected events, such as the Covid pandemic. Therefore, it becomes evident that subsequent investigations should broaden their scope to include multivariate models.

Keywords: Forecasting Tax on Circulation of Goods and Services; Holt-Winters; ARIMA; SARIMA.

Índice

Conteúdo

1.	Introdução	12
2.	Panorama do ICMS	14
2.1	Histórico do ICMS no Brasil.....	14
2.2	ICMS no Estado de Goiás	15
2.3	Relação entre o PIB e a arrecadação do ICMS	16
3.	Fundamentos teóricos de Séries Temporais	18
3.1	Definição de Série Temporal.....	18
3.1.1	Estacionariedade	19
3.1.2	Funções de Autocovariância e Autocorrelação.....	20
3.1.3	Componentes da Série Temporal	21
3.2	Métodos de Suavização Exponencial.....	23
3.2.1	Método de Suavização Exponencial Simples (SES):.....	24
3.2.2	Método Holt (Exponencial Duplo - SEH):	25
3.2.3	Método Holt-Winters (HW).....	25
3.2.3.1	Holt-Winters Aditivo.....	27
3.2.3.2	Holt-Winters Multiplicativo	28
3.3	Modelando a Série Temporal – Box & Jenkins	29
3.3.1	Modelos Autorregressivos – AR (p)	31
3.3.2	Modelos de Média Móvel – MA(q).....	31
3.3.3	Modelo ARMA(p,q)	32
3.3.4	Modelo ARIMA (p,d,q)	33
3.3.5	Modelo SARIMA(p,d,q)(P,D,Q)[m]	34
3.3.6	Medidas de acurácia de previsão	36
4.	Base de dados utilizada e análise exploratória dos dados	39
5.	Análise dos Resultados	43
5.1	Ajustes nas Séries.....	43
5.2	Diferenciação da Série	43
5.3	Determinação dos Parâmetros (p,q) do Modelo ARIMA	44

5.4	Testes de Sazonalidade.....	46
5.5	Modelagem e Previsão	47
5.5.1	Partição I [2019].....	47
5.5.2	Partição II [2020].....	54
5.5.3	Partição III [2021]	57
5.5.4	Partição IV [2022]	60
6	Conclusão	65
6.1.1	Método de Suavização Exponencial Simples (SES) – IPCA e ‘Em Nível’:.....	68
6.1.2	Método de Suavização Exponencial Simples (SES) – IGPD e ‘Em Nível’:.....	69
6.1.3	Método de Suavização Exponencial Simples (SES) – IGPD e ‘Log’:.....	71
6.1.4	Método de Suavização Exponencial Simples (SES) – Nominal:.....	74
6.2.1	Método Holt Aditivo (Exponencial Duplo - SEH) – IPCA e ‘Em Nível’:.....	76
6.2.2	Método Holt Aditivo (Exponencial Duplo - SEH) – IGPD e ‘Em Nível’:.....	78
6.2.3	Método Holt Aditivo (Exponencial Duplo - SEH) – IGPD e ‘Log’:.....	79
6.3.1	Método Holt Multi (Exponencial Duplo - SEH) – IPCA e ‘Em Nível’:	82
6.3.2	Método Holt Multi (Exponencial Duplo - SEH) – IGPD e ‘Em Nível’:.....	84
6.3.3	Método Holt Multi (Exponencial Duplo - SEH) – IGPD e ‘Log’:.....	85
6.2.4	Método Holt Aditivo (Exponencial Duplo - SEH) – Nominal:	88
6.4.1	Método Holt-Winters Aditivo (HW) – IPCA e ‘Em Nível’:	90
6.4.2	Método Holt-Winters Aditivo (HW) – IGPD e ‘Em Nível’:.....	91
6.4.3	Método Holt-Winters Aditivo (HW) – IGPD e ‘Log’:.....	93
6.5.1	Método Holt-Winters Multiplicativo (HW) – IPCA e ‘Em Nível’:.....	97
6.5.2	Método Holt-Winters Multiplicativo (HW) – IGPD e ‘Em Nível’:.....	100
6.5.3	Método Holt-Winters Multiplicativo (HW) – IGPD e ‘Log’:.....	101
6.5.4	Método Holt-Winters Multiplicativo (HW) – Nominal:.....	101
6.6.1	Método ARIMA – IPCA e ‘Em Nível’:.....	103
6.6.2	Método ARIMA – IGPD e ‘Em Nível’:.....	104
6.6.3	Método ARIMA – IGPD e ‘Log’:.....	107
6.6.4	Método ARIMA – Nominal:.....	110
6.7.1	Método SARIMA – IPCA e ‘Em Nível’:	111
6.7.2	Método SARIMA – IGPD e ‘Em Nível’:.....	113
6.7.3	Método SARIMA – IGPD e ‘Log’:.....	114
6.7.4	Método SARIMA – Nominal:	117

Capítulo 1

1. Introdução

O planejamento adequado dos gastos é essencial para que os entes públicos possam cumprir com suas obrigações e oferecer serviços essenciais à população de forma contínua e sustentável. Ao elaborar um planejamento detalhado, os gestores têm a oportunidade de identificar prioridades, definir metas, estimar receitas e despesas, e, assim, criar uma base sólida para uma gestão financeira responsável.

No âmbito acadêmico, pesquisadores têm voltado seus olhares para o desenvolvimento de metodologias mais sofisticadas e precisas de estimação e previsão de receitas. A compreensão detalhada dos padrões econômicos e das variáveis que afetam as receitas fiscais é essencial para aprimorar a capacidade de prever com exatidão a arrecadação futura. Por meio da análise rigorosa de dados históricos e da aplicação de modelos econômicos avançados, a investigação científica busca contribuir com soluções inovadoras que permitam aos governos antecipar cenários e tomar decisões acertadas sobre suas políticas orçamentárias.

A importância da previsão de receitas é evidenciada pela Lei de Responsabilidade Fiscal (LRF), a qual estabelece a obrigação dos entes federativos em executar e divulgar tais ações na Lei de Diretrizes Orçamentárias (LDO) e na Lei Orçamentária Anual (LOA).

A atividade de previsão assume importância significativa quando é tornada obrigatória pela legislação. A Lei Complementar nº 101, de 4 de maio de 2000, também conhecida como Lei de Responsabilidade Fiscal, estabelece que a instituição, previsão e efetiva arrecadação de todos os tributos são requisitos essenciais para a responsabilidade na gestão fiscal. É necessário observar as normas técnicas e legais ao realizar as previsões de receita, considerando os efeitos das alterações na legislação, variação do índice de preços, crescimento econômico e outros fatores relevantes.

Além disso, as previsões de receita devem ser acompanhadas de demonstrativos que apresentem sua evolução nos últimos três anos, bem como projeções para os dois anos seguintes, juntamente com a metodologia de cálculo e premissas utilizadas. Essas medidas visam garantir a transparência e a fundamentação das previsões, fornecendo uma base sólida para a gestão fiscal (GADELHA, 2017).

Nesse estudo, utilizamos metodologias e modelos já consagrados na literatura para analisar a série temporal do Imposto sobre Circulação de Mercadorias e Serviços (ICMS) para o Estado de Goiás. Para isso foram empregados os modelos de alisamento exponencial e os modelos sazonais autorregressivos integrados de médias móveis (SARIMA), utilizando o pacote estatístico R como ferramenta de análise.

Vários trabalhos acadêmicos seguiram essa mesma abordagem. Sousa et al. (2019) utilizaram modelos SARIMA para estimar a arrecadação do ICMS do estado do Ceará entre janeiro e outubro de 2018, relatando a importância da componente sazonal para as previsões. Almeida (2017) utilizou modelos de alisamento exponencial e SARIMA para realizar a previsão de receitas do ICMS no período de 2002 a 2017. Azevedo et al. (2017) analisaram a aplicabilidade do modelo ARIMA às previsões de ICMS de seis estados brasileiros, São Paulo, Rio de Janeiro, Minas Gerais, Bahia, Rio Grande do Sul e Paraná, verificando a aumento de

acurácia nas previsões realizadas em relação às metodologias utilizadas pelos citados entes federativos. Moço (2017) utilizou modelos SARIMA, dentre outros, para a realização da previsão do ICMS do Rio de Janeiro utilizando dados de 2003 a 2015. Castanho (2011) utilizou modelos de alisamento exponencial e modelos ARIMA/SARIMA para efetuar estimativas de receitas do ICMS do Espírito Santo em 2010, utilizando dados de 2000 a 2009. Finalmente, Gomes (2003) utilizou modelos de alisamento exponencial e SARIMA, além de uma combinação de ambos, para estimar as receitas do Imposto de Renda em 2001, utilizando dados de 1994 a 2000.

Assim, o objetivo deste trabalho é utilizar os modelos univariados de alisamento exponencial e ARIMA e SARIMA para efetuar a previsão de receitas do ICMS de Goiás em um horizonte de previsão de 12 meses, correspondentes às previsões de receita de um ciclo orçamentário, e verificar qual modelo fornece a melhor acurácia para os diferentes períodos econômicos considerados. Ainda que essa investigação seja apenas uma etapa do processo de previsão de receitas, se reveste de importância no sentido de sinalizar os modelos que serão os potenciais candidatos a serem utilizados em futuros contextos de previsões orçamentárias para o estado.

Este trabalho se divide em seis capítulos incluindo essa introdução. O capítulo dois trata do panorama nacional e estadual do ICMS, o capítulo três aborda os fundamentos teóricos de séries temporais, o capítulo quatro discute a base de dados utilizada e faz uma análise exploratória dos dados, o capítulo cinco apresenta a análise dos resultados e, por fim, o capítulo seis apresenta as conclusões.

Capítulo 2

2. Panorama do ICMS

2.1 Histórico do ICMS no Brasil

O Imposto sobre Operações Relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS) é um tributo estadual que incide sobre a circulação de mercadorias e a prestação de serviços de transporte e comunicação. Sua história é marcada por diversas mudanças e adaptações ao longo do tempo.

Antes da criação do ICMS, existiam diversos impostos estaduais que incidiam sobre as vendas e consignações de mercadorias, como o Imposto sobre Vendas e Consignações (IVC) e o Imposto sobre Circulação de Mercadorias (ICM). Com a promulgação da Constituição Federal de 1988, foi criado o ICMS, que substituiu esses impostos anteriores e unificou a tributação sobre a circulação de mercadorias e serviços em todo o território brasileiro.

Desde então, a legislação do ICMS passou por diversas mudanças, embora o objetivo inicial de torná-la mais clara e simplificada tenha sido consideravelmente frustrado. Entre as principais alterações, destaca-se a Emenda Constitucional nº 42/2003, que estabeleceu a unificação das alíquotas interestaduais do ICMS, com o objetivo de evitar a chamada "guerra fiscal" entre os estados.

Outra importante mudança foi a Lei Complementar nº 87/1996, conhecida como "Lei Kandir", que estabeleceu normas gerais para a cobrança do ICMS em todo o país. Essa lei definiu, por exemplo, as regras para o cálculo do imposto e para a concessão de créditos tributários.

Além disso, a legislação do ICMS também passou por diversas adaptações em resposta a mudanças na economia brasileira e na legislação tributária. Por exemplo, em 2016, foi criado o Convênio ICMS nº 93/2015, que estabeleceu a cobrança do ICMS sobre as operações de comércio eletrônico entre estados.

Atualmente, o Imposto sobre Operações Relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS) figura como o tributo mais relevante no Brasil, com uma arrecadação anual que supera a marca dos R\$ 500 bilhões. Em 2022, somente no Estado de Goiás, a arrecadação com ICMS atingiu a cifra de, aproximadamente, R\$ 24 bilhões (vinte e quatro bilhões de reais).

2.2 ICMS no Estado de Goiás

A arrecadação tributária em Goiás é composta pelo Imposto sobre Operações Relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS), Imposto sobre a Propriedade de Veículos Automotores (IPVA), Imposto sobre Transmissão Causa Mortis e Doações (ITCD) e as Taxas de Serviços Estaduais, que por uma convenção interna local, são denominadas de Outros Tributos. De acordo com dados da Secretaria de Economia do Estado de Goiás, o ICMS representou 81,02% da arrecadação tributária total do Estado no ano de 2022. Os demais tributos arrecadados compuseram apenas 18,98% dos recolhimentos, conforme Tabela 1. Isso mostra o quão importante é o ICMS como fonte geradora de receita em Goiás.

Tabela 1. Arrecadação Tributária do Estado de Goiás

ARRECADANÇA TRIBUTÁRIA NOMINAL DO ESTADO DE GOIÁS [2022] (em R\$)		
Grupo Receita Gerencial	Valor Total	Part. %
ICMS	24.248.258.744,88	81,02%
IPVA	2.462.554.979,70	8,23%
ITCD	895.202.923,08	2,99%
OUTROS TRIBUTOS	808.428.358,79	2,70%
PROTEGE	1.513.802.067,35	5,06%
TOTAL	29.928.247.073,80	100,00%

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Há um aspecto relevante que se deve ser destacado no que se refere à arrecadação de ICMS. A forma com que os recolhimentos são executados por parte dos contribuintes afeta a disponibilidade dos recursos para a formação de receitas ao Estado, e conseqüentemente podem influenciar quaisquer análises a respeito desse imposto.

Existem três modalidades de recolhimento deste imposto: o ICMS espontâneo, o ICMS devido em decorrência de ações fiscais e o ICMS inscrito em dívida ativa. Cada modalidade tributária apresenta particularidades em relação à forma como o tributo é arrecadado e à sua natureza, que variam de acordo com a constituição do crédito tributário.

O ICMS espontâneo é um indicador que reflete a efetiva disposição dos contribuintes em cumprir com suas obrigações tributárias, ou seja, o pagamento do imposto de forma voluntária e sem a necessidade de ações coercitivas por parte do fisco.

Por ser uma arrecadação voluntária, o ICMS espontâneo é mais sensível às variações da atividade econômica, já que as empresas tendem a pagar mais impostos quando estão com suas vendas em alta e menos impostos quando a economia está em baixa, além de refletir a real disposição do contribuinte em cumprir com suas obrigações tributárias. Isso significa que ele pode ser utilizado como um indicador da saúde econômica de um estado ou região.

Já o ICMS devido em decorrência de ações fiscais é aquele que é cobrado após a realização de ações de fiscalização, como auditorias e autuações, quando o Estado verifica que o tributo não foi recolhido integralmente ou não foi recolhido de forma correta pelo contribuinte. Nessa

modalidade, o tributo é cobrado com correção monetária, multas e juros, o que pode gerar valores significativamente maiores, para um mesmo fato gerador, do que o ICMS espontâneo.

Por fim, o ICMS em dívida ativa é aquele que foi cobrado por meio de ações fiscais, mas que não foi pago pelo contribuinte, gerando uma dívida. Nessa modalidade, o Estado pode tomar medidas coercitivas para realizar a cobrança, como a inscrição do contribuinte em cadastros de inadimplentes, protestos e execuções fiscais.

O ICMS espontâneo é considerado uma fonte de recursos mais confiável para o planejamento do orçamento governamental, pois ele não está sujeito a atrasos ou inadimplências por parte dos contribuintes. Dessa forma, ele permite uma maior previsibilidade de receitas e maior capacidade de planejamento para o Estado. Além disso, oferece uma fonte de recursos mais estável e confiável para o planejamento e execução do orçamento governamental. Por esse motivo, este estudo se concentra na análise da série temporal do ICMS espontâneo. Com base nos dados apresentados na Tabela 2, o ICMS espontâneo é responsável pela maior parte da arrecadação total de ICMS. No ano de 2022, representou 97,97% do ICMS total arrecadado, conforme tabela abaixo:

Tabela 2. Arrecadação do ICMS por Tipo de Condição de Pagamento

ARRECADAÇÃO NOMINAL DO ICMS POR CONDIÇÃO DE PAGAMENTO [2018 a 2022] - GOIÁS (em R\$)										
CONDIÇÃO PGTO	2018	Part. %	2019	Part. %	2020	Part. %	2021	Part. %	2022	Part. %
ESPONTÂNEO	15.216.326.941	96,58%	16.650.393.234	97,22%	17.511.776.556	97,71%	22.338.103.389	95,56%	23.755.067.310	97,97%
AÇÃO FISCAL	337.893.571	2,14%	271.678.895	1,59%	222.443.469	1,24%	678.294.846	2,90%	314.305.737	1,30%
DÍVIDA ATIVA	200.431.912	1,27%	203.808.015	1,19%	187.519.555	1,05%	360.046.167	1,54%	178.885.698	0,74%
TOTAL	15.754.652.424	100,00%	17.125.880.144	100,00%	17.921.739.580	100,00%	23.376.444.402	100,00%	24.248.258.745	100,00%

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

2.3 Relação entre o PIB e a arrecadação do ICMS

O Produto Interno Bruto (PIB) e a arrecadação do ICMS são variáveis macroeconômicas que estão diretamente relacionadas, uma vez que a arrecadação do ICMS é uma importante fonte de receita para os Estados e pode impactar diretamente o crescimento econômico e o desenvolvimento regional.

Uma das principais razões para essa correlação é o fato de que o ICMS é um imposto que incide sobre a circulação de mercadorias e serviços, ou seja, ele é cobrado em cada etapa da cadeia produtiva, seguindo o princípio da não cumulatividade. Dessa forma, à medida que a economia cresce e a produção de bens e serviços aumenta, a arrecadação do ICMS também tende a crescer.

Por outro lado, a arrecadação do ICMS pode ser afetada por diversos fatores, como a conjuntura econômica do país, a estrutura tributária estadual, a legislação tributária vigente, entre outros. Além disso, a distribuição das receitas do ICMS entre os municípios de cada Estado também pode impactar o desenvolvimento regional e a desigualdade social.

A relação entre o crescimento percentual da arrecadação e o crescimento percentual do PIB chama-se elasticidade arrecadação-PIB. Quanto maior essa elasticidade, mais a arrecadação

tende a subir conforme o PIB cresce e mais tende a cair conforme o PIB decresce. (MENDONÇA; MEDRANO, 2017)

Assim sendo, é importante ressaltar que a correlação entre o PIB e a arrecadação do ICMS não é linear e pode variar em função de diversos fatores macroeconômicos e institucionais. No entanto, em geral, um aumento no PIB tende a gerar um aumento na arrecadação do ICMS, o que pode contribuir para o desenvolvimento econômico e social dos Estados brasileiros.

Há diversas formas de conseguir incrementos na arrecadação de ICMS na hipótese da manutenção do PIB constante, como: ampliação da capacidade do fisco; aumento na rigidez das fiscalizações; operações de combate à sonegação; programas de educação fiscal; aumento da formalização dos negócios; entre outros (PEDROSA; DE MOURA, 2019).

Tabela 3. Relação ICMS / PIB - Região Centro-Oeste

RELAÇÃO ICMS / PIB - REGIÃO CENTRO-OESTE [2002 - 2017]																
Ano	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
DF	3,62%	3,69%	3,85%	3,88%	3,92%	3,70%	3,58%	3,22%	3,19%	3,36%	3,47%	3,56%	3,34%	3,01%	3,13%	3,09%
GO	7,82%	8,12%	7,78%	7,84%	7,66%	7,33%	7,45%	7,23%	7,65%	8,14%	8,19%	8,02%	7,87%	7,78%	7,70%	7,61%
MS	8,98%	8,51%	10,05%	11,24%	11,29%	11,64%	12,00%	10,83%	9,82%	9,82%	9,68%	9,82%	8,69%	8,34%	7,75%	7,90%
MT	9,71%	9,27%	9,84%	10,05%	11,39%	10,22%	9,63%	9,52%	9,43%	8,41%	8,42%	8,37%	7,05%	7,24%	6,81%	7,14%

Fonte: PEDROSA; DE MOURA, 2019

Capítulo 3

3. Fundamentos teóricos de Séries Temporais

3.1 Definição de Série Temporal

Definição formal de série temporal: Uma coleção de observações que foram coletadas em intervalos de tempo regulares para uma determinada variável durante um determinado período é chamada de série temporal. Uma série temporal pode ser tanto discreta quanto contínua:

- 1) **Séries temporais discretas:** o intervalo entre as observações pertence a um conjunto discreto, uma série temporal discreta é obtida através da amostragem de uma série temporal contínua em intervalos de tempos iguais Δt , pontos equidistantes no tempo.
- 2) **Séries temporais contínuas:** observações obtidas continuamente. De modo geral, uma série contínua sempre pode ser discretizada.

A principal característica de séries temporais é a existência de alguma forma de dependência entre dados observados em tempos diferentes. O que limita a utilização de modelos estatísticos convencionais desenvolvidos para dados i.i.d (independente e identicamente distribuída). Quando as observações possuem a capacidade de assumir valores de forma probabilística, caracterizamos a série temporal como um processo aleatório ou estocástico. Em termos concisos, "um processo estocástico consiste em um conjunto de variáveis aleatórias organizadas ao longo do tempo." (GUJARATI; PORTER, 2011).

O intervalo de tempo regular pode ser diário (preço das ações na bolsa de valores), semanalmente (produtos manufaturados), mensal (taxa de desemprego), trimestral (vendas de uma mercadoria), anual (Produto Interno Bruto) ou decenal (censo da população).

As séries temporais podem ser aplicadas em vários campos, como previsão econômica, previsão de vendas, análise orçamentária, análise do mercado de ações, projeção de rendimento, estudos de estoque, projeções de carga de trabalho, estudos de serviços públicos, análise de censo, processo e controle de qualidade e muito mais.

Os dados de séries temporais têm várias características que os tornam únicos. Essas características podem ser descritas abaixo como:

- **Todas as observações são dependentes:** A análise de séries temporais pressupõe que cada observação dependa das observações anteriores, estabelecendo uma interdependência entre os instantes de tempo. A ordem dos dados é essencial, ou seja, não podem ser embaralhados, pois a sequência temporal é fundamental para extrair informações significativas.
- **Dados faltantes devem ser inseridos:** Como todos os pontos de dados são sequenciais em séries temporais, se algum ponto de dados estiver ausente, ele deverá ser imputado antes do início do processo de análise real; caso contrário, a ordem adequada não é preservada.

- **Dois tipos diferentes de intervalos não podem ser misturados:** Os dados da série temporal são observados na mesma variável durante um determinado período de tempo com intervalos de tempo fixos e regulares. Embora os dados possam ser coletados em vários intervalos, como anual, mensal, semanal, diário, horário (por exemplo, temperatura) e/ou qualquer intervalo de tempo específico, o intervalo deve permanecer o mesmo em todo o intervalo; por exemplo, séries anuais não podem ser combinadas com séries trimestrais ou mensais;

São exemplos de séries temporais formais:

- I. Valores de despesas operacionais do **último ano** em uma empresa, tomados **mensalmente**;
- II. Valores **diários** de poluição na cidade de São Paulo;
- III. Valores **mensais** de temperatura na cidade de Canenéia – SP;
- IV. Índices **diários** da Bolsa de Valores de São Paulo;
- V. Precipitação atmosférica **anual** da cidade de Fortaleza;
- VI. Número de vendas **diárias** de um determinado produto;
- VII. Número médio **anual** de manchas solares;

3.1.1 Estacionariedade

Estacionariedade é um conceito fundamental em análise de séries temporais, que se refere a uma propriedade em que as propriedades estatísticas de uma série temporal são constantes ao longo do tempo. Em outras palavras, uma série temporal é considerada estacionária se sua média, variância e autocorrelação não mudam com o tempo.

Assim como a correlação mede a extensão de uma relação linear entre duas variáveis, a autocorrelação mede a relação linear entre valores defasados de uma série temporal (HYNDMAN, 2018).

A estacionariedade é uma suposição importante para muitos métodos de análise de séries temporais, pois permite a aplicação de modelos estatísticos que dependem de propriedades fixas da série ao longo do tempo. Em geral, é mais fácil analisar e prever uma série estacionária do que uma série não estacionária.

Existem duas formas de estacionariedade: estacionariedade estrita e estacionariedade fraca:

Estacionariedade estrita: uma série temporal é considerada estacionária estrita se sua distribuição de probabilidade é a mesma em todos os momentos do tempo. Isso significa que a média, variância e correlação não mudam com o tempo.

Estacionariedade fraca: uma série temporal é considerada estacionária fraca se sua média, variância e correlação não mudam de forma significativa ao longo do tempo. Nesse caso, a série não precisa ter a mesma distribuição de probabilidade em todos os momentos do tempo, mas sua estrutura estatística deve ser aproximadamente constante.

Função de autocovariância constante: A autocovariância é uma medida estatística que descreve como os valores da série estão correlacionados com seus próprios valores passados. Em uma série estacionária, a função de autocovariância deve ser aproximadamente constante ao longo do tempo, o que indica que a estrutura de dependência dos dados não muda.

Ausência de padrões sazonais ou cíclicos: Em uma série estacionária, não deve haver padrões sazonais ou cíclicos óbvios. Isso significa que a série não deve exibir variações sistemáticas relacionadas a períodos específicos ou ciclos repetitivos.

3.1.2 Funções de Autocovariância e Autocorrelação

Uma função bastante útil é a função de autocovariância (FACV), pois analisa a dependência entre as observações temporais, ajudando a descrever a estrutura de uma série temporal. (Cryer e Chan, 2008).

Função de Autocovariância (FACV): A função de autocovariância mede a covariância entre os valores de uma série temporal em diferentes defasagens. A FACV é denotada por $\gamma(h)$, onde h representa a defasagem. A fórmula geral da FACV é:

$$\gamma(h) = E[(Y_t - \mu)(Y_{t-h} - \mu)]$$

Onde:

E representa o operador de esperança.

Y_t e Y_{t-h} são os valores da série temporal em diferentes instantes de tempo.

μ é a média da série temporal.

Função de Autocorrelação (ACF): A função de autocorrelação (ACF) é uma versão normalizada da ACVF, que mede a correlação entre os valores de uma série temporal em diferentes defasagens. A ACF é denotada por $\rho(h)$, onde h representa a defasagem. A fórmula geral da ACF é:

$$\rho(h) = \frac{\gamma(h)}{\gamma(0)}$$

Onde:

$\gamma(h)$ é a função de autocovariância na defasagem h .

$\gamma(0)$ é a função de autocovariância na defasagem zero, que é a variância da série temporal.


3.1.3 Componentes da Série Temporal

Existem várias forças que podem afetar as observações em uma série temporal. Os quatro componentes importantes são:

- I. **Tendência:** ocorre quando a variável da série temporal apresenta um aumento ou diminuição a longo prazo;
- II. **Componente sazonal:** corresponde a um padrão fixo que se repete no mesmo período;
- III. **Ciclo:** é caracterizado pelas oscilações de subida e queda nas séries de forma suave e repetida ao longo do componente da tendência;
- IV. **Componente irregular:** movimentos randômicos explicados por causas desconhecidas.

Tendência (T_t): representa a direção geral que a série temporal segue ao longo do tempo, indicando se ela está aumentando ou diminuindo de forma constante. Por exemplo, o preço de uma ação pode aumentar ou diminuir linearmente ao longo de um período de tempo. As vendas de um novo produto podem aumentar exponencialmente (ou não linearmente). A Figura 1 mostra a tendência linear crescente do crescimento da arrecadação do ICMS, corrigida pelo IPCA, entre 2003 e 2022.

Figura 1. Gráfico da Série Temporal do ICMS com a Linha de Tendência



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Sazonalidade (S_t): Quando se trata de dados, a sazonalidade é qualquer tipo de comportamento recorrente no qual a frequência é estável (NIELSEN, 2021). Refere-se a padrões ou variações regulares que ocorrem em intervalos de tempo fixos e previsíveis. Esses padrões são repetidos ao longo do tempo e geralmente estão associados a fatores sazonais, como estações do ano, feriados, dias da semana ou qualquer outro ciclo recorrente. Por

exemplo, as vendas de guarda-chuva aumentam na estação chuvosa, enquanto as vendas de ar-condicionado aumentam no verão e as vendas de roupas de lã aumentam no inverno.

Ciclo (C_t): Um ciclo em uma série temporal é uma flutuação repetitiva que ocorre em um intervalo de tempo fixo ou aproximadamente fixo. É caracterizado por um padrão regular de oscilação entre valores mais altos e mais baixos em um intervalo de tempo específico. Os ciclos podem ser causados por fatores internos ou externos ao sistema que está sendo observado. Por exemplo, os ciclos podem ser influenciados por mudanças tecnológicas, demográficas ou políticas.

Irregularidade (I_t): Essas flutuações são puramente aleatórias, erráticas, imprevistas e imprevisíveis. Representa flutuações aleatórias que não podem ser explicadas pelos outros componentes e que são atribuídas ao acaso ou a fatores não controlados.

Tabela 4. Componentes de uma Série Temporal

Componente	Classificação	Explicação	Prazo
Tendência	Sistemático	Demografia, Tecnologia, Riqueza	Longo prazo (10 anos ou mais)
Cíclico	Sistemático	Ciclos de negócios ou ciclos naturais	Médio prazo
Sazonal	Sistemático	Condições climáticas e práticas culturais	Curto prazo
Irregular	Aleatório	Eventos não previstos (tempestades, tornados, greves, doenças)	Curto prazo (em geral) e sem repetição

Fonte:(NIELSEN, 2021)

Dados sazonais e dados cíclicos: As séries temporais sazonais são séries temporais em que os comportamentos se repetem durante um período fixo. É possível ter várias periodicidades refletindo diferentes ritmos de sazonalidade, como sazonalidade diária de 24 horas versus as estações do calendário de 12 meses, ambas as quais apresentam fortes características na maioria das séries temporais relacionadas ao comportamento humano (NIELSEN, 2021).

3.2 Métodos de Suavização Exponencial

A suavização de dados pode ser feita por vários motivos e, não raro, os dados de séries temporais do mundo real são suavizados antes da análise, sobretudo quando se trata de visualizações que têm como objetivo contar uma história compreensível sobre dados. (NIELSEN, 2021).

Em geral, métodos de previsão em séries temporais utilizam observações passadas para tentar discernir um padrão consistente de comportamento, enquanto filtram possíveis ruídos. O algoritmo de suavização exponencial é um procedimento de previsão que tenta lidar com ambos os aspectos de forma simultânea. Essa técnica foi proposta no final dos anos 1950 por Brown, Holt e Winters, e tem sido utilizada em alguns dos métodos de previsão mais bem-sucedidos.

Os métodos de suavização exponencial geram previsões a partir de médias ponderadas de observações passadas, em que os pesos associados decaem exponencialmente com o tempo. Isso significa que observações mais recentes têm mais peso na previsão do que observações mais antigas, permitindo que sejam geradas previsões confiáveis rapidamente e para uma ampla variedade de séries temporais.

Esta é uma extensão do método de média móvel, na suavização exponencial, os pesos atribuídos às observações diminuem exponencialmente à medida que nos afastamos no tempo, o que significa que as observações mais recentes recebem maior peso do que as observações mais antigas. Essa abordagem permite que o modelo capture mudanças mais recentes na série temporal, ao mesmo tempo em que suaviza os efeitos de flutuações aleatórias e oscilações de curto prazo.

Em outras palavras, a suavização exponencial é capaz de encontrar um equilíbrio entre a captura das tendências de longo prazo e a resposta rápida às mudanças mais recentes na série temporal. Ao usar a suavização, geralmente não vai se querer tratar todos os pontos de tempo de forma indiscriminada. Talvez queira tratar os dados mais recentes como dados mais informativos; nesse caso, a suavização exponencial é uma boa opção. Logo, para uma determinada janela, o ponto no tempo mais próximo tem peso mais denso e cada ponto anterior no tempo tem peso exponencialmente menor, por isso o nome (NIELSEN, 2021).

Tabela 5. Categorização da Série considerando Tendência e Sazonalidade

COMPONENTE DE TENDÊNCIA		COMPONENTE SAZONAL		
		N	A	M
		(Nenhum)	(Aditivo)	(Multiplicativo)
N	(Nenhum)	N,N	N,A	N,M
A	(Aditivo)	A,N	A,A	A,M
A _d	(Aditivo damped)	A _d ,N	A _d ,A	A _d ,M
M	(Multiplicativo)	M,N	M,A	M,M
M _d	(Multiplicativo)	M _d ,N	M _d ,A	M _d ,M

Fonte: (NIELSEN, 2021)

Algum desses métodos são mais conhecidos por outros nomes. Por exemplo, a célula (N,N) descreve o método da Suavização Exponencial Simples (SES), a célula (A,N) descreve o

método Linear Holt e a célula (Ad,N) descreve o método *damped trend*. As demais células correspondem a modelos não tão usuais, mas que funcionam de maneira análoga.

3.2.1 Método de Suavização Exponencial Simples (SES):

O método conhecido como Suavização Exponencial Simples - SES ou exponencial de um parâmetro é aplicável a séries temporais que não contêm tendência ou sazonalidade. A previsão pelo método SES é dada por:

$$\hat{y}_t = \alpha \cdot y_t + (1 - \alpha) \cdot \hat{y}_{t-1}$$

onde:

\hat{y}_t : valor previsto

\hat{y}_{t-1} : previsão anterior

y_t : é o valor observado no período t.

α : é o fator de suavização, $0 < \alpha < 1$, que controla o peso dado ao valor observado e à previsão anterior.

O parâmetro de suavização do nível é representado por α e varia entre 0 e 1. Quanto menor for o valor de α , mais estáveis serão as previsões, pois as observações passadas terão mais peso em comparação com um α grande, ou seja, mais próximo de 1.

A determinação do valor de α é o cerne do problema em questão. Uma abordagem plausível para sua escolha é realizar uma inspeção visual dos dados. Se a série exibir uma evolução suave, um valor alto para α faz sentido; por outro lado, se a série apresentar uma evolução errática, é mais adequado atribuir um peso menor à última observação. Alternativamente, pode-se adotar um procedimento mais objetivo, selecionando o valor de α que minimize a soma dos quadrados dos erros de previsão de um passo adiante.

$$SSE = \sum_{t=1}^n e_t^2$$

Onde:

SSE representa a soma dos quadrados dos erros;

$$e_t = y_t - \hat{y}_t.$$

Este método calcula a média ponderada dos valores observados e dos valores previstos na etapa anterior, atribuindo um peso exponencialmente decrescente aos valores observados à

medida que avança no tempo. É adequado para séries temporais com padrões de tendência leve ou sem tendência. Na realidade, tal série é difícil de encontrar, é possível utilizar este método ao identificar e remover tais efeitos, produzindo séries estacionárias. Como será visto mais a frente, é importante ressaltar que para o caso de SES, o conjunto de parâmetros ‘beta’ e ‘gama’ serão especificados com ‘FALSE’ (FERREIRA et al., [s.d.]). Os valores previstos por este método são todos idênticos, como podemos observar na tabela e no gráfico abaixo.

3.2.2 Método Holt (Exponencial Duplo - SEH):

Inicialmente proposto por Holt (1957) e depois estudado em Winters (1960), conhecido como Suavização Exponencial de Holt (SEH). Este método é uma extensão do SES. Uma possível aplicação do modelo SES acarretaria previsões que subestimariam ou superestimariam continuamente os valores reais da série. Ele usa dois parâmetros de suavização exponencial para estimar a tendência e a sazonalidade separadamente. O valor da previsão é dado por:

$$\begin{aligned} \text{Equação de Previsão} & \quad \hat{y}_{t+h} = \hat{y}_t + h \cdot b_t + s_{t-m+h} \\ \text{Equação do Nível:} & \quad \hat{y}_t = \alpha \cdot y_t + (1 - \alpha) \cdot (\hat{y}_{t-1} + b_{t-1}); \\ \text{Equação da Tendência:} & \quad b_t = \beta \cdot (\hat{y}_t - \hat{y}_{t-1}) + (1 - \beta) \cdot b_{t-1}; \\ \text{Equação da Sazonalidade:} & \quad s_t = \gamma \cdot (y_t - \hat{y}_t) + (1 - \gamma) \cdot s_{t-m} \end{aligned}$$

Onde:

- y_t é o valor observado no período t.
- \hat{y}_t é a previsão para o período t.
- b_t é a estimativa da tendência no período t.
- s_t é a estimativa da componente sazonal no período t.
- α é o fator de suavização do nível.
- β é o fator de suavização da tendência.
- γ é o fator de suavização da sazonalidade.
- h é o número de períodos à frente para a previsão.
- m é o comprimento do ciclo sazonal.
- n é o número total de períodos.

3.2.3 Método Holt-Winters (HW)

O método de suavização de Holt-Winters é uma técnica de previsão de séries temporais que estende a suavização exponencial dupla, adicionando um componente sazonal ao modelo. É adequado para prever séries temporais com tendência, sazonalidade e variação aleatória.

O método usa três parâmetros de suavização exponencial: alfa (α), beta (β) e gama (γ). Alfa é o parâmetro de suavização para a estimativa da média dos valores observados, beta é o parâmetro de suavização para a estimativa da tendência e gama é o parâmetro de suavização

para a estimativa da componente sazonal. Além disso, há um quarto parâmetro chamado de nível inicial, que é usado para estimar o primeiro valor previsto.

$$\begin{aligned}
 \text{Equação de Previsão} & \quad \hat{y}_{t+h} = \hat{y}_t + h \cdot b_t + s_{t-m+h} \\
 \text{Equação do Nível:} & \quad \hat{y}_t = \alpha \cdot (y_t - s_{t-m}) + (1 - \alpha) \cdot (\hat{y}_{t-1} + b_{t-1}) \\
 \text{Equação da Tendência:} & \quad b_t = \beta \cdot (\hat{y}_t - \hat{y}_{t-1}) + (1 - \beta) \cdot b_{t-1} \\
 \text{Equação da Sazonalidade:} & \quad s_t = \gamma \cdot (y_t - \hat{y}_t) + (1 - \gamma) \cdot s_{t-m}
 \end{aligned}$$

Onde:

y_t é o valor observado no período t.

\hat{y}_t é a previsão para o período t.

b_t é a estimativa da tendência no período t.

s_t é a estimativa da componente sazonal no período t.

α é o fator de suavização do nível.

β é o fator de suavização da tendência.

γ é o fator de suavização da sazonalidade.

h é o número de períodos à frente para a previsão.

m é o comprimento do ciclo sazonal.

Parâmetros de suavização: O método Holt-Winters possui três parâmetros de suavização, também conhecidos como *smoothing parameters*:

Parâmetro de suavização de nível (**alpha**): Representado por α , o parâmetro de suavização de nível controla a taxa de suavização da componente de nível ou média da série temporal. Ele varia entre 0 e 1, onde valores mais próximos de 1 dão mais peso aos valores recentes e resultam em uma suavização mais rápida da tendência.

Parâmetro de suavização de tendência (**beta**): Representado por β , o parâmetro de suavização de tendência controla a taxa de suavização da componente de tendência da série temporal. Assim como o parâmetro de suavização de nível, ele varia entre 0 e 1, e valores mais próximos de 1 dão mais peso aos valores recentes e resultam em uma adaptação mais rápida a mudanças na tendência.

Parâmetro de suavização de sazonalidade (**gama**): Representado por γ , o parâmetro de suavização de sazonalidade é específico para modelos de Holt-Winters com componente sazonal. Ele controla a taxa de suavização da componente de sazonalidade da série temporal. O parâmetro gama também varia entre 0 e 1, onde valores mais próximos de 1 dão mais peso aos valores recentes da sazonalidade.

Esses parâmetros de suavização são valores que precisam ser escolhidos e ajustados para cada série temporal específica. Eles afetam o quanto os valores passados e recentes contribuem para as previsões futuras. Valores menores resultam em uma suavização mais lenta e maior ênfase nos valores passados, enquanto valores maiores levam a uma adaptação mais rápida às mudanças recentes.

A escolha adequada dos parâmetros de suavização depende das características da série, como a quantidade de ruído, a regularidade da sazonalidade e a estabilidade da tendência.

Geralmente, é necessário realizar experimentos e ajustar os parâmetros para encontrar a combinação que melhor se adapte aos dados e produza previsões precisas. Métodos como a validação cruzada ou a minimização do erro de previsão podem ser usados para determinar os valores ótimos dos parâmetros.

O modelo Holt-Winters é iterativo, o que significa que as estimativas do nível, da tendência e da componente sazonal são atualizadas a cada período. Além disso, os valores de alfa, beta e gama podem ser ajustados para otimizar o modelo. O modelo Holt-Winters é útil para prever séries temporais com padrões sazonais bem definidos, como vendas de varejo, temperatura e demanda de energia.

Existem duas formas de aplicar o método de suavização de Holt-Winters: aditiva e multiplicativa. A principal diferença entre elas é a forma como a componente sazonal é incorporada no modelo:

I - HW aditivo (sazonalidade aditiva)

II - HW multiplicativo (sazonalidade multiplicativa)

3.2.3.1 Holt-Winters Aditivo

No modelo aditivo, a componente sazonal é adicionada diretamente à previsão, o que significa que a amplitude da sazonalidade é constante ao longo da série temporal. Ou seja, a variação sazonal é independente do nível da série temporal. A fórmula para o modelo aditivo de Holt-Winters é baseada na decomposição aditiva da série $Y_t = Tt + S_t + I_t$.

$$\begin{aligned} \text{Equação de Previsão:} \quad & \hat{y}_{t+h} = \hat{y}_t + h \cdot b_t + s_{t-m+h} \\ \text{Equação do Nível:} \quad & \hat{y}_t = \alpha \cdot (y_t - s_{t-m}) + (1 - \alpha) \cdot (\hat{y}_{t-1} + b_{t-1}) \\ \text{Equação da Tendência:} \quad & b_t = \beta \cdot (\hat{y}_t - \hat{y}_{t-1}) + (1 - \beta) \cdot b_{t-1} \\ \text{Equação da Sazonalidade:} \quad & s_t = \gamma \cdot (y_t - \hat{y}_t) + (1 - \gamma) \cdot s_{t-m} \end{aligned}$$

Onde:

y_t é o valor observado no período t.

\hat{y}_t é a previsão para o período t.

b_t é a estimativa da tendência no período t.

s_t é a estimativa da componente sazonal no período t.

α é o fator de suavização do nível.

β é o fator de suavização da tendência.

γ é o fator de suavização da sazonalidade.

h é o número de períodos à frente para a previsão.

m é o comprimento do ciclo sazonal.

3.2.3.2 Holt-Winters Multiplicativo

O modelo multiplicativo, a componente sazonal é multiplicada à previsão, o que significa que a amplitude da sazonalidade é proporcional ao nível da série temporal. Ou seja, a variação sazonal é dependente do nível da série temporal.

Este modelo é adequado para séries temporais em que a amplitude da sazonalidade varia à medida que o nível da série aumenta, ou seja, onde a variação na sazonalidade é proporcional ao nível.

Em resumo, a diferença entre o modelo aditivo e multiplicativo de Holt-Winters está na forma como a componente sazonal é incorporada na previsão. O modelo aditivo é adequado para séries temporais com variação sazonal constante, enquanto o modelo multiplicativo é adequado para séries temporais com variação sazonal proporcional ao nível da série temporal. A escolha entre os dois modelos depende do padrão de variação sazonal observado na série temporal.

$$\text{Equação de Previsão: } \hat{y}_t = \alpha \cdot \left(\frac{y_t}{s_{t-m}} \right) + (1 - \alpha) \cdot (\hat{y}_{t-1} + b_{t-1})$$

$$\text{Equação do Nível: } \hat{y}_t = \alpha \cdot \left(\frac{y_t}{s_{t-m}} \right) + (1 - \alpha) \cdot (\hat{y}_{t-1} + b_{t-1})$$

$$\text{Equação da Tendência: } b_t = \beta \cdot (\hat{y}_t - \hat{y}_{t-1}) + (1 - \beta) \cdot b_{t-1}$$

$$\text{Equação da Sazonalidade: } s_t = \gamma \cdot \left(\frac{y_t}{\hat{y}_t} \right) + (1 - \gamma) \cdot s_{t-m}$$

Onde:

y_t é o valor observado no período t .

\hat{y}_t é a previsão para o período t .

b_t é a estimativa da tendência no período t .

s_t é a estimativa da componente sazonal no período t .

α é o fator de suavização do nível.

β é o fator de suavização da tendência.

γ é o fator de suavização da sazonalidade.

h é o número de períodos à frente para a previsão.

m é o comprimento do ciclo sazonal.

3.3 Modelando a Série Temporal – Box & Jenkins

Os modelos de Box & Jenkins são amplamente utilizados para modelar séries temporais estacionárias ou que foram transformadas em estacionárias por meio de diferenciação. A metodologia de Box & Jenkins segue um ciclo iterativo composto por cinco partes, conforme descrito por Granger & Newbold em 1976.

Identificação: nesta fase, a série temporal é analisada para identificar possíveis padrões, tais como tendência, sazonalidade e autocorrelação. A partir desta análise, é escolhido um modelo inicial para ser ajustado.

Estimação: nesta fase, são estimados os parâmetros do modelo inicial escolhido na etapa anterior. Isso é feito por meio de técnicas de estimativa, como a máxima verossimilhança ou mínimos quadrados.

Diagnóstico: os resíduos do modelo são examinados para avaliar a qualidade do ajuste. Se houver indícios de que os resíduos não são aleatórios, o modelo deve ser refinado ou descartado. Nesta etapa, é realizada uma análise dos resíduos para verificar se eles apresentam comportamento de ruído branco, além de serem aplicados testes estatísticos, como o teste de Ljung-Box, para avaliar se o modelo proposto é adequado.

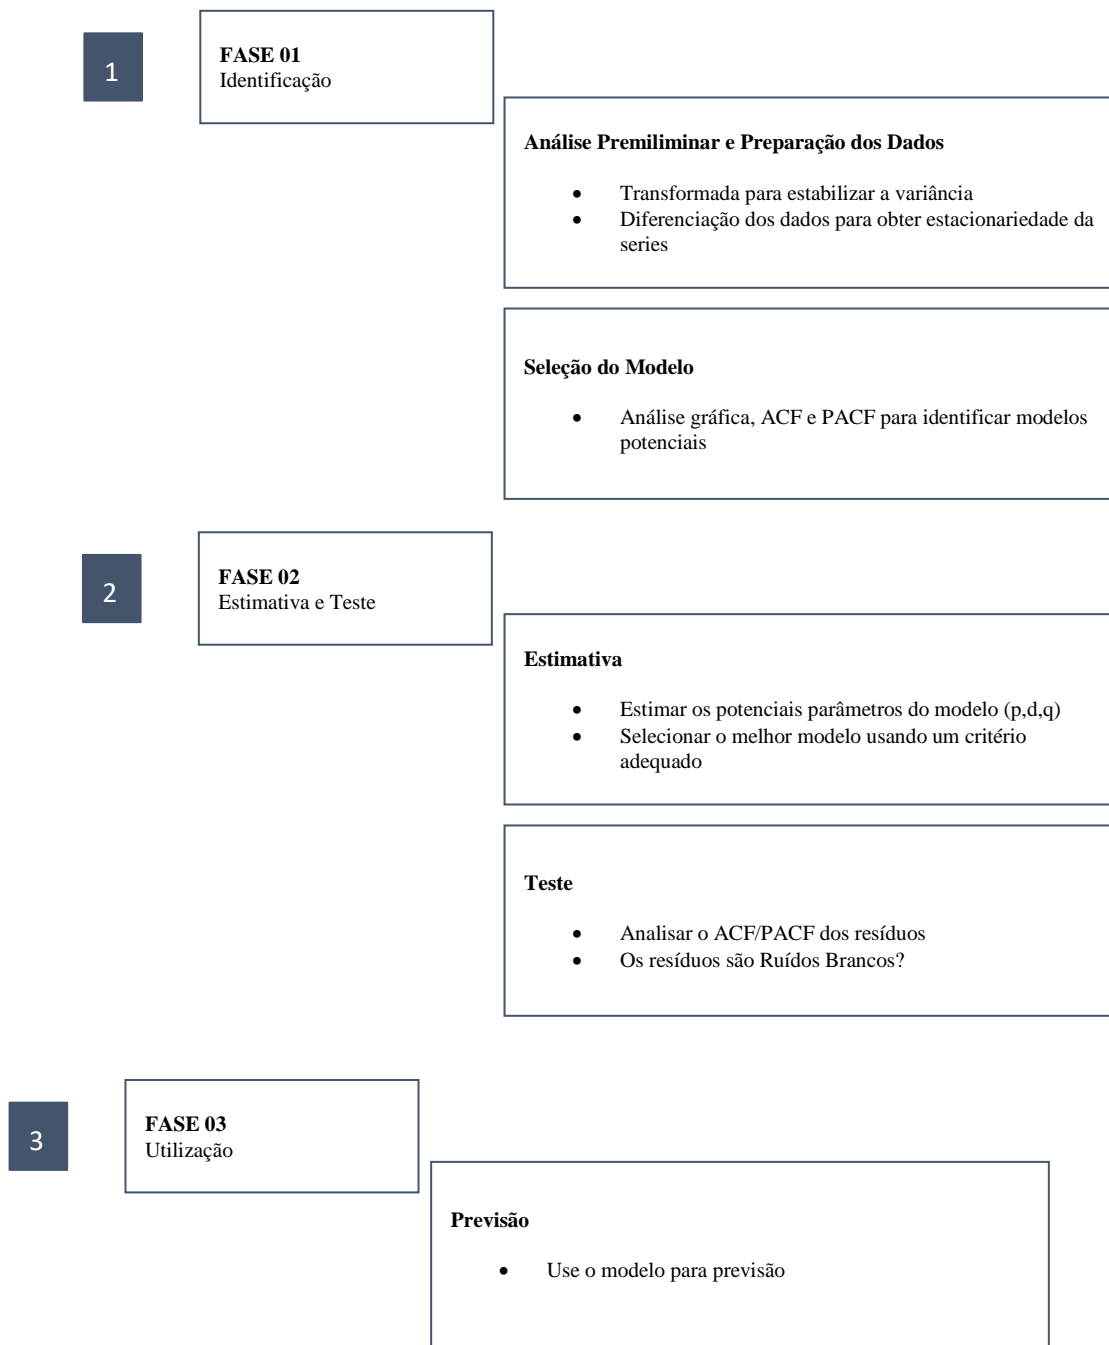
O teste de Ljung-Box é um teste estatístico utilizado em séries temporais para verificar a presença de autocorrelação nos resíduos de um modelo ajustado. O teste é especialmente importante em análise de séries temporais, onde a independência dos resíduos é uma suposição crítica para obter previsões válidas e confiáveis.

Em seguida, são comparados os modelos que apresentam os menores valores para os critérios AIC e BIC, que são utilizados para selecionar o modelo com a melhor relação entre ajuste e complexidade. Caso sejam identificados problemas no diagnóstico, o ciclo retorna à etapa de identificação para realizar novas modificações no modelo.

Modelagem: nesta fase, o modelo inicial é modificado com base nos resultados da etapa anterior, por meio da inclusão de novos termos ou modificação dos parâmetros.

Previsão: nesta fase, o modelo final é usado para fazer previsões para o futuro. É importante realizar uma avaliação da precisão das previsões para verificar a qualidade do modelo.

Esse ciclo é repetido até que um modelo final satisfatório seja alcançado. O processo de identificação, estimação, diagnóstico e modelagem é iterativo e pode ser repetido várias vezes para aprimorar o modelo, conforme fluxograma abaixo:



3.3.1 Modelos Autorregressivos – AR (p)

O modelo autorregressivo (AR) toma como base a intuição de que o passado prediz o futuro. Desse modo, ele pressupõe um processo de série temporal no qual o valor em um ponto no tempo t é uma função dos valores da série em pontos anteriores no tempo (NIELSEN, 2021).

O modelo autorregressivo de ordem p , AR(p), é um modelo matemático utilizado para modelar séries temporais. Ele assume que o valor atual da série é uma função linear dos seus p valores anteriores, acrescido de um erro aleatório. A equação do modelo AR(p) é dada por:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

Onde:

y_t é o valor observado no período t .

c é a constante do modelo.

$\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes de autoregressão do modelo.

$y_{t-1}, y_{t-2}, \dots, y_{t-p}$ são os valores observados anteriores.

ε_t é o termo de erro no período t .

ε_t é o termo de erro aleatório no momento t , que é normalmente distribuído com média zero e variância constantes, também descrito como **ruído branco** ou *white noise*, seus valores são aleatórios, independentes e igualmente distribuídos ao longo do tempo, sem nenhuma relação com os valores anteriores ou futuros da série temporal

3.3.2 Modelos de Média Móvel – MA(q)

Um modelo de média móvel (MA) é um método que se baseia na relação entre os valores atuais e os termos de "erro" dos valores passados mais recentes. Cada termo de erro é considerado independente dos outros. Os modelos de média móvel são usados na análise de séries temporais e pertencem a uma classe de modelos estatísticos. Assim como os modelos autorregressivos (AR), os modelos de média móvel também descrevem processos estocásticos que capturam o comportamento de uma série temporal ao longo do tempo. A estrutura desse modelo é semelhante à de um modelo autorregressivo, mas, em vez de usar valores passados do próprio processo, utiliza termos de erro presentes e passados na equação linear.

O modelo de média móvel é construído com base em um processo estocástico ε_t que representa o ruído aleatório ou erro em cada instante de tempo t . A equação do modelo MA é dada por:

$$y_t = c + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

Onde:

y_t é o valor observado no período t.

c é a constante do modelo.

$\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes de média móvel do modelo.

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ são os termos de erro anteriores.

ε_t é o termo de erro aleatório no momento t, que é normalmente distribuído com média zero e variância constante, também descrito como ruído branco ou *white noise*, seus valores são aleatórios, independentes e igualmente distribuídos ao longo do tempo, sem nenhuma relação com os valores anteriores ou futuros da série temporal

A ordem do modelo MA, q , representa o número de termos de erro passados que são usados para modelar a média móvel da série temporal. Assim como a ordem do modelo AR, a escolha da ordem do modelo MA é importante e deve ser determinada com cuidado, com base na análise dos dados e em critérios estatísticos.

Uma das principais características dos modelos MA é que eles são capazes de capturar padrões de curto prazo na série temporal, o que pode ser útil em previsões de curto prazo. Além disso, os modelos MA também podem ser combinados com os modelos AR para formar modelos ARMA, que são capazes de capturar tanto padrões de curto prazo quanto de longo prazo na série temporal. As principais características de um modelo MA(q) são:

3.3.3 Modelo ARMA(p,q)

O modelo ARMA (Autoregressive Moving Average) é um modelo combinado que abrange características do modelo AR (Autorregressivo) e do modelo MA (Média Móvel). É utilizado para modelar séries temporais em que o valor atual depende dos valores passados e dos termos de erro passados. A ordem do AR define quantos valores passados são utilizados para prever o valor atual, enquanto a ordem do MA define quantos termos de erro passados são considerados na previsão. O modelo ARMA(p,q) é definido pelas seguintes equações:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

Onde:

y_t é o valor observado no período t.

c é a constante do modelo.

$\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes de autoregressão do modelo.

$y_{t-1}, y_{t-2}, \dots, y_{t-p}$ são os valores observados anteriores.

$\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes de média móvel do modelo.

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ são os termos de erro anteriores.

ε_t é o termo de erro no período t.

3.3.4 Modelo ARIMA (p,d,q)

O modelo autorregressivo integrado de médias móveis (ARIMA, do inglês *Autoregressive Integrated Moving Average*) é um modelo estatístico amplamente utilizado para analisar e prever séries temporais. Ele combina elementos do modelo autorregressivo (AR), modelo de média móvel (MA) e inclui um componente de diferenciação integrada (I), que permite lidar com tendências e padrões não estacionários nos dados.

p : Número de termos autorregressivos

d : Número de diferenciações para estacionarizar a série

q : Número de termos da média móvel

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)(1 - L)^d y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) \varepsilon_t$$

Onde:

y_t é o valor observado no período t .

L é o operador de defasagem.

c é a constante do modelo.

$\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes de autoregressão do modelo.

q é a ordem da parte de média móvel do modelo.

$\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes de média móvel do modelo.

d é o número de diferenciações necessárias para tornar a série temporal estacionária.

ε_t é o termo de erro no período t .

Componente Autoregressivo (AR): Este componente descreve a relação entre a série temporal e suas observações anteriores. Um modelo AR de ordem p usa as p observações anteriores para prever o valor atual da série temporal.

Componente Integrado (I): Este componente é usado para remover tendências não estacionárias da série temporal, como uma tendência linear crescente ou decrescente. A ordem do componente integrado, d , indica o número de vezes que a série temporal foi diferenciada para torná-la estacionária.

Componente de Média Móvel (MA): Este componente descreve a relação entre a série temporal e seus erros de previsão anteriores. Um modelo MA de ordem q usa os q erros de previsão anteriores para prever o valor atual da série temporal.

Em geral, um modelo ARIMA pode ser escrito como ARIMA (p, d, q), onde p é a ordem do componente autoregressivo, d é a ordem do componente integrado e q é a ordem do componente de média móvel.

A seleção adequada dos parâmetros p, d, q é crucial para o modelo ARIMA. Ela é geralmente realizada por meio de técnicas como análise da função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) dos resíduos.

3.3.5 Modelo SARIMA(p,d,q)(P,D,Q)[m]

O modelo Seasonal ARIMA, também conhecido como SARIMA (Seasonal Autoregressive Integrated Moving Average), é uma extensão do modelo ARIMA que é projetado para lidar com séries temporais sazonais. Ele é particularmente útil quando há padrões sazonais claros e repetitivos nos dados.

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)(1 - \Phi_1 L^s - \Phi_2 L^{2s} - \dots - \Phi_P L^{Ps})(1 - L)^d(1 - L^s)^D y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q)(1 + \Theta_1 L^s + \Theta_2 L^{2s} + \dots + \Theta_Q L^{Qs}) \varepsilon_t$$

Onde:

y_t é o valor observado no período t.

L é o operador de defasagem regular.

L^s é o operador de defasagem sazonal.

c é a constante do modelo.

$\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes de autoregressão do modelo regular.

$\Phi_1, \Phi_2, \dots, \Phi_P$ são os coeficientes de autoregressão do modelo sazonal.

q é a ordem da parte de média móvel do modelo regular.

Q é a ordem da parte de média móvel do modelo sazonal.

$\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes de média móvel do modelo regular.

$\Theta_1, \Theta_2, \dots, \Theta_Q$ são os coeficientes de média móvel do modelo sazonal.

d é o número de diferenciações regulares necessárias para tornar a série temporal estacionária.

D é o número de diferenciações sazonais necessárias para tornar a série temporal estacionária.

s é o período da sazonalidade.

A definição do modelo SARIMA envolve vários parâmetros que descrevem a estrutura de autoregressão, média móvel, diferenciação e sazonalidade. Aqui estão os principais parâmetros do modelo SARIMA:

Parâmetros de Autoregressão (AR):

p: Ordem da parte autoregressiva regular, que representa a dependência linear dos valores passados da série temporal.

P: Ordem da parte autoregressiva sazonal, que representa a dependência linear dos valores passados em períodos sazonais.

Parâmetros de Média Móvel (MA):

q: Ordem da parte de média móvel regular, que representa a dependência linear dos erros passados da série temporal.

Q: Ordem da parte de média móvel sazonal, que representa a dependência linear dos erros passados em períodos sazonais.

Parâmetros de Diferenciação (I):

d: Número de diferenciações regulares necessárias para tornar a série temporal estacionária, ou seja, remover tendências e padrões de longo prazo.

D: Número de diferenciações sazonais necessárias para tornar a série temporal estacionária em períodos sazonais.

Parâmetros de Sazonalidade:

s: Período da sazonalidade, que indica o número de períodos em uma temporada completa.

Além desses parâmetros, o modelo SARIMA também inclui um termo de interceptação (c) que representa uma constante no modelo.

A fórmula geral do modelo SARIMA é uma combinação dos operadores de defasagem, diferenciação e sazonalidade, juntamente com os parâmetros correspondentes. Essa fórmula pode variar dependendo da ordem e das características específicas do modelo SARIMA, mas a estrutura geral envolve a aplicação dos operadores de defasagem (L e L^s) nos termos de autoregressão e média móvel, juntamente com os termos de diferenciação $(1 - L)^d$ e $(1 - L^s)^D$.

É importante selecionar adequadamente os valores dos parâmetros do modelo SARIMA para obter uma boa adequação aos dados e previsões precisas. Isso geralmente é feito por meio de técnicas como a análise dos gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF), além da avaliação de critérios de seleção de modelos, como o Critério de Informação de Akaike (AIC) e o Critério de Informação Bayesiano (BIC).

3.3.6 Medidas de acurácia de previsão

Um dos principais objetivos da análise de séries temporais é realizar previsões dos valores futuros. Para alcançar esse objetivo, é essencial selecionar o melhor método de previsão e avaliar a precisão das previsões geradas por esse método. Para isso, podemos considerar uma série temporal com t observações e remover as últimas n observações, formando uma nova série. Em seguida, podemos utilizar um modelo estimado para gerar n previsões com base nessa nova série e calcular os erros de previsão correspondentes:

$$e_t = y_t - \hat{y}_{t|t-1}$$

onde:

e_t é o erro de previsão no período t

y_t é o valor observado no período t

$\hat{y}_{t|t-1}$ é a previsão do valor no período t com base nas observações até o período $t - 1$

Medidas de acurácia de previsão comparam os valores previstos com os valores observados para quantificar o poder preditivo do modelo proposto. Existem várias medidas de acurácia de previsão que podem ser utilizadas em séries temporais. Algumas das mais comuns são:

Erro médio absoluto (Mean Absolute Error - MAE)

O MAE é a média das diferenças absolutas entre as previsões e os valores observados. O MAE é uma medida fácil de interpretar e calcular, pois não envolve a elevação de valores ao quadrado. A fórmula é:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Onde:

y_i é o valor observado na posição i da série temporal.

\hat{y}_i é o valor previsto na posição i da série temporal.

n é o número total de observações.

Erro quadrático médio (Mean Squared Error - MSE)

O MSE é a média das diferenças quadráticas entre as previsões e os valores observados. O MSE é uma medida mais sensível aos erros grandes do que o MAE, pois os erros são elevados ao quadrado. A fórmula é:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Onde:

y_i é o valor observado na posição i da série temporal.

\hat{y}_i é o valor previsto na posição i da série temporal.

n é o número total de observações.

Raiz do erro quadrático médio (Root Mean Squared Error - RMSE)

O RMSE é a raiz quadrada do MSE e é uma medida mais interpretável que o MSE, pois está na mesma escala da série temporal original. A fórmula é:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Onde:

y_i é o valor observado na posição i da série temporal.

\hat{y}_i é o valor previsto na posição i da série temporal.

n é o número total de observações.

Erro percentual absoluto médio (Mean Absolute Percentage Error - MAPE)

O MAPE é uma medida de acurácia de previsão que expressa o erro como uma porcentagem do valor real. É uma medida útil quando se deseja avaliar a precisão da previsão em termos relativos. A fórmula é:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%$$

Onde:

y_i é o valor observado na posição i da série temporal.

\hat{y}_i é o valor previsto na posição i da série temporal.

n é o número total de observações.

De acordo com (HYNDMAN, 2018), o MAPE é amplamente empregado por sua interpretação intuitiva, expressando o erro médio em termos percentuais, o que é valioso quando as magnitudes dos valores da série variam. Contudo, o uso do MAPE apresenta limitações: pode ser indefinido em valores próximos de zero ou negativos e não diferencia a

magnitude dos erros. Apesar dessas considerações, optamos pelo MAPE como indicador principal de qualidade em nossas previsões.

Capítulo 4

4. Base de dados utilizada e análise exploratória dos dados

Foram analisados dados do ICMS no período de janeiro de 2003 a dezembro de 2022, considerando valores nominais. Além desses valores, sujeitou-se esses montantes a ajustes conforme o IPCA (Índice Nacional de Preços ao Consumidor Amplo), o qual representa o índice oficial de inflação no Brasil, assegurando, assim, a devida atualização monetária. Adicionalmente, implementou-se o IPG-DI, um indicador econômico brasileiro que mensura a variação de preços de uma cesta de produtos e serviços ao longo do tempo. Este índice, calculado mensalmente pela Fundação Getúlio Vargas (FGV), tem como propósito oferecer uma medida abrangente da inflação no Brasil. Na apuração do crédito tributário, foram considerados o valor principal, a correção monetária, a multa e os juros. No entanto, os valores decorrentes de ação fiscal e da dívida ativa foram expurgados da análise, uma vez que poderiam distorcer a série histórica. Isso ocorre porque programas de recuperação de crédito, tais como o REGULARIZA (Lei nº 18.459, de 05 de maio de 2014), o FACILITA (Lei nº 20.939, de 28 de dezembro de 2020), geralmente são realizados no final do balanço orçamentário, o que pode resultar em aumento artificial da arrecadação em determinados períodos, principalmente nos últimos meses do ano.

Tabela 6. Quadro Resumo de descrições estatísticas da série do ICMS

Descrição estatística resumida da Série Temporal do ICMS atualizada pelo IPCA – função <i>summary</i>		
Métrica	Ano/Mês	Valor Total (em R\$)
Min. :	2006-04	608.889.177
1st Qu. :	2007-03	1.123.634.955
Median :	2012-06 e 2016-08	1.537.904.183
Mean :	2003-01 a 2022-12	1.456.326.019
3rd Qu. :	2013-08	1.717.638.254
Max. :	2021-10	2.319.203.262

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Verificamos que a arrecadação média mensal foi de aproximadamente **R\$ 1.456.000 milhão**. A arrecadação mediana, por sua vez, foi de cerca de **R\$ 1.537.904 milhão**. Os valores mínimo e máximo de arrecadação foram, respectivamente, R\$ 608.889 milhão e pouco mais de **R\$ 2.319.000 milhão**.

Além disso, observamos que a mediana da série temporal analisada foi superior à média. Isso sugere uma distribuição assimétrica dos valores, com uma cauda longa positiva. Essa diferença entre a mediana e a média geralmente ocorre devido à presença de valores extremos ou *outliers* na série temporal. Esses valores atípicos têm um impacto maior na média do que na mediana, uma vez que a média é sensível a esses valores extremos, enquanto a mediana é mais resistente a influências pontuais.

Além disso, é relevante destacar que este estudo não realizou a normalização das quedas de arrecadação decorrentes de eventos excepcionais, que também são conhecidas como

mudanças estruturais nos dados. No entanto, é relevante mencionar um exemplo recente que ilustra um panorama econômico desafiador enfrentado pelo Brasil, e, conseqüentemente por Goiás, a partir de 2020, impulsionado principalmente pela pandemia de COVID-19 e seus impactos significativos. A crise sanitária teve um impacto importante na atividade econômica do país, resultando em uma série de medidas adotadas pelo governo para mitigar os efeitos negativos.

Adicionalmente, merece destaque a promulgação da Lei Complementar (LC) 194/2022, a qual desempenhou um papel significativo ao reduzir as alíquotas do Imposto sobre Circulação de Mercadorias e Serviços (ICMS) em setores específicos. Esses fatores influenciaram tanto a atividade econômica quanto a arrecadação tributária no Brasil.

Tabela 7. Arrecadação do ICMS por Atividade Econômica Macro

ARRECAÇÃO do ICMS - por Semestre 2022				
GRUPO ATIVIDADE ECONÔMICA	Semestre 01	% Part	Semestre 02	% Part
COMBUSTÍVEL	3.389.664.278,51	26,93%	2.387.475.604,16	20,48%
COMÉRCIO ATACADISTA E DISTRIBUIDOR	2.169.039.701,78	17,23%	2.581.698.399,80	22,14%
INDÚSTRIA	2.118.040.933,18	16,82%	2.399.107.209,03	20,58%
COMÉRCIO VAREJISTA	1.793.059.101,68	14,24%	1.941.942.471,23	16,66%
ENERGIA ELÉTRICA	1.688.166.520,30	13,41%	906.232.535,35	7,77%
OUTRAS	393.366.687,48	3,12%	464.907.114,23	3,99%
PRESTAÇÃO DE SERVIÇO	315.777.133,36	2,51%	395.852.657,99	3,40%
COMUNICAÇÃO	426.478.331,98	3,39%	271.450.517,99	2,33%
PRODUÇÃO AGROPECUÁRIA	260.956.184,13	2,07%	268.359.746,65	2,30%
EXTRATOR MINERAL OU FÓSSIL	34.673.575,17	0,28%	42.010.040,88	0,36%
TOTAL	12.589.222.447,57	100,00%	11.659.036.297,31	100,00%
Participação dos Grupos Afetados pela LC 194	5.504.309.130,79	43,72%	3.565.158.657,50	30,58%

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

A LC 194 foi promulgada como parte dos esforços para estimular a economia. Essa lei teve como objetivo reduzir as alíquotas do ICMS em determinados setores, como combustíveis, telecomunicações, energia elétrica e transporte intermunicipal, segmentos com forte influência na arrecadação estadual. A redução das alíquotas visava diminuir os custos para as empresas e estimular o consumo, incentivando a retomada da atividade econômica. Essa medida teve impacto direto na arrecadação tributária, uma vez que a redução das alíquotas resultou em uma diminuição da receita proveniente do ICMS.

Tabela 8. Alterações de alíquotas do ICMS decorrentes da LC 194/2022

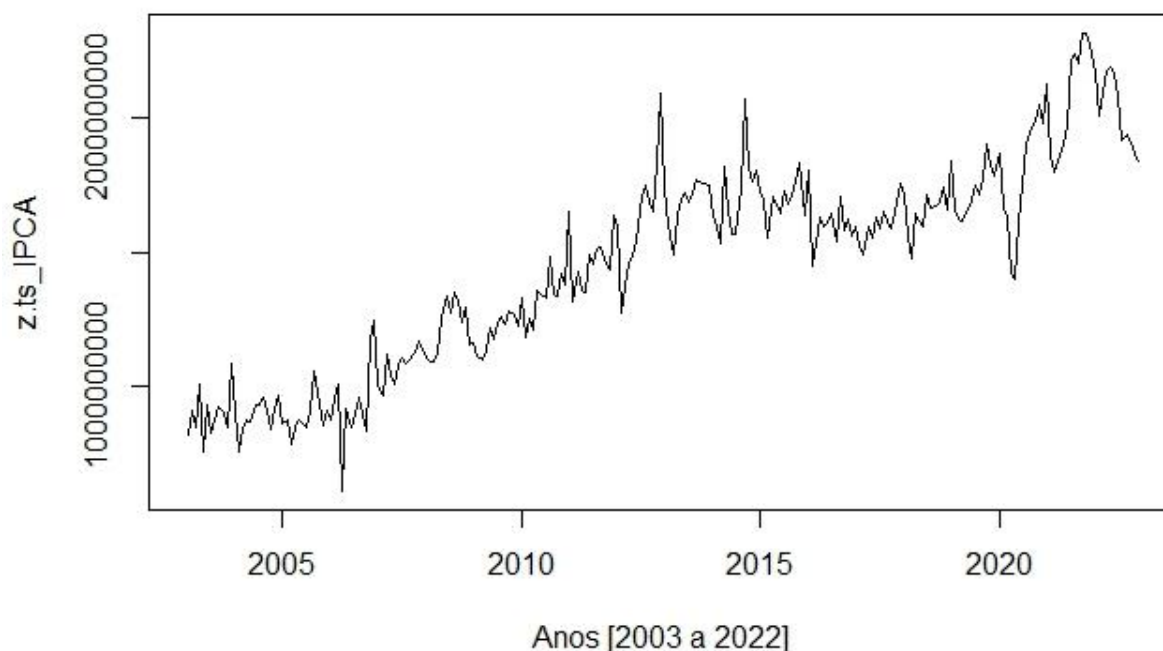
ALÍQUOTAS DO ICMS [LC 194/2022]		
Item	Alíquota Anterior	Alíquota Vigente
Gasolina	30,00%	17,00%
Diesel	16,00%	14,00%
Etanol hidratado	25,00%	14,17%
Energia elétrica	29,00%	17,00%
Comunicação	29,00%	17,00%

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

No entanto, é importante ressaltar que a pandemia e a redução das alíquotas do ICMS tiveram efeitos distintos nos diferentes setores da economia. Enquanto alguns setores enfrentaram uma redução drástica na demanda e na arrecadação tributária, outros conseguiram se adaptar ou até mesmo se beneficiar das mudanças no cenário econômico.

Figura 2. Arrecadação Espontânea do ICMS GO - 2003 a 2022

Arrecadação Espontânea do ICMS [Valor Atualizado pelo IPCA]



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Para realizar uma avaliação mais precisa das previsões da série em diferentes momentos no tempo, adotaremos uma abordagem *ex-ante* nos testes, dividindo os dados em partições em datas distintas. Essa estratégia nos permitirá verificar se a dinâmica da série varia ao longo do

tempo e nos auxiliará na seleção do modelo mais adequado para cada período específico. Ao aplicar análise prospectiva, poderemos assegurar que nossas previsões sejam adaptadas às possíveis mudanças na série temporal, garantindo assim maior precisão e confiabilidade em nossos resultados.

Nesse contexto, iremos modelar a série do ICMS, considerando os valores do período a partir de janeiro de 2003:

- 1) **Treino:** Jan/2003 a Dez/2018; **Teste:** Jan a Dez/2019, denominada '**Partição I**';
- 2) **Treino:** Jan/2003 a Dez/2019; **Teste:** Jan a Dez/2020, denominada '**Partição II**';
- 3) **Treino:** Jan/2003 a Dez/2020; **Teste:** Jan a Dez/2021, denominada '**Partição III**';
- 4) **Treino:** Jan/2003 a Dez/2021; **Teste:** Jan a Dez/2012, denominada '**Partição IV**'.

Os conjuntos de 'Treino' possuindo, respectivamente, 192, 204, 216 e 228 observações, em que serão consideradas para cada partição as previsões de 12 passos à frente (h), denominadas de coleções de 'Teste'.

O particionamento da série em várias datas distintas é fundamental para analisar o comportamento das previsões em diferentes momentos, considerando a variação dinâmica da série. Essa abordagem nos permite avaliar os impactos das mudanças drásticas no recolhimento do imposto, como as ocorridas durante a pandemia da Covid-19 e após a implementação da LC 194/2022, no desempenho do modelo. Como resultado, obtemos uma compreensão mais abrangente dos resultados obtidos, contribuindo para uma análise mais sólida e completa.

Além da segmentação mencionada anteriormente, os conjuntos de dados foram criados a partir da combinação de valores deflacionados pelo IPCA e IGP-DI, bem como por valores em nível e logaritimizadas. Essa combinação resultou em um total de 16 conjuntos de séries temporais distintas.

Capítulo 5

5. Análise dos Resultados

Neste capítulo serão apresentados os resultados encontrados na estimação dos modelos e na previsão do ICMS no Estado de Goiás. Para tanto, a partir de cinco dos modelos descritos no capítulo anterior – SES, SEHM, HWM, ARIMA e SARIMA; realizaram-se várias simulações, utilizando como base os dados, em valores reais corrigidos, em níveis e transformados para a escala logarítmica, referente ao período de 2003 a 2022, mensalmente, portanto, uma amostra de 240 meses:

5.1 Ajustes nas Séries

No desenvolvimento do trabalho, as séries coletadas sofreram ajustes. No caso da série arrecadação do ICMS, foram realizados ajustes na série temporal com o objetivo de eliminar o efeito de certas especificidades.

Para a análise, além da série original, os valores nominais das séries foram convertidos para valores reais, adotando como base o mês de janeiro de 2023, fixando o índice 100. Essa transformação foi realizada mediante a aplicação dos indexadores IPCA e IGP-DI, proporcionando uma contextualização mais precisa e atualizada ao longo do período estudado.

Por fim, em um dos três conjuntos de dados foi aplicado a transformação logarítmica conjuntamente com o deflator IGP-DI, que é um ajuste comum aplicado a séries temporais quando há uma tendência de crescimento exponencial nos dados. Ela envolve a aplicação do logaritmo natural (\ln) aos valores da série temporal. Essa transformação é útil quando a variação relativa dos dados é mais importante do que a variação absoluta.

5.2 Diferenciação da Série

A ideia por trás da diferenciação é remover uma tendência ou padrão de crescimento na série, tornando-a estacionária. Dependendo do caso, pode ser necessário aplicar a diferenciação várias vezes para alcançar a estacionariedade desejada.

A função *diff()* é uma função padrão do R que é usada para calcular diferenças entre elementos consecutivos em um vetor. Essa função calcula a diferença entre cada elemento de um vetor e o seu elemento imediatamente anterior, criando um vetor com essas diferenças.

Após a aplicação da função de diferenciação de primeira ordem *diff()* na série temporal {z.ts_IPCA} e a realização do teste de estacionariedade ADF, constatamos que esse procedimento efetivamente transforma a série em uma forma estacionária. A diferenciação, ao calcular a diferença entre cada valor consecutivo, permite remover tendências ou padrões de crescimento na série, tornando-a mais estacionária. Através do teste ADF, confirmamos que as propriedades estatísticas da série se tornam mais constantes ao longo do tempo após a aplicação

da diferenciação. Esse resultado é essencial para a aplicação de modelos de séries temporais e para garantir a validade das análises e previsões realizadas.

Ao prosseguir, aplicamos o teste ADF (Augmented Dickey-Fuller) à série após a diferenciação, constatando que esta se tornou estacionária após 01(uma) diferenciação, dado que o p-valor é inferior a 0,05.

Augmented Dickey-Fuller Test

data: z.ts_IPCA_diff

Dickey-Fuller = -8.5241, Lag order = 6, p-value = 0.01

alternative hypothesis: stationary


5.3 Determinação dos Parâmetros (p,q) do Modelo ARIMA

Nesta seção, apresentamos os resultados do modelo temporal utilizado para realizar as previsões de arrecadação de ICMS mensal. Primeiramente, realizamos o teste ADF para determinar a ordem de integração da série de ICMS, que se mostrou integrada de ordem 1 ($d = 1$). Portanto, estimamos um modelo ARIMA ($p, 1, q$).

Para garantir a solidez da modelagem, recorremos aos indicadores AIC (Critério de Informação de Akaike) e BIC (Critério de Informação Bayesiana). Esses critérios desempenham um papel fundamental na seleção do melhor modelo, levando em consideração tanto a qualidade do ajuste aos dados quanto a complexidade do modelo.

Apesar da análise gráfica não ter sido suficiente para verificar os parâmetros de forma conclusiva, a utilização desses indicadores oferece uma abordagem mais objetiva e imparcial. Os valores de AIC e BIC para cada modelo ajustado estão resumidos na tabela abaixo:

Figura 3. Testes ACF e PACF da Série Temporal



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Tabela 9. Comparativos de Informação – AIC e BIC entre modelos

Teste da Série Temporal ICMS IPCA {Partição I}		
Modelo (p,d,q)	AIC	BIC
(1,1,1)	7594.51	7604.26
(2,1,1)	7596.37	7609.38
(2,1,2)	7598.51	7614.77
(3,1,4)	7598.29	7624.31
(4,1,4)	7603.81	7633.08

* Coeficientes do melhor modelo (1,1,1): **ar1 0.2437; ma1 -0.7833**

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Para o modelo temporal em questão, os resultados do teste sugerem que os parâmetros p e q sejam iguais a 1 e 1, respectivamente. Portanto, procederemos à estimação do modelo ARIMA (1, 1, 1), o qual é composto por um termo autorregressivo de ordem 1, uma média móvel de ordem 1 e uma diferenciação de ordem 1.

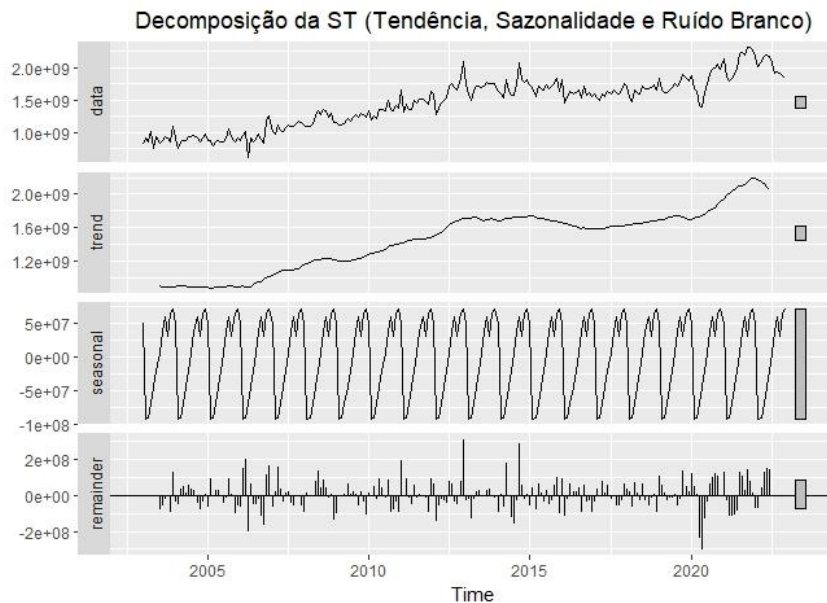
Nesse modelo, estamos levando em consideração tanto a autocorrelação dos dados ($p = 1$) quanto a média móvel ($q = 1$) para capturar as relações entre os valores passados e os erros passados da série temporal. Além disso, a diferenciação de ordem 1 ($d = 1$) é aplicada para tornar a série temporal estacionária e permitir um ajuste adequado do modelo.

O modelo ARIMA (1, 1, 1) é amplamente utilizado para séries temporais que apresentam tendências lineares e variações irregulares. Com sua estimação, estaremos preparados para analisar e fazer previsões sobre o comportamento da série temporal, considerando tanto os padrões de autocorrelação quanto as variações dos erros passados.

5.4 Testes de Sazonalidade

Para testar a sazonalidade de uma série temporal {z.ts_IPCA}, uma das principais funções utilizadas é o teste de decomposição sazonal, que pode ser aplicado em conjunto com outras técnicas estatísticas.

Figura 4. Decomposição da Série Temporal



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Teste Estatístico para detecção de sazonalidade:

O valor do teste representa a probabilidade associada à hipótese nula de que não há diferença significativa entre as duas amostras (componente sazonal e componente aleatória). Um p-valor maior que um nível de significância pré-determinado (geralmente 0,05) indica que há evidências para aceitar a hipótese nula e concluir que não existe uma diferença significativa entre as amostras, como podemos observar no gráfico acima.

kruskal-wallis rank sum test

```
data: sazonalidade by remainder
kruskal-wallis chi-squared = 239, df = 239, p-value = 0.4878
```

5.5 Modelagem e Previsão

Para a seleção das amostras de teste, procedemos com quatro divisões que englobaram distintos intervalos temporais. O horizonte de previsão foi mantido constante, abrangendo os doze meses subsequentes ao período de arrecadação do ICMS. Essa seleção também levou em conta fases com ocorrências atípicas na arrecadação, que se manifestaram nos anos de 2020, 2021 e 2022. Tais anos enfrentaram os impactos econômicos da pandemia de Covid-19 nos dois primeiros e, no último ano mencionado, as consequências decorrentes da Lei Complementar 194/2022 também foram consideradas.

- 1) ‘**Partição I**’: Treino: Jan/2003 a Dez/2018; Teste: Jan a Dez/2019;
- 2) ‘**Partição II**’: Treino: Jan/2003 a Dez/2019; Teste: Jan a Dez/2020;
- 3) ‘**Partição III**’: Treino: Jan/2003 a Dez/2020; Teste: Jan a Dez/2021;
- 4) ‘**Partição IV**’: Treino: Jan/2003 a Dez/2021; Teste: Jan a Dez/2012.

5.5.1 Partição I [2019]

IPCA

Tabela 10. Previsões dos modelos - Partição I – IPCA

Resumo: Previsões de Receita ICMS - IPCA - ano 2019						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/19	1.840.970.555	1.682.165.624	1.692.887.002	1.690.126.425	1.666.949.908	1.675.274.859
fev/19	1.657.009.049	1.682.165.624	1.696.928.020	1.543.815.000	1.669.303.506	1.672.574.348
mar/19	1.622.543.240	1.682.165.624	1.700.969.039	1.530.221.501	1.669.877.154	1.643.720.156
abr/19	1.614.543.630	1.682.165.624	1.705.010.057	1.589.586.176	1.670.016.971	1.697.118.183
mai/19	1.662.835.100	1.682.165.624	1.709.051.076	1.589.941.986	1.670.051.049	1.687.445.410
jun/19	1.693.777.090	1.682.165.624	1.713.092.094	1.632.600.241	1.670.059.354	1.692.829.912
jul/19	1.749.330.272	1.682.165.624	1.717.133.113	1.649.324.568	1.670.061.379	1.717.272.398
ago/19	1.718.671.603	1.682.165.624	1.721.174.132	1.674.622.160	1.670.061.872	1.725.264.294
set/19	1.779.057.237	1.682.165.624	1.725.215.150	1.720.033.576	1.670.061.993	1.718.574.469
out/19	1.902.031.656	1.682.165.624	1.729.256.169	1.665.117.620	1.670.062.022	1.727.072.917
nov/19	1.826.362.340	1.682.165.624	1.733.297.187	1.717.447.095	1.670.062.029	1.747.284.499
dez/19	1.788.371.770	1.682.165.624	1.737.338.206	1.742.772.567	1.670.062.031	1.746.808.096
TOTAL	20.855.503.542	20.185.987.488	20.581.351.245	19.745.608.915	20.036.629.268	20.451.239.541
	MAPE	5,0182	4,0240	5,6253	5,3084	3,4411

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

IGP-DI

Tabela 11. Previsões dos modelos - Partição I - IGP-DI

Resumo: Previsões de Receita ICMS - IGPDI - ano 2019						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/19	2.366.232.359	2.147.227.240	2.171.266.263	2.127.626.707	2.137.866.947	2.153.861.986
fev/19	2.135.137.566	2.147.227.240	2.178.275.673	1.928.515.172	2.142.456.032	2.109.122.287
mar/19	2.073.755.203	2.147.227.240	2.185.285.084	1.930.870.907	2.143.483.984	2.073.974.361
abr/19	2.056.934.206	2.147.227.240	2.192.294.494	2.017.549.186	2.143.714.244	2.138.580.332
mai/19	2.111.458.745	2.147.227.240	2.199.303.904	2.043.858.943	2.143.765.823	2.121.942.198
jun/19	2.144.967.519	2.147.227.240	2.206.313.314	2.049.348.077	2.143.777.376	2.107.005.904
jul/19	2.201.649.908	2.147.227.240	2.213.322.725	2.069.178.407	2.143.779.964	2.151.628.421
ago/19	2.167.347.568	2.147.227.240	2.220.332.135	2.119.131.467	2.143.780.544	2.131.259.873
set/19	2.257.404.411	2.147.227.240	2.227.341.545	2.149.635.110	2.143.780.674	2.129.698.719
out/19	2.400.401.026	2.147.227.240	2.234.350.956	2.064.303.307	2.143.780.703	2.126.404.671
nov/19	2.294.600.577	2.147.227.240	2.241.360.366	2.141.252.718	2.143.780.709	2.148.649.906
dez/19	2.239.293.703	2.147.227.240	2.248.369.776	2.166.791.040	2.143.780.711	2.122.050.165
TOTAL	26.449.182.791	25.766.726.880	26.517.816.235	24.808.061.041	25.717.747.711	25.514.178.823
MAPE		4,3087	3,6239	6,6445	4,3706	4,3696

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

LOG IGP-DI

Tabela 12. Previsões dos modelos - Partição I - Log IGP-DI

Resumo: Previsões de Receita ICMS - LOG IGPDI - ano 2019						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/19	2.366.220.989	2.146.533.388	2.179.758.657	2.129.578.692	2.141.473.542	2.182.659.665
fev/19	2.135.144.152	2.146.533.388	2.187.051.223	1.977.877.229	2.144.280.711	2.153.025.717
mar/19	2.073.761.614	2.146.533.388	2.194.368.187	1.988.387.807	2.144.602.377	2.131.048.609
abr/19	2.056.929.142	2.146.533.388	2.201.709.630	2.031.316.618	2.144.645.269	2.186.307.752
mai/19	2.111.448.412	2.146.533.388	2.209.075.634	2.056.538.363	2.144.645.269	2.179.061.246
jun/19	2.144.966.990	2.146.533.388	2.216.466.283	2.104.555.252	2.144.645.269	2.172.816.306
jul/19	2.201.643.580	2.146.533.388	2.223.881.657	2.101.421.800	2.144.645.269	2.212.635.111
ago/19	2.167.347.702	2.146.533.388	2.231.321.840	2.161.568.603	2.144.645.269	2.202.634.542
set/19	2.257.401.026	2.146.533.388	2.238.786.914	2.187.816.825	2.144.645.269	2.206.933.870
out/19	2.400.397.055	2.146.533.388	2.246.276.964	2.109.084.913	2.144.645.269	2.209.871.045
nov/19	2.294.589.965	2.146.533.388	2.253.792.072	2.171.469.578	2.144.645.269	2.232.527.079
dez/19	2.239.301.895	2.146.533.388	2.261.332.323	2.230.340.274	2.144.645.269	2.217.486.092
TOTAL	26.449.152.522	25.758.400.653	26.643.821.384	25.249.955.953	25.732.164.052	26.287.007.033
MAPE		4,3154	3,7491	4,7758	4,3484	3,2502

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

VALORES NOMINAIS – SÉRIE ORIGINAL

Tabela 13. Previsões dos modelos - Partição I - Nominal

Resumo: Previsões de Receita ICMS - NOMINAL - ano 2019						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/19	1.442.762.096	1.315.930.035	1.324.550.795	1.329.448.257	1.306.375.986	1.307.333.189
fev/19	1.302.747.113	1.315.930.035	1.330.168.384	1.218.063.920	1.308.194.490	1.306.204.696
mar/19	1.281.134.554	1.315.930.035	1.335.785.973	1.208.246.155	1.308.542.355	1.286.743.944
abr/19	1.284.378.835	1.315.930.035	1.341.403.561	1.302.512.420	1.308.608.898	1.329.106.106
mai/19	1.330.334.508	1.315.930.035	1.347.021.150	1.296.134.486	1.308.621.628	1.323.106.862
jun/19	1.356.851.193	1.315.930.035	1.352.638.739	1.309.694.349	1.308.624.063	1.331.407.410
jul/19	1.401.493.510	1.315.930.035	1.358.256.327	1.341.359.799	1.308.624.528	1.352.065.178
ago/19	1.379.547.941	1.315.930.035	1.363.873.916	1.358.859.196	1.308.624.618	1.362.967.694
set/19	1.429.590.193	1.315.930.035	1.369.491.505	1.392.615.695	1.308.624.635	1.357.920.818
out/19	1.527.797.488	1.315.930.035	1.375.109.093	1.348.348.649	1.308.624.638	1.366.943.116
nov/19	1.468.484.108	1.315.930.035	1.380.726.682	1.404.012.278	1.308.624.639	1.386.147.569
dez/19	1.445.271.695	1.315.930.035	1.386.344.271	1.388.436.838	1.308.624.639	1.390.812.851
TOTAL	16.650.393.234	15.791.160.420	16.265.370.396	15.897.732.042	15.700.715.117	16.100.759.433
	MAPE	6,4485	4,2758	4,9829	6,7761	4,0546

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Análise - Partição I [2019]

Em relação às previsões para o ano de 2019, período caracterizado por relativa estabilidade, resultando em uma arrecadação com poucas oscilações significativas, demonstramos abaixo os melhores modelos para cada tipo de série temporal:

Tabela 14. Resumo dos melhores modelos por Série

Melhores Modelos por Tipo de Série - Análise Partição I - 2019		
Série Temporal	Algoritmo	MAPE
IPCA	SARIMA (0,1,2)(0,0,2)[12] with drift	3,441115956
IGP-DI	SEHM	3,623887265
LOG IGP-DI	SARIMA(2,1,1)(1,0,0)[12] with drift	3,250153109
NOMINAL	SARIMA (0,1,2)(0,0,2)[12] with drift	4,054623167

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

O SARIMA (2,1,1)(1,0,0)[12] obteve o menor MAPE (3,2502), quando utilizamos a série temporal logaritimizada atualizada pelo IGP-DI, {LOG IGPDI}.

O segundo melhor modelo foi a Suavização Exponencial Holt Multiplicativo (SEHM) sobre a série em nível e com atualização pelo IGPDI, com MAPE (3,6239) – {IGPDI}. Esse algoritmo, em geral, tem baixo viés em relação a outras técnicas de previsão, o que significa que, em média, suas previsões não são excessivamente otimistas nem pessimistas.

Ao analisar a série temporal deflacionada pelo IPCA "em nível" {IPCA}, constatou-se que nenhum dos algoritmos apresentados neste comparativo proporcionou resultados satisfatórios para essa série em particular.

Vale ressaltar que as divergências nos valores da arrecadação real entre {IGPDI} e {LoG IGPDI} decorrem da aplicação do logaritmo natural (Ln) e da subsequente reversão desses valores para sua escala original.


Figura 5. Coeficientes do Modelo SARIMA

Coefficients					
	ar1	ar2	ma1	sar1	drift
	0.0984	-0.0356	-0.8006	0.2242	0.0032
s.e.	0.1083	0.0950	0.0811	0.0748	0.0016

A combinação de um coeficiente AR(1) positivo e um AR(2) negativo em um modelo AR(2), apresentado no resultado acima, sugere uma dinâmica específica. A série apresenta uma tendência geral de crescimento devido ao coeficiente AR(1) positivo. No entanto, também exibe oscilações periódicas influenciadas pelos valores de dois períodos anteriores, graças ao coeficiente AR(2) negativo. Esse conjunto de características resulta em uma série que manifesta um padrão de crescimento acompanhado por flutuações regulares.

Por outro lado, a presença de um coeficiente MA(1) negativo em um modelo de média móvel traz à tona um comportamento distinto. Nesse cenário, a série temporal responde de maneira contrária às variações no erro anterior, instaurando uma espécie de "correção" automática na direção oposta. Esse efeito pode ser interpretado como um mecanismo de amortecimento que busca reconduzir a série à sua média histórica após ocorrerem choques ou perturbações nos resíduos anteriores.


Figura 6. Gráfico do algoritmo SARIMA - Treino vs Validação



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Teste dos Resíduos do melhor Modelo: SARIMA (2,1,1)(1,0,0)[12] { LOG IGPD I }

Figura 7. Teste ACF e PACF dos Resíduos



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Após a definição da melhor estrutura e a estimativa dos parâmetros do modelo, outra etapa fundamental é o diagnóstico do modelo. Nessa fase, é essencial analisar e confirmar as seguintes características dos resíduos, que são as diferenças entre os valores reais e os valores previstos pelo modelo. Esses testes têm o propósito de garantir que os resíduos apresentem certas propriedades estatísticas desejáveis.

1) Modelo: SARIMA {LOG IGPD I}

a) Teste de Autocorrelação (Ljung-Box);

Se os resíduos forem aleatórios e não correlacionados, espera-se que o teste não apresente autocorrelações significativas nos resíduos. Caso contrário, isso indica que o modelo de previsão não capturou toda a estrutura temporal da série. Nesse cenário, torna-se importante considerar melhorias no modelo para aprimorar suas capacidades de previsão.

Resultado: p-valor [0.9372] - **não auto correlacionados**

b) Número de diferenciações:

Através desse teste, é possível determinar a ordem de diferenciação necessária para remover tendências e padrões sazonais dos resíduos e torná-los estacionários.

Resultado: ndiffs [0] – não é preciso fazer diferenciações na série;

c) SARIMA;

O objetivo é verificar se ainda existe alguma estrutura temporal remanescente que pode ser capturada pelo modelo e garantir que os resíduos apresentem características de um ruído branco.

Resultado: (0,0,0)(1,0,1)[12] with zero mean , o teste indicou que os resíduos apresentam componentes autorregressivos (P) e de média móvel (Q) na parte sazonal, portanto, esse modelo não capturou toda a estrutura temporal da série.

d) Teste de Normalidade (Shapiro-Wilk Test):

O teste de normalidade, como o teste de Shapiro-Wilk, é aplicado para verificar se os resíduos seguem uma distribuição normal.

Resultado: p-value = 4.303e-08 - a amostra **não** segue uma distribuição normal

5.5.2 Partição II [2020]

IPCA

Tabela 15. Previsões dos modelos - Partição II – IPCA

Resumo: Previsões de Receita ICMS - IPCA - ano 2020						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/20	1.869.909.914	1.799.467.863	1.805.937.958	1.789.010.555	1.778.927.287	1.831.187.731
fev/20	1.665.098.820	1.799.467.863	1.809.999.644	1.630.398.911	1.776.608.731	1.776.514.105
mar/20	1.633.833.219	1.799.467.863	1.814.061.329	1.652.514.520	1.776.039.542	1.763.490.347
abr/20	1.420.370.267	1.799.467.863	1.818.123.015	1.746.804.557	1.775.899.810	1.775.698.634
mai/20	1.399.390.521	1.799.467.863	1.822.184.701	1.761.507.192	1.775.865.506	1.791.010.491
jun/20	1.610.418.676	1.799.467.863	1.826.246.386	1.796.743.241	1.775.857.085	1.794.762.361
jul/20	1.751.063.371	1.799.467.863	1.830.308.072	1.820.936.230	1.775.855.018	1.828.450.779
ago/20	1.903.088.078	1.799.467.863	1.834.369.758	1.849.517.439	1.775.854.510	1.813.418.259
set/20	1.970.823.312	1.799.467.863	1.838.431.444	1.913.701.490	1.775.854.386	1.834.305.180
out/20	1.989.100.369	1.799.467.863	1.842.493.129	1.832.384.974	1.775.854.355	1.873.289.937
nov/20	2.052.418.876	1.799.467.863	1.846.554.815	1.848.692.516	1.775.854.348	1.859.720.610
dez/20	1.979.777.260	1.799.467.863	1.850.616.501	1.918.337.329	1.775.854.346	1.835.129.333
TOTAL	21.245.292.683	21.593.614.356	21.939.326.752	21.560.548.954	21.314.324.924	21.776.977.767
MAPE		10,5816	9,9786	7,4908	10,7115	9,0777

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

IGP-DI

Tabela 16. Previsões dos modelos - Partição II - IGP-DI

Resumo: Previsões de Receita ICMS - IGPDI - ano 2020						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/20	2.327.779.488	2.260.258.886	2.280.164.892	2.282.905.603	2.237.882.298	2.299.936.318
fev/20	2.075.238.672	2.260.258.886	2.287.546.865	2.057.804.271	2.237.558.669	2.229.908.439
mar/20	2.041.118.756	2.260.258.886	2.294.928.837	2.077.320.009	2.237.484.463	2.204.050.687
abr/20	1.746.954.345	2.260.258.886	2.302.310.810	2.159.417.640	2.237.467.447	2.214.186.984
mai/20	1.714.962.602	2.260.258.886	2.309.692.782	2.190.276.311	2.237.463.546	2.223.404.424
jun/20	1.945.252.524	2.260.258.886	2.317.074.755	2.205.698.298	2.237.462.651	2.217.919.343
jul/20	2.087.209.781	2.260.258.886	2.324.456.727	2.243.305.323	2.237.462.446	2.252.472.389
ago/20	2.224.560.744	2.260.258.886	2.331.838.700	2.277.266.822	2.237.462.399	2.229.136.805
set/20	2.223.148.468	2.260.258.886	2.339.220.672	2.322.579.011	2.237.462.388	2.252.466.826
out/20	2.185.987.758	2.260.258.886	2.346.602.645	2.272.066.082	2.237.462.386	2.291.344.404
nov/20	2.194.207.736	2.260.258.886	2.353.984.617	2.325.182.901	2.237.462.385	2.268.231.583
dez/20	2.080.598.376	2.260.258.886	2.361.366.590	2.352.371.918	2.237.462.385	2.233.509.328
TOTAL	24.847.019.250	27.123.106.632	27.849.188.892	26.766.194.189	26.850.093.463	26.916.567.530
MAPE		8,8896	11,1365	7,6411	8,1299	7,9462

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

LOG IGP-DI

Tabela 17. Previsões dos modelos - Partição II - Log IGP-DI

Resumo: Previsões de Receita ICMS - LOG IGPD - ano 2020						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/20	2.327.777.997	2.253.589.240	2.274.372.438	2.232.571.730	2.242.080.351	2.309.830.541
fev/20	2.075.234.508	2.253.589.240	2.281.981.542	2.076.563.083	2.242.416.688	2.263.685.332
mar/20	2.041.110.787	2.253.589.240	2.289.639.000	2.092.467.859	2.242.461.537	2.254.310.504
abr/20	1.746.954.809	2.253.589.240	2.297.299.179	2.097.328.020	2.242.461.537	2.255.753.725
mai/20	1.714.967.557	2.253.589.240	2.304.984.987	2.161.157.944	2.242.461.537	2.275.100.354
jun/20	1.945.257.119	2.253.589.240	2.312.719.635	2.216.133.838	2.242.461.537	2.289.135.334
jul/20	2.087.201.478	2.253.589.240	2.320.457.033	2.215.070.349	2.242.461.537	2.308.722.089
ago/20	2.224.571.167	2.253.589.240	2.328.220.316	2.272.326.424	2.242.461.537	2.306.253.077
set/20	2.223.147.897	2.253.589.240	2.336.032.933	2.296.127.855	2.242.461.537	2.333.814.756
out/20	2.185.979.831	2.253.589.240	2.343.848.328	2.258.123.510	2.242.461.537	2.372.926.879
nov/20	2.194.214.586	2.253.589.240	2.351.689.869	2.295.668.676	2.242.461.537	2.354.490.046
dez/20	2.080.595.525	2.253.589.240	2.359.581.241	2.342.419.016	2.242.461.537	2.347.319.792
TOTAL	24.847.013.260	27.043.070.882	27.800.826.501	26.555.958.302	26.909.112.412	27.671.342.428
MAPE		8,6693	11,0247	7,1835	8,3001	10,3904

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

VALORES NOMINAIS – SÉRIE ORIGINAL

Tabela 18. Previsões dos modelos - Partição II - Nominal

Resumo: Previsões de Receita ICMS - NOMINAL - ano 2020						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/20	1.528.545.913	1.454.830.747	1.458.302.924	1.478.582.520	1.445.757.519	1.479.185.373
fev/20	1.363.982.108	1.454.830.747	1.464.745.341	1.343.398.799	1.445.845.063	1.437.820.293
mar/20	1.341.716.873	1.454.830.747	1.471.187.759	1.342.649.822	1.445.860.838	1.430.609.543
abr/20	1.167.235.598	1.454.830.747	1.477.630.177	1.430.165.993	1.445.863.681	1.444.368.493
mai/20	1.146.429.893	1.454.830.747	1.484.072.595	1.425.668.655	1.445.864.193	1.460.436.224
jun/20	1.314.298.500	1.454.830.747	1.490.515.013	1.446.093.698	1.445.864.286	1.465.864.846
jul/20	1.432.797.299	1.454.830.747	1.496.957.431	1.486.052.905	1.445.864.302	1.496.647.333
ago/20	1.562.796.023	1.454.830.747	1.503.399.849	1.495.555.640	1.445.864.305	1.487.005.129
set/20	1.622.304.570	1.454.830.747	1.509.842.266	1.549.229.409	1.445.864.306	1.505.745.162
out/20	1.647.829.254	1.454.830.747	1.516.284.684	1.532.469.980	1.445.864.306	1.539.452.351
nov/20	1.714.906.910	1.454.830.747	1.522.727.102	1.559.704.758	1.445.864.306	1.530.487.015
dez/20	1.668.933.614	1.454.830.747	1.529.169.520	1.563.280.832	1.445.864.306	1.513.376.446
TOTAL	17.511.776.556	17.457.968.964	17.924.834.661	17.652.853.011	17.350.241.411	17.790.998.208
MAPE		11,3350	10,1832	7,4249	11,4058	9,3489

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Análise - Partição II [2020]

Resumo dos melhores modelos, 2020:

Tabela 19. Resumo dos melhores modelos por Série

Melhores Modelos por Tipo de Série - Análise Partição II - 2020		
Série Temporal	Algoritmo	MAPE
IPCA	HWM	7,490793670
IGP-DI	HWM	7,641131102
LOG IGP-DI	HWM	7,183473702
NOMINAL	HWM	7,424932795

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

O ano de 2020 foi amplamente afetado pela pandemia da COVID-19, resultando em erros absolutos de previsão que atingiram até 22% (vinte e dois por cento), especialmente nos meses de abril a junho, como destacado na tabela abaixo. Entre os cinco algoritmos analisados (SES, SEHM, HWM, ARIMA e SARIMA), o modelo Holt-Winters Multiplicativo demonstrou a melhor habilidade em capturar os valores previstos, sendo as séries {LOG IGP-DI} e {NOMINAL} que apresentaram os dois Erros Percentuais Médios Absolutos mais baixos, 7,1835 e 7,4249 respectivamente.

Tabela 20. Previsões do modelo HWM - Partição I - IGP-DI

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.282.905.603	1,965648
fevereiro-20	2.075.238.672	2.057.804.271	0,847233
março-20	2.041.118.756	2.077.320.009	1,742690
abril-20	1.746.954.345	2.159.417.640	19,100673
maio-20	1.714.962.602	2.190.276.311	21,701084
junho-20	1.945.252.524	2.205.698.298	11,807860
julho-20	2.087.209.781	2.243.305.323	6,958283
agosto-20	2.224.560.744	2.277.266.822	2,314445
setembro-20	2.223.148.468	2.322.579.011	4,281040
outubro-20	2.185.987.758	2.272.066.082	3,788548
novembro-20	2.194.207.736	2.325.182.901	5,632897
dezembro-20	2.080.598.376	2.352.371.918	11,553171
<i>alfa</i>	0.2587	AIC	8.716.116
<i>beta</i>	0.0034	BIC	8.772.524
<i>gama</i>	1,00E-04	MAPE	7,641131
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,0)[12] with zero mean		0.003536717

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

5.5.3 Partição III [2021]

IPCA

Tabela 21. Previsões dos modelos - Partição III – IPCA

Resumo: Previsões de Receita ICMS - IPCA - ano 2021						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/21	2.127.521.083	1.987.732.284	1.993.247.393	1.948.651.991	1.917.503.986	1.923.332.158
fev/21	1.863.411.442	1.987.732.284	1.997.325.127	1.790.885.991	1.893.179.611	1.858.228.991
mar/21	1.798.387.854	1.987.732.284	2.001.402.860	1.771.279.185	1.883.678.339	1.844.814.570
abr/21	1.844.786.660	1.987.732.284	2.005.480.594	1.854.024.207	1.879.967.077	1.793.999.545
mai/21	1.904.591.749	1.987.732.284	2.009.558.327	1.829.148.578	1.878.517.431	1.787.567.680
jun/21	1.973.741.052	1.987.732.284	2.013.636.061	1.890.221.803	1.877.951.190	1.840.895.957
jul/21	2.223.561.962	1.987.732.284	2.017.713.794	1.927.524.607	1.877.730.012	1.878.107.996
ago/21	2.243.792.299	1.987.732.284	2.021.791.528	1.945.586.775	1.877.643.618	1.920.545.501
set/21	2.206.743.739	1.987.732.284	2.025.869.261	2.018.612.393	1.877.609.872	1.937.858.500
out/21	2.319.203.262	1.987.732.284	2.029.946.994	1.946.800.629	1.877.596.691	1.938.668.876
nov/21	2.315.946.455	1.987.732.284	2.034.024.728	1.982.202.637	1.877.591.542	1.963.599.687
dez/21	2.275.533.924	1.987.732.284	2.038.102.461	2.016.778.025	1.877.589.531	1.949.848.588
TOTAL	25.097.221.481	23.852.787.408	24.188.099.128	22.921.716.821	22.596.558.900	22.637.468.049
MAPE		9,8601	9,0560	9,3835	12,4101	11,1151

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

IGP-DI

Tabela 22. Previsões dos modelos - Partição III - IGP-DI

Resumo: Previsões de Receita ICMS - IGPDI - ano 2021						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/21	2.248.976.766	2.134.629.270	2.152.884.570	2.117.112.076	2.103.121.509	2.135.431.568
fev/21	1.918.898.708	2.134.629.270	2.159.960.723	1.941.381.593	2.110.366.994	2.063.900.980
mar/21	1.818.665.188	2.134.629.270	2.167.036.875	1.932.290.479	2.112.697.800	2.055.272.554
abr/21	1.842.932.341	2.134.629.270	2.174.113.027	1.980.829.164	2.113.447.599	1.963.214.115
mai/21	1.867.147.284	2.134.629.270	2.181.189.180	1.995.804.710	2.113.688.802	1.953.288.171
jun/21	1.886.890.034	2.134.629.270	2.188.265.332	2.017.504.796	2.113.766.395	2.025.831.158
jul/21	2.134.605.389	2.134.629.270	2.195.341.485	2.053.561.009	2.113.791.356	2.070.535.115
ago/21	2.143.711.810	2.134.629.270	2.202.417.637	2.097.745.520	2.113.799.386	2.113.781.364
set/21	2.129.575.118	2.134.629.270	2.209.493.789	2.127.661.514	2.113.801.969	2.113.337.424
out/21	2.276.479.957	2.134.629.270	2.216.569.942	2.080.382.782	2.113.802.800	2.101.637.928
nov/21	2.265.530.496	2.134.629.270	2.223.646.094	2.134.952.283	2.113.803.067	2.104.225.955
dez/21	2.260.271.378	2.134.629.270	2.230.722.247	2.137.865.616	2.113.803.153	2.068.457.190
TOTAL	24.793.684.469	25.615.551.240	26.301.640.901	24.617.091.542	25.349.890.830	24.768.913.522
MAPE		7,2827	7,5053	5,0537	7,5059	5,9823

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

LOG IGP-DI

Tabela 23. Previsões dos modelos - Partição III - Log IGP-DI

Resumo: Previsões de Receita ICMS - LOG IGPDI - ano 2021						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/21	2.248.974.114	2.127.705.487	2.145.975.362	2.031.519.760	2.106.513.399	2.150.271.607
fev/21	1.918.903.949	2.127.705.487	2.152.358.383	1.868.347.150	2.111.701.801	2.103.692.561
mar/21	1.818.667.633	2.127.705.487	2.158.781.977	1.867.058.435	2.112.736.788	2.101.610.936
abr/21	1.842.925.331	2.127.705.487	2.165.203.090	1.864.912.552	2.112.948.072	2.029.245.731
mai/21	1.867.151.790	2.127.705.487	2.171.643.302	1.899.658.557	2.112.990.332	2.024.563.584
jun/21	1.886.897.910	2.127.705.487	2.178.102.670	1.915.816.999	2.112.990.332	2.091.045.464
jul/21	2.134.610.433	2.127.705.487	2.184.603.097	1.915.050.826	2.112.990.332	2.131.091.230
ago/21	2.143.701.833	2.127.705.487	2.191.101.013	1.969.902.724	2.112.990.332	2.168.431.647
set/21	2.129.578.692	2.127.705.487	2.197.618.256	1.965.829.243	2.112.990.332	2.172.599.035
out/21	2.276.488.589	2.127.705.487	2.204.176.926	1.896.868.110	2.112.990.332	2.168.323.228
nov/21	2.265.519.660	2.127.705.487	2.210.733.063	1.938.421.851	2.112.990.332	2.174.794.469
dez/21	2.260.269.747	2.127.705.487	2.217.308.700	1.925.516.345	2.112.990.332	2.151.691.255
TOTAL	24.793.689.680	25.532.465.847	26.177.605.837	23.058.902.552	25.347.822.715	25.467.360.748
MAPE		7,3208	7,4100	8,6076	7,5095	5,9208

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

VALORES NOMINAIS – SÉRIE ORIGINAL

Tabela 24. Previsões dos modelos - Partição III - Nominal

Resumo: Previsões de Receita ICMS - NOMINAL - ano 2021						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/21	1.817.692.898	1.674.717.493	1.680.242.473	1.639.707.384	1.634.989.226	1.638.292.642
fev/21	1.596.024.898	1.674.717.493	1.684.506.732	1.487.506.247	1.619.438.556	1.550.608.176
mar/21	1.553.578.425	1.674.717.493	1.688.770.991	1.475.474.467	1.612.314.452	1.532.896.579
abr/21	1.608.482.539	1.674.717.493	1.693.035.250	1.527.858.441	1.609.050.743	1.467.467.549
mai/21	1.665.774.485	1.674.717.493	1.697.299.509	1.527.982.945	1.607.555.566	1.465.539.864
jun/21	1.740.582.200	1.674.717.493	1.701.563.767	1.578.802.042	1.606.870.593	1.520.696.258
jul/21	1.971.284.501	1.674.717.493	1.705.828.026	1.635.916.121	1.606.556.791	1.554.083.096
ago/21	2.008.315.461	1.674.717.493	1.710.092.285	1.676.335.672	1.606.413.032	1.596.808.102
set/21	1.992.338.600	1.674.717.493	1.714.356.544	1.721.390.751	1.606.347.173	1.622.755.512
out/21	2.118.159.797	1.674.717.493	1.718.620.803	1.711.053.951	1.606.317.001	1.639.681.406
nov/21	2.141.624.193	1.674.717.493	1.722.885.062	1.758.371.936	1.606.303.179	1.655.751.200
dez/21	2.124.245.391	1.674.717.493	1.727.149.321	1.741.037.016	1.606.296.846	1.650.197.329
TOTAL	22.338.103.389	20.096.609.916	20.444.350.763	19.481.436.973	19.328.453.158	18.894.777.713
MAPE		13,8905	12,5285	14,3024	16,4523	17,9670

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Análise - Partição III [2021]

Resumo dos melhores modelos, 2021:

Tabela 25. Resumo dos melhores modelos por Série

Melhores Modelos por Tipo de Série - Análise Partição III - 2021		
Série Temporal	Algoritmo	MAPE
IPCA	SEHM	9,056010353
IGP-DI	HWM	5,053709074
LOG IGP-DI	SARIMA(1,1,1)(0,0,1)[12] with drift	5,920767916
NOMINAL	HWM	14,302379841

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Em relação às previsões para o ano de 2021, ano ainda sob o impacto da COVID-19, porém com restrições menos severas as que enfrentadas em 2020, portanto caracterizado por relativa estabilidade, resultando em uma arrecadação com poucas oscilações significativas, os algoritmos mencionados acima demonstraram que o Método de Previsão: HW Multiplicativo (Holt-Winters) aplicado sobre a série {IGP-DI} em nível apresentou o menor MAPE (5,053709), seguido pelo SARIMA(1,1,1)(0,0,1)[12] with drift, $h = 12$, cujo o MAPE resultou em (5,920768), quando utilizamos a série temporal logaritimizada atualizada pelo IGP-DI, {LOG IGPDI}.

Ao analisar a série temporal deflacionada pelo IPCA no nível do índice {IPCA}, nota-se que nenhum dos algoritmos apresentados neste estudo comparativo produziu resultados satisfatórios para essa série em particular.

5.5.4 Partição IV [2022]

IPCA

Tabela 26. Previsões dos modelos - Partição IV – IPCA

Resumo: Previsões de Receita ICMS - IPCA - ano 2022						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/22	2.168.718.063	2.283.819.716	2.290.414.979	2.254.542.768	2.232.533.353	2.298.360.254
fev/22	2.010.344.554	2.283.819.716	2.294.532.538	2.034.722.068	2.215.243.563	2.236.766.107
mar/22	2.105.051.580	2.283.819.716	2.298.650.097	2.025.392.238	2.208.291.636	2.225.467.090
abr/22	2.181.862.606	2.283.819.716	2.302.767.655	2.098.926.443	2.205.496.386	2.259.388.820
mai/22	2.194.776.679	2.283.819.716	2.306.885.214	2.116.252.984	2.204.372.464	2.284.094.131
jun/22	2.171.386.951	2.283.819.716	2.311.002.773	2.182.018.277	2.203.920.555	2.292.675.017
jul/22	2.083.925.804	2.283.819.716	2.315.120.331	2.243.984.603	2.203.738.849	2.357.321.938
ago/22	1.916.927.201	2.283.819.716	2.319.237.890	2.281.041.534	2.203.665.789	2.355.631.007
set/22	1.940.686.950	2.283.819.716	2.323.355.448	2.334.423.700	2.203.636.413	2.345.859.331
out/22	1.914.744.207	2.283.819.716	2.327.473.007	2.281.942.003	2.203.624.601	2.383.787.690
nov/22	1.867.793.793	2.283.819.716	2.331.590.566	2.314.969.352	2.203.619.852	2.380.803.226
dez/22	1.842.880.471	2.283.819.716	2.335.708.124	2.325.340.522	2.203.617.942	2.379.989.061
TOTAL	24.399.098.859	27.405.836.592	27.756.738.622	26.493.556.492	26.491.761.403	27.800.143.672
MAPE		10,9712	12,0667	9,4338	7,9056	12,0909

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

IGP-DI

Tabela 27. Previsões dos modelos - Partição IV - IGP-DI

Resumo: Previsões de Receita ICMS - IGPDI - ano 2022						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/22	2.143.050.126	2.237.648.932	2.256.423.645	2.219.971.605	2.190.454.376	2.225.255.967
fev/22	1.957.871.168	2.237.648.932	2.265.185.812	2.026.964.188	2.165.124.511	2.131.150.214
mar/22	2.040.168.672	2.237.648.932	2.273.947.980	2.001.313.777	2.155.934.744	2.109.898.362
abr/22	2.099.142.137	2.237.648.932	2.282.710.147	2.056.206.337	2.152.600.662	2.139.256.456
mai/22	2.125.165.471	2.237.648.932	2.291.472.314	2.079.480.745	2.151.391.045	2.152.732.543
jun/22	2.097.920.244	2.237.648.932	2.300.234.482	2.104.010.673	2.150.952.192	2.146.443.134
jul/22	2.014.323.063	2.237.648.932	2.308.996.649	2.162.856.422	2.150.792.974	2.205.863.849
ago/22	1.847.234.446	2.237.648.932	2.317.758.817	2.195.589.873	2.150.735.209	2.202.091.940
set/22	1.873.765.635	2.237.648.932	2.326.520.984	2.255.636.989	2.150.714.252	2.203.583.076
out/22	1.866.052.284	2.237.648.932	2.335.283.152	2.200.844.364	2.150.706.649	2.251.306.771
nov/22	1.842.388.225	2.237.648.932	2.344.045.319	2.253.448.137	2.150.703.890	2.249.201.210
dez/22	1.828.467.463	2.237.648.932	2.352.807.487	2.262.371.780	2.150.702.889	2.258.907.388
TOTAL	23.735.548.934	26.851.787.184	27.655.386.788	25.818.694.890	25.870.813.393	26.275.690.910
MAPE		11,6053	14,1059	8,8071	8,2635	9,5472

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

LOG IGP-DI

Tabela 28. Previsões dos modelos - Partição IV - Log IGP-DI

Resumo: Previsões de Receita ICMS - LOG IGPDI - ano 2022						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/22	2.143.058.819	2.209.097.725	2.199.618.999	2.122.859.845	2.180.412.683	2.221.947.721
fev/22	1.957.864.157	2.209.097.725	2.206.514.592	1.983.542.055	2.162.000.960	2.116.627.803
mar/22	2.040.172.092	2.209.097.725	2.213.409.669	1.989.203.213	2.157.681.279	2.085.365.549
abr/22	2.099.132.498	2.209.097.725	2.220.326.291	2.000.674.079	2.156.667.407	2.095.504.138
mai/22	2.125.175.024	2.209.097.725	2.227.286.800	2.101.316.731	2.156.430.186	2.106.639.793
jun/22	2.097.915.354	2.209.097.725	2.234.246.787	2.118.512.440	2.156.365.495	2.116.670.135
jul/22	2.014.325.023	2.209.097.725	2.241.250.935	2.174.555.255	2.156.365.495	2.192.109.151
ago/22	1.847.242.826	2.209.097.725	2.248.254.558	2.255.686.053	2.156.365.495	2.198.959.212
set/22	1.873.773.221	2.209.097.725	2.255.280.066	2.325.381.620	2.156.365.495	2.199.421.042
out/22	1.866.050.496	2.209.097.725	2.262.350.152	2.285.887.069	2.156.365.495	2.243.538.177
nov/22	1.842.390.960	2.209.097.725	2.269.419.707	2.356.445.084	2.156.365.495	2.245.109.204
dez/22	1.828.460.147	2.209.097.725	2.276.511.354	2.396.775.190	2.156.365.495	2.248.164.629
TOTAL	23.735.560.616	26.509.172.703	26.854.469.908	26.110.838.633	25.907.750.977	26.070.056.555
MAPE		10,4628	11,5587	10,0522	8,3905	8,9584

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

VALORES NOMINAIS – SÉRIE ORIGINAL

Tabela 29. Previsões dos modelos - Partição IV - Nominal

Resumo: Previsões de Receita ICMS - NOMINAL - ano 2022						
Ano/Mês	Arrecadação Real	SES	SEHM	HWM	ARIMA	SARIMA
jan/22	2.039.309.399	2.125.290.828	2.137.526.091	2.206.085.125	2.114.511.005	2.160.513.384
fev/22	1.900.594.766	2.125.290.828	2.146.963.145	1.974.820.100	2.111.533.214	2.088.114.691
mar/22	2.010.233.050	2.125.290.828	2.156.400.199	1.931.713.892	2.110.622.295	2.077.898.115
abr/22	2.117.339.360	2.125.290.828	2.165.837.253	1.997.842.615	2.110.343.640	2.085.200.550
mai/22	2.152.448.554	2.125.290.828	2.175.274.307	2.025.588.071	2.110.258.399	2.101.717.097
jun/22	2.139.518.768	2.125.290.828	2.184.711.361	2.121.915.537	2.110.232.323	2.148.271.581
jul/22	2.067.099.810	2.125.290.828	2.194.148.415	2.212.506.768	2.110.224.346	2.238.616.628
ago/22	1.888.519.662	2.125.290.828	2.203.585.469	2.216.070.735	2.110.221.906	2.274.396.359
set/22	1.905.045.270	2.125.290.828	2.213.022.523	2.250.666.717	2.110.221.160	2.274.766.716
out/22	1.874.127.530	2.125.290.828	2.222.459.577	2.270.251.295	2.110.220.931	2.314.501.359
nov/22	1.838.960.709	2.125.290.828	2.231.896.631	2.315.946.374	2.110.220.861	2.342.775.094
dez/22	1.821.870.433	2.125.290.828	2.241.333.685	2.315.985.170	2.110.220.840	2.341.526.433
TOTAL	23.755.067.310	25.503.489.936	26.273.158.656	25.839.392.399	25.328.830.920	26.448.298.007
MAPE		7,1802	9,5170	10,3788	6,8334	10,4846

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Análise - Partição IV [2022]

Resumo dos melhores modelos, 2022:

Tabela 30. Resumo dos melhores modelos por Série

Melhores Modelos por Tipo de Série - Análise Partição IV - 2022		
Série Temporal	Algoritmo	MAPE
IPCA	ARIMA (1,1,1)	7,905552797
IGP-DI	ARIMA (1,1,1)	8,263456293
LOG IGP-DI	ARIMA (1,1,1)	8,390528908
NOMINAL	ARIMA (1,1,1)	6,833423529

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Durante o primeiro semestre de 2022, a arrecadação transcorreu de forma estável, apresentando valores nominais superiores aos detectados no ano anterior, em 2021. Entretanto, a partir de julho, começamos a sentir os efeitos das medidas decorrentes da LC 194/2022, resultando em uma redução significativa na arrecadação do ICMS.

Ao aplicar o algoritmo ARIMA[1,1,1] à série original – valores nominais {NOMINAL}, observou-se que ele exibiu o menor MAPE – 6,8334.

Destaca-se ainda o desempenho do modelo Holt-Winters Multiplicativo, quando aplicado à série temporal {IPCA}. Este algoritmo figura como o segundo melhor, conforme detalhado na Tabela 26 apresentada anteriormente, consolidando sua posição como uma opção de alto desempenho para a análise desta série.

Na tabela abaixo, destacamos esses dois momentos para o algoritmo ARIMA (1,1,1) da série {IPCA} e apresentamos o MAPE para os dois semestres separadamente e constatamos um aumento no erro de 3,29 % para 12,52% e no agregado, 7,90%

Tabela 31. Previsões do modelo ARIMA - Partição IV – IPCA

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022	Correção: IPCA		Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.232.533.353	2,858425
fevereiro-22	2.010.344.554	2.215.243.563	9,249503
março-22	2.105.051.580	2.208.291.636	4,675110
abril-22	2.181.862.606	2.205.496.386	1,071586
maio-22	2.194.776.679	2.204.372.464	0,435307
junho-22	2.171.386.951	2.203.920.555	1,476170
julho-22	2.083.925.804	2.203.738.849	5,436808
agosto-22	1.916.927.201	2.203.665.789	13,011891
setembro-22	1.940.686.950	2.203.636.413	11,932525
outubro-22	1.914.744.207	2.203.624.601	13,109329
novembro-22	1.867.793.793	2.203.619.852	15,239746
dezembro-22	1.842.880.471	2.203.617.942	16,370237
<i>ar1</i>	0.4021	AIC	9048.3
<i>ma1</i>	-0.7866	BIC	9058.58
		MAPE	7,905553
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		16.803.280

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Tabela 32. Previsão I Semestre de 2022

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.232.533.353	2,858425
fevereiro-22	2.010.344.554	2.215.243.563	9,249503
março-22	2.105.051.580	2.208.291.636	4,675110
abril-22	2.181.862.606	2.205.496.386	1,071586
maio-22	2.194.776.679	2.204.372.464	0,435307
junho-22	2.171.386.951	2.203.920.555	1,476170
<i>ar1</i>	0.4021	AIC	9048.3
<i>ma1</i>	-0.7866	BIC	9058.58
		MAPE	3,294350
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		16.803.280

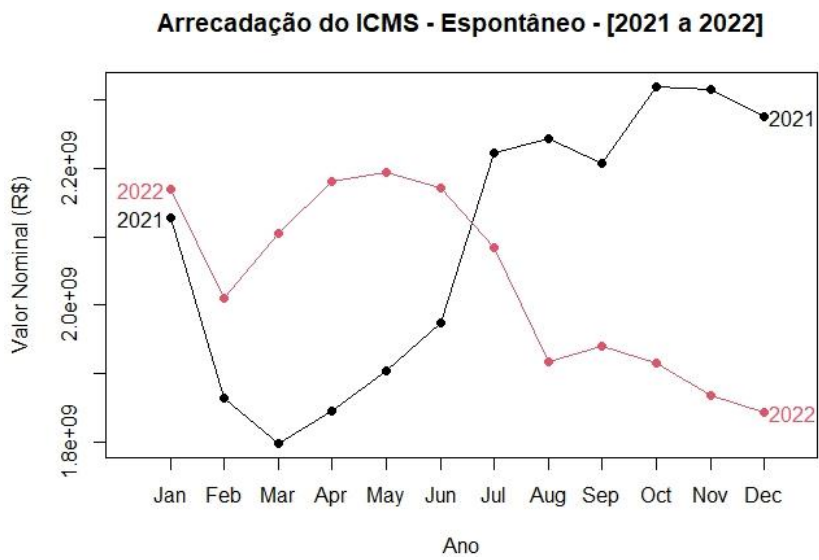
Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Tabela 33. Previsão II Semestre de 2022

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
julho-22	2.083.925.804	2.203.738.849	5,436808
agosto-22	1.916.927.201	2.203.665.789	13,011891
setembro-22	1.940.686.950	2.203.636.413	11,932525
outubro-22	1.914.744.207	2.203.624.601	13,109329
novembro-22	1.867.793.793	2.203.619.852	15,239746
dezembro-22	1.842.880.471	2.203.617.942	16,370237
<i>ar1</i>	0.4021	AIC	9048.3
<i>ma1</i>	-0.7866	BIC	9058.58
		MAPE	12,516756
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		16.803.280

Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Tabela 34. Valor nominal da Arrecadação do ICMS - 2021 e 2022



Fonte: Secretaria de Estado da Economia - GO, elaboração própria

Capítulo 6

6 Conclusão

A essência desta dissertação concentrou-se na avaliação de diferentes estratégias univariadas voltadas para a modelagem e previsão da arrecadação. Foram avaliados cinco algoritmos, dos quais três estão vinculados a métodos de alisamento exponencial (SES, Holt e Holt-Winters Multiplicativo), enquanto os outros dois adotam abordagens do tipo Box-Jenkins (ARIMA e SARIMA). Essas análises foram aplicadas tanto a séries temporais com valores nominais, como deflacionadas por meio de dois índices distintos (IPCA e IGP-DI), quanto a valores em nível, e também foram testadas em uma versão logaritimizada para o índice IGP-DI.

A aplicação de valores deflacionados proporciona uma análise adicional das variações reais. No entanto, é crucial ressaltar que essa abordagem pode obscurecer tendências subjacentes e dificultar a identificação de padrões autênticos. A precisão dos índices de preços utilizados na deflação assume importância central, visto que sua inadequação pode introduzir incertezas adicionais no processo.

A relevância do ICMS para a sustentabilidade econômica dos estados é incontestável, exercendo um papel crucial, especialmente no contexto do Estado de Goiás. Nesse cenário, a fração arrecadada por meio desse tributo atinge expressivos 81,02% das receitas fiscais estaduais. Como resultado, a dinâmica da arrecadação emerge como uma preocupação de alta magnitude para as autoridades administrativas, uma vez que uma diminuição inesperada nesse fluxo comprometeria substancialmente a capacidade de cumprir as obrigações fiscais.

O objetivo primordial é fundamentar essa previsão com base em abordagens amplamente empregadas por outros pesquisadores que se dedicaram ao mesmo tema.

Nessa perspectiva, considerando um horizonte de previsão constante e igual a 12 meses (h), o algoritmo que apresentou os melhores resultados para o ano de 2019 foi o SARIMA (2,1,1)(1,0,0)[12], quando utilizamos a série temporal logaritimizada atualizada pelo IGP-DI.

Ao analisarmos o horizonte de previsão para o ano de 2020, um período amplamente impactado pela pandemia da COVID-19, o modelo Holt-Winters Multiplicativo para a série {LOG IGP-DI} demonstrou maior habilidade em capturar os valores previstos, devido à sua projeção mais conservadora, alinhada com a realidade apresentada pela pandemia, que provocou uma queda no montante arrecadado.

Considerando o cenário do ano de 2021, marcado ainda pelos impactos restritivos da pandemia, destaca-se a persistente eficácia do modelo Holt-Winters Multiplicativo na previsão de receita para a série {IGP-DI}. Este algoritmo continua a revelar-se como a escolha mais apropriada para enfrentar os desafios específicos desse período, garantindo precisão e confiabilidade nas projeções.

Em 2022, a arrecadação manteve-se estável, registrando valores nominais superiores aos de 2021. Entretanto, a partir de julho, os efeitos das medidas decorrentes da LC 194/2022 começaram a ser percebidos, resultando em uma redução significativa na arrecadação do ICMS. Para esse cenário, o modelo mais adequado para o horizonte de 12 meses, abrangendo

um semestre de relativa normalidade e outro de redução acentuada de recursos, foi o algoritmo ARIMA (1,1,1) aplicado à série com valores nominais.

Nesse sentido, é possível constatar que, em situações de arrecadação regular, a série ajustada pelo IGP-DI revela-se mais apropriada. Tal constatação encontra respaldo na medida em que o ICMS é sensível à taxa de câmbio, devido à sua incidência sobre importações – um fator econômico que encontra representação mais precisa no IGP-DI do que no IPCA. No entanto, em cenários atípicos, essa correlação pode ser enfraquecida por outros elementos econômicos de maior relevância. Tomemos o período de pandemia, por exemplo, quando diversos insumos foram beneficiados por isenções tributárias, o que potencialmente contribuiu para um maior distanciamento em relação ao IGP-DI.

Finalmente, diante dos diversos cenários possíveis, podemos considerar uma abordagem de combinação de modelos univariados, para abranger a ampla gama de possibilidades que se apresentam. A utilização de modelos multivariados para o período da pandemia pode se mostrar promissor como futuro tema de pesquisa, permitindo uma análise mais abrangente e robusta das previsões futuras da arrecadação do ICMS.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, T. R. C. de. Previsão de Arrecadação Tributária na Crise: Alisamento Exponencial de Holt-Winters e SARIMA. *Revista de Estatística UFOP*, v. 6, p. 101-120, 2017

AZEVEDO, R. R.; SILVA, J. M.; GATSIOS, R. C. Análise Crítica dos Modelos de Previsão de Série Temporal com Base no ICMS Estadual. *Revista de Gestão, Finanças e Contabilidade*, v. 7, n. 1, p. 164-184, 2017.

CASTANHO, Bernardino J. S. Modelos para Previsão de Receitas Tributárias: O ICMS do Estado do Espírito Santo. Dissertação de Mestrado em Economia – Universidade Federal do Espírito Santo, Espírito Santo, 2011.

GOMES, Amanda dos Santos. Modelagem e Previsão da Arrecadação do Imposto de Renda no Brasil. Dissertação de Mestrado em Estatística – Universidade Federal de Pernambuco, Pernambuco, 2003.

FERREIRA, P. C. et al. Análise de Séries Temporais em R. [s.d.].

GADELHA, S. R. DE B. Receita e Despesa Públicas. 2017.

GUJARATI, D. N.; PORTER, D. C. *Econometria básica*. ed. Porto Alegre: AMGH, 2011.

HOLT, C. C. (1957). Forecasting seasonals and trends by exponentially weighted averages (O.N.R. Memorandum No. 52). Carnegie Institute of Technology, Pittsburgh USA.

HYNDMAN, R. J. ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. Monash University, Australia, v. 2, p. 23, 2018.

MENDONÇA, M. J. C. DE; MEDRANO, L. A. T. Estimando a elasticidade-renda da arrecadação tributária federal. 2017.

MOÇO, João Ricardo Cruz. Estimção de um Modelo de Previsão do ICMS do Estado do Rio de Janeiro. Dissertação de Mestrado em Economia – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2017.

NIELSEN, A. Análise Prática de Séries Temporais: Predição com Estatística e Aprendizado de Máquina. 1ª edição ed. [s.l.] Alta Books, 2021.

PEDROSA, L. S.; DE MOURA, F. R. Eficiência na arrecadação de ICMS dos estados brasileiros com base no PIB estadual: uma análise do gap tributário e da hipótese do ICMS em relação ao PIB como fato estilizado (2002-2017). Revista Debate Econômico, v. 7, n. 1, p. 4–25, 2019.

SOUSA, Katsuk R.; CORREIA, J.J.A.; SANTOS, R.R.; SANTOS, J. F. Previsão de Receitas Tributárias: Uma análise do ICMS do Ceará por meio de séries temporais. Refas, v.5, n.5, p. 1-17, 2019.

WINTERS, P. R. (1960). Forecasting sales by exponentially weighted moving averages. Management Science.

APÊNDICE – TABELAS COM OS RESULTADOS DE CADA MODELO

6.1 Método de Suavização Exponencial Simples (SES):

6.1.1 Método de Suavização Exponencial Simples (SES) – IPCA e ‘Em Nível’:

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.840.970.555	1.682.165.624	9,440505
fevereiro-19	1.657.009.049	1.682.165.624	1,495487
março-19	1.622.543.240	1.682.165.624	3,544383
abril-19	1.614.543.630	1.682.165.624	4,019937
maio-19	1.662.835.100	1.682.165.624	1,149145
junho-19	1.693.777.090	1.682.165.624	0,690269
julho-19	1.749.330.272	1.682.165.624	3,992749
agosto-19	1.718.671.603	1.682.165.624	2,170177
setembro-19	1.779.057.237	1.682.165.624	5,759933
outubro-19	1.902.031.656	1.682.165.624	13,070415
novembro-19	1.826.362.340	1.682.165.624	8,572088
dezembro-19	1.788.371.770	1.682.165.624	6,313656
<i>alfa</i>	0.3525	AIC	8.103.013
<i>beta</i>	0	BIC	8.112.786
<i>gama</i>	0	MAPE	5,018229
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		11.871.743

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.869.909.914	1.799.467.863	3,914605
fevereiro-20	1.665.098.820	1.799.467.863	7,467154
março-20	1.633.833.219	1.799.467.863	9,204646
abril-20	1.420.370.267	1.799.467.863	21,067206
maio-20	1.399.390.521	1.799.467.863	22,233092
junho-20	1.610.418.676	1.799.467.863	10,505838
julho-20	1.751.063.371	1.799.467.863	2,689934
agosto-20	1.903.088.078	1.799.467.863	5,758381
setembro-20	1.970.823.312	1.799.467.863	9,522562
outubro-20	1.989.100.369	1.799.467.863	10,538255
novembro-20	2.052.418.876	1.799.467.863	14,056990
dezembro-20	1.979.777.260	1.799.467.863	10,020151
<i>alfa</i>	0.3624	AIC	8.617.496
<i>beta</i>	0	BIC	8.627.450
<i>gama</i>	0	MAPE	10,581568
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		12.454.441

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.127.521.083	1.987.732.284	7,032577
fevereiro-21	1.863.411.442	1.987.732.284	6,254406
março-21	1.798.387.854	1.987.732.284	9,525650
abril-21	1.844.786.660	1.987.732.284	7,191392
maio-21	1.904.591.749	1.987.732.284	4,182683
junho-21	1.973.741.052	1.987.732.284	0,703879
julho-21	2.223.561.962	1.987.732.284	11,864258
agosto-21	2.243.792.299	1.987.732.284	12,882017
setembro-21	2.206.743.739	1.987.732.284	11,018157
outubro-21	2.319.203.262	1.987.732.284	16,675836
novembro-21	2.315.946.455	1.987.732.284	16,511991
dezembro-21	2.275.533.924	1.987.732.284	14,478893
<i>alfa</i>	0.5171	AIC	9.158.403
<i>beta</i>	0	BIC	9.168.529
<i>gama</i>	0	MAPE	9,860145
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		9.929.112

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.283.819.716	5,039875
fevereiro-22	2.010.344.554	2.283.819.716	11,974464
março-22	2.105.051.580	2.283.819.716	7,827594
abril-22	2.181.862.606	2.283.819.716	4,464324
maio-22	2.194.776.679	2.283.819.716	3,898865
junho-22	2.171.386.951	2.283.819.716	4,923014
julho-22	2.083.925.804	2.283.819.716	8,752613
agosto-22	1.916.927.201	2.283.819.716	16,064863
setembro-22	1.940.686.950	2.283.819.716	15,024512
outubro-22	1.914.744.207	2.283.819.716	16,160448
novembro-22	1.867.793.793	2.283.819.716	18,216233
dezembro-22	1.842.880.471	2.283.819.716	19,307095
<i>alfa</i>	0.5729	AIC	9.686.243
<i>beta</i>	0	BIC	9.696.531
<i>gama</i>	0	MAPE	10,971158
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		10.757.427

6.1.2 Método de Suavização Exponencial Simples (SES) – IGPDI e ‘Em Nível’:

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.147.227.240	10,199438
fevereiro-19	2.135.137.566	2.147.227.240	0,563037
março-19	2.073.755.203	2.147.227.240	3,421717
abril-19	2.056.934.206	2.147.227.240	4,205099
maio-19	2.111.458.745	2.147.227.240	1,665799
junho-19	2.144.967.519	2.147.227.240	0,105239
julho-19	2.201.649.908	2.147.227.240	2,534556
agosto-19	2.167.347.568	2.147.227.240	0,937038
setembro-19	2.257.404.411	2.147.227.240	5,131137
outubro-19	2.400.401.026	2.147.227.240	11,790731
novembro-19	2.294.600.577	2.147.227.240	6,863425
dezembro-19	2.239.293.703	2.147.227.240	4,287691
<i>alfa</i>	0.3243	AIC	8.198.978
<i>beta</i>	0	BIC	8.208.751
<i>gama</i>	0	MAPE	4,308742
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		15.612.920

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.260.258.886	2,987295
fevereiro-20	2.075.238.672	2.260.258.886	8,185797
março-20	2.041.118.756	2.260.258.886	9,695355
abril-20	1.746.954.345	2.260.258.886	22,709989
maio-20	1.714.962.602	2.260.258.886	24,125391
junho-20	1.945.252.524	2.260.258.886	13,936738
julho-20	2.087.209.781	2.260.258.886	7,656163
agosto-20	2.224.560.744	2.260.258.886	1,579383
setembro-20	2.223.148.468	2.260.258.886	1,641866
outubro-20	2.185.987.758	2.260.258.886	3,285957
novembro-20	2.194.207.736	2.260.258.886	2,922283
dezembro-20	2.080.598.376	2.260.258.886	7,948670
<i>alfa</i>	0.3277	AIC	8.719.351
<i>beta</i>	0	BIC	8.729.305
<i>gama</i>	0	MAPE	8,889574
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		16.232.044

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPD	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.976.766	2.134.629.270	5,356785
fevereiro-21	1.918.898.708	2.134.629.270	10,106231
março-21	1.818.665.188	2.134.629.270	14,801825
abril-21	1.842.932.341	2.134.629.270	13,664992
maio-21	1.867.147.284	2.134.629.270	12,530606
junho-21	1.886.890.034	2.134.629.270	11,605727
julho-21	2.134.605.389	2.134.629.270	0,001119
agosto-21	2.143.711.810	2.134.629.270	0,425486
setembro-21	2.129.575.118	2.134.629.270	0,236770
outubro-21	2.276.479.957	2.134.629.270	6,645214
novembro-21	2.265.530.496	2.134.629.270	6,132270
dezembro-21	2.260.271.378	2.134.629.270	5,885898
<i>alfa</i>	0.3933	AIC	9.257.927
<i>beta</i>	0	BIC	9.268.052
<i>gama</i>	0	MAPE	7,282743
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		11.293.475

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPD	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.050.126	2.237.648.932	4,227598
fevereiro-22	1.957.871.168	2.237.648.932	12,503202
março-22	2.040.168.672	2.237.648.932	8,825346
abril-22	2.099.142.137	2.237.648.932	6,189836
maio-22	2.125.165.471	2.237.648.932	5,026859
junho-22	2.097.920.244	2.237.648.932	6,244442
julho-22	2.014.323.063	2.237.648.932	9,980380
agosto-22	1.847.234.446	2.237.648.932	17,447531
setembro-22	1.873.765.635	2.237.648.932	16,261858
outubro-22	1.866.052.284	2.237.648.932	16,606566
novembro-22	1.842.388.225	2.237.648.932	17,664107
dezembro-22	1.828.467.463	2.237.648.932	18,286223
<i>alfa</i>	0.4591	AIC	9.788.260
<i>beta</i>	0	BIC	9.798.548
<i>gama</i>	0	MAPE	11,605329
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		10.148.947

6.1.3 Método de Suavização Exponencial Simples (SES) – IGPDI e ‘Log’:

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	21,58456	21,48712	0,453481
fevereiro-19	21,48180	21,48712	0,024759
março-19	21,45263	21,48712	0,160515
abril-19	21,44448	21,48712	0,198444
maio-19	21,47064	21,48712	0,076697
junho-19	21,48639	21,48712	0,003397
julho-19	21,51247	21,48712	0,117978
agosto-19	21,49677	21,48712	0,044911
setembro-19	21,53748	21,48712	0,234373
outubro-19	21,59890	21,48712	0,520219
novembro-19	21,55382	21,48712	0,310419
dezembro-19	21,52943	21,48712	0,196909
alfa	0.2906	AIC	5.156.502
beta	0	BIC	6.133.751
gama	0	MAPE	0,195175
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0,01118873

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.220.989	2.146.533.388	10,234530
fevereiro-19	2.135.144.152	2.146.533.388	0,530587
março-19	2.073.761.614	2.146.533.388	3,390200
abril-19	2.056.929.142	2.146.533.388	4,174370
maio-19	2.111.448.412	2.146.533.388	1,634495
junho-19	2.144.966.990	2.146.533.388	0,072973
julho-19	2.201.643.580	2.146.533.388	2,567404
agosto-19	2.167.347.702	2.146.533.388	0,969671
setembro-19	2.257.401.026	2.146.533.388	5,164962
outubro-19	2.400.397.055	2.146.533.388	11,826681
novembro-19	2.294.589.965	2.146.533.388	6,897474
dezembro-19	2.239.301.895	2.146.533.388	4,321783
alfa	0.2906	AIC	5.156.502
beta	0	BIC	6.133.751
gama	0	MAPE	4,315428
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		1,011252

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	21,56818	21,53579	0,150401
fevereiro-20	21,45334	21,53579	0,382851
março-20	21,43676	21,53579	0,459839
abril-20	21,28114	21,53579	1,182450
maio-20	21,26266	21,53579	1,268261
junho-20	21,38866	21,53579	0,683188
julho-20	21,45909	21,53579	0,356151
agosto-20	21,52283	21,53579	0,060179
setembro-20	21,52219	21,53579	0,063151
outubro-20	21,50533	21,53579	0,141439
novembro-20	21,50909	21,53579	0,123980
dezembro-20	21,45592	21,53579	0,370871
alfa	0.2923	AIC	5.896.592
beta	0	BIC	6.892.028
gama	0	MAPE	0,436897
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0,0112857

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.777.997	2.253.589.240	3,292027
fevereiro-20	2.075.234.508	2.253.589.240	7,914252
março-20	2.041.110.787	2.253.589.240	9,428446
abril-20	1.746.954.809	2.253.589.240	22,481223
maio-20	1.714.967.557	2.253.589.240	23,900615
junho-20	1.945.257.119	2.253.589.240	13,681824
julho-20	2.087.201.478	2.253.589.240	7,383234
agosto-20	2.224.571.167	2.253.589.240	1,287638
setembro-20	2.223.147.897	2.253.589.240	1,350794
outubro-20	2.185.979.831	2.253.589.240	3,000077
novembro-20	2.194.214.586	2.253.589.240	2,634671
dezembro-20	2.080.595.525	2.253.589.240	7,676364
alfa	0.2923	AIC	5.896.592
beta	0	BIC	6.892.028
gama	0	MAPE	8,669264
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		1,011350

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDl	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'Log'
			Absolute Percent Error
janeiro-21	21,53374	21,47831	0,258074
fevereiro-21	21,37502	21,47831	0,480904
março-21	21,32137	21,47831	0,730691
abril-21	21,33462	21,47831	0,669000
maio-21	21,34768	21,47831	0,608195
junho-21	21,35820	21,47831	0,559215
julho-21	21,48155	21,47831	0,015085
agosto-21	21,48580	21,47831	0,034872
setembro-21	21,47919	21,47831	0,004097
outubro-21	21,54590	21,47831	0,314690
novembro-21	21,54107	21,47831	0,292202
dezembro-21	21,53875	21,47831	0,281400
alfa	0.3166	AIC	8.105.246
beta	0	BIC	9.117.830
gama	0	MAPE	0,354035
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0,009030

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDl	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'Log'
			Absolute Percent Error
janeiro-21	2.248.974.114	2.127.705.487	5,699502
fevereiro-21	1.918.903.949	2.127.705.487	9,813461
março-21	1.818.667.633	2.127.705.487	14,524466
abril-21	1.842.925.331	2.127.705.487	13,384379
maio-21	1.867.151.790	2.127.705.487	12,245759
junho-21	1.886.897.910	2.127.705.487	11,317712
julho-21	2.134.610.433	2.127.705.487	0,324525
agosto-21	2.143.701.833	2.127.705.487	0,751812
setembro-21	2.129.578.692	2.127.705.487	0,088039
outubro-21	2.276.488.589	2.127.705.487	6,992655
novembro-21	2.265.519.660	2.127.705.487	6,477126
dezembro-21	2.260.269.747	2.127.705.487	6,230386
alfa	0.3166	AIC	8.105.246
beta	0	BIC	9.117.830
gama	0	MAPE	7,320818
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		1,00907

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	21,48550	21,51585	0,141059
fevereiro-22	21,39512	21,51585	0,561121
março-22	21,43630	21,51585	0,369727
abril-22	21,46479	21,51585	0,237313
maio-22	21,47712	21,51585	0,180007
junho-22	21,46421	21,51585	0,240009
julho-22	21,42355	21,51585	0,428986
agosto-22	21,33696	21,51585	0,831434
setembro-22	21,35122	21,51585	0,765157
outubro-22	21,34709	21,51585	0,784352
novembro-22	21,33433	21,51585	0,843657
dezembro-22	21,32674	21,51585	0,878933
alfa	0.3492	AIC	9.774.518
beta	0	BIC	10.803.322
gama	0	MAPE	0,521813
Resíduos	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0,008265

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.058.819	2.209.097.725	2,989406
fevereiro-22	1.957.864.157	2.209.097.725	11,372678
março-22	2.040.172.092	2.209.097.725	7,646816
abril-22	2.099.132.498	2.209.097.725	4,977834
maio-22	2.125.175.024	2.209.097.725	3,798958
junho-22	2.097.915.354	2.209.097.725	5,032931
julho-22	2.014.325.023	2.209.097.725	8,816844
agosto-22	1.847.242.826	2.209.097.725	16,380212
setembro-22	1.873.773.221	2.209.097.725	15,179252
outubro-22	1.866.050.496	2.209.097.725	15,528839
novembro-22	1.842.390.960	2.209.097.725	16,599843
dezembro-22	1.828.460.147	2.209.097.725	17,230454

alfa	0.3492	AIC	9.774.518
beta	0	BIC	10.803.322
gama	0	MAPE	10,462839
Resíduos	ARIMA(2,0,0)(1,0,0)[12] with zero mean		1,008299

6.1.4 Método de Suavização Exponencial Simples (SES) – Nominal:

Método de Previsão: SES (Simple Exponential Smoothing), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.442.762.096	1.315.930.035	9,638207
fevereiro-19	1.302.747.113	1.315.930.035	1,001795
março-19	1.281.134.554	1.315.930.035	2,644174
abril-19	1.284.378.835	1.315.930.035	2,397635
maio-19	1.330.334.508	1.315.930.035	1,094623
junho-19	1.356.851.193	1.315.930.035	3,109676
julho-19	1.401.493.510	1.315.930.035	6,502129
agosto-19	1.379.547.941	1.315.930.035	4,834444
setembro-19	1.429.590.193	1.315.930.035	8,637249
outubro-19	1.527.797.488	1.315.930.035	16,100207
novembro-19	1.468.484.108	1.315.930.035	11,592871
dezembro-19	1.445.271.695	1.315.930.035	9,828916
alfa	0.4457	AIC	7391.31
beta	0	BIC	7397.82
gama	0	MAPE	6,448494
Resíduos	ARIMA(0,0,0) with non-zero mean		11.987.935

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.528.545.913	1.454.830.747	5,066924
fevereiro-20	1.363.982.108	1.454.830.747	6,244619
março-20	1.341.716.873	1.454.830.747	7,775054
abril-20	1.167.235.598	1.454.830.747	19,768289
maio-20	1.146.429.893	1.454.830.747	21,198401
junho-20	1.314.298.500	1.454.830.747	9,659697
julho-20	1.432.797.299	1.454.830.747	1,514502
agosto-20	1.562.796.023	1.454.830.747	7,421157
setembro-20	1.622.304.570	1.454.830.747	11,511567
outubro-20	1.647.829.254	1.454.830.747	13,266045
novembro-20	1.714.906.910	1.454.830.747	17,876730
dezembro-20	1.668.933.614	1.454.830.747	14,716686
<i>alfa</i>	0.463	AIC	7857.76
<i>beta</i>	0	BIC	7864.40
<i>gama</i>	0	MAPE	11,334973
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		12.331.620

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	1.817.692.898	1.674.717.493	8,537285
fevereiro-21	1.596.024.898	1.674.717.493	4,698858
março-21	1.553.578.425	1.674.717.493	7,233403
abril-21	1.608.482.539	1.674.717.493	3,954993
maio-21	1.665.774.485	1.674.717.493	0,534001
junho-21	1.740.582.200	1.674.717.493	3,932885
julho-21	1.971.284.501	1.674.717.493	17,708480
agosto-21	2.008.315.461	1.674.717.493	19,919656
setembro-21	1.992.338.600	1.674.717.493	18,965653
outubro-21	2.118.159.797	1.674.717.493	26,478633
novembro-21	2.141.624.193	1.674.717.493	27,879729
dezembro-21	2.124.245.391	1.674.717.493	26,842014
<i>alfa</i>	0.6806	AIC	8372.39
<i>beta</i>	0	BIC	8379.14
<i>gama</i>	0	MAPE	13,890466
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		9.418.969

Método de Previsão: SES (Simple Exponential Smoothing), h = 12		»» Partição IV ««	
Treino: 2003 a 2021 - Teste: 2022		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.039.309.399	2.125.290.828	4,045631
fevereiro-22	1.900.594.766	2.125.290.828	10,572485
março-22	2.010.233.050	2.125.290.828	5,413743
abril-22	2.117.339.360	2.125.290.828	0,374136
maio-22	2.152.448.554	2.125.290.828	1,277836
junho-22	2.139.518.768	2.125.290.828	0,669458
julho-22	2.067.099.810	2.125.290.828	2,738026
agosto-22	1.888.519.662	2.125.290.828	11,140648
setembro-22	1.905.045.270	2.125.290.828	10,363079
outubro-22	1.874.127.530	2.125.290.828	11,817832
novembro-22	1.838.960.709	2.125.290.828	13,472515
dezembro-22	1.821.870.433	2.125.290.828	14,276653
<i>alfa</i>	0.7594	AIC	8866.11
<i>beta</i>	0	BIC	8872.97
<i>gama</i>	0	MAPE	7,180170
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		10.599.443

6.2 Método Holt (Exponencial Duplo - SEH):

6.2.1 Método Holt Aditivo (Exponencial Duplo - SEH) – IPCA e ‘Em Nível’:

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12		»» Partição I ««	
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.840.970.555	1.692.887.002	8,747397
fevereiro-19	1.657.009.049	1.696.928.020	2,352426
março-19	1.622.543.240	1.700.969.039	4,610654
abril-19	1.614.543.630	1.705.010.057	5,305918
maio-19	1.662.835.100	1.709.051.076	2,704189
junho-19	1.693.777.090	1.713.092.094	1,127494
julho-19	1.749.330.272	1.717.133.113	1,875053
agosto-19	1.718.671.603	1.721.174.132	0,145397
setembro-19	1.779.057.237	1.725.215.150	3,120891
outubro-19	1.902.031.656	1.729.256.169	9,991318
novembro-19	1.826.362.340	1.733.297.187	5,369255
dezembro-19	1.788.371.770	1.737.338.206	2,937457
<i>alfa</i>	0.305	AIC	8.104.053
<i>beta</i>	1,00E-04	BIC	8.120.341
<i>gama</i>	0	MAPE	4,023954
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		661.716

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.869.909.914	1.805.937.958	3,542312
fevereiro-20	1.665.098.820	1.809.999.644	8,005572
março-20	1.633.833.219	1.814.061.329	9,935062
abril-20	1.420.370.267	1.818.123.015	21,877109
maio-20	1.399.390.521	1.822.184.701	23,202597
junho-20	1.610.418.676	1.826.246.386	11,818105
julho-20	1.751.063.371	1.830.308.072	4,329583
agosto-20	1.903.088.078	1.834.369.758	3,746154
setembro-20	1.970.823.312	1.838.431.444	7,201349
outubro-20	1.989.100.369	1.842.493.129	7,957003
novembro-20	2.052.418.876	1.846.554.815	11,148549
dezembro-20	1.979.777.260	1.850.616.501	6,979337
<i>alfa</i>	0.3097	AIC	8.617.990
<i>beta</i>	1,00E-04	BIC	8.634.581
<i>gama</i>	0	MAPE	9,978561
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		1.635.892

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.127.521.083	1.993.247.393	6,736429
fevereiro-21	1.863.411.442	1.997.325.127	6,704651
março-21	1.798.387.854	2.001.402.860	10,143635
abril-21	1.844.786.660	2.005.480.594	8,012739
maio-21	1.904.591.749	2.009.558.327	5,223366
junho-21	1.973.741.052	2.013.636.061	1,981242
julho-21	2.223.561.962	2.017.713.794	10,202050
agosto-21	2.243.792.299	2.021.791.528	10,980399
setembro-21	2.206.743.739	2.025.869.261	8,928240
outubro-21	2.319.203.262	2.029.946.994	14,249449
novembro-21	2.315.946.455	2.034.024.728	13,860290
dezembro-21	2.275.533.924	2.038.102.461	11,649633
<i>alfa</i>	0.494	AIC	8604.46
<i>beta</i>	1,00E-04	BIC	8607.84
<i>gama</i>	0	MAPE	9,056010
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		2.287.897

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível' Absolute Percent Error
janeiro-22	2.168.718.063	2.290.414.979	5,313313
fevereiro-22	2.010.344.554	2.294.532.538	12,385441
março-22	2.105.051.580	2.298.650.097	8,422270
abril-22	2.181.862.606	2.302.767.655	5,250423
maio-22	2.194.776.679	2.306.885.214	4,859736
junho-22	2.171.386.951	2.311.002.773	6,041352
julho-22	2.083.925.804	2.315.120.331	9,986286
agosto-22	1.916.927.201	2.319.237.890	17,346676
setembro-22	1.940.686.950	2.323.355.448	16,470510
outubro-22	1.914.744.207	2.327.473.007	17,732915
novembro-22	1.867.793.793	2.331.590.566	19,891862
dezembro-22	1.842.880.471	2.335.708.124	21,099711
<i>alfa</i>	0.552	AIC	9.688.195
<i>beta</i>	1,00E-04	BIC	9.705.342
<i>gama</i>	0	MAPE	12,066708
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		3.914.221

6.2.2 Método Holt Aditivo (Exponencial Duplo - SEH) – IGPDI e ‘Em Nível’:

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2019 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.171.266.263	8,979373
fevereiro-19	2.135.137.566	2.178.275.673	1,980379
março-19	2.073.755.203	2.185.285.084	5,103676
abril-19	2.056.934.206	2.192.294.494	6,174366
maio-19	2.111.458.745	2.199.303.904	3,994226
junho-19	2.144.967.519	2.206.313.314	2,780466
julho-19	2.201.649.908	2.213.322.725	0,527389
agosto-19	2.167.347.568	2.220.332.135	2,386335
setembro-19	2.257.404.411	2.227.341.545	1,349720
outubro-19	2.400.401.026	2.234.350.956	7,431691
novembro-19	2.294.600.577	2.241.360.366	2,375353
dezembro-19	2.239.293.703	2.248.369.776	0,403674
<i>alfa</i>	0.2924	AIC	8.201.334
<i>beta</i>	0.001	BIC	8.217.621
<i>gama</i>	0	MAPE	3,623887
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		- 10.504.202

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.280.164.892	2,088208
fevereiro-20	2.075.238.672	2.287.546.865	9,281042
março-20	2.041.118.756	2.294.928.837	11,059606
abril-20	1.746.954.345	2.302.310.810	24,121698
maio-20	1.714.962.602	2.309.692.782	25,749320
junho-20	1.945.252.524	2.317.074.755	16,047054
julho-20	2.087.209.781	2.324.456.727	10,206555
agosto-20	2.224.560.744	2.331.838.700	4,600574
setembro-20	2.223.148.468	2.339.220.672	4,962003
outubro-20	2.185.987.758	2.346.602.645	6,844571
novembro-20	2.194.207.736	2.353.984.617	6,787507
dezembro-20	2.080.598.376	2.361.366.590	11,890073
<i>alfa</i>	0.2921	AIC	8.721.120
<i>beta</i>	8,00E-04	BIC	8.737.711
<i>gama</i>	0	MAPE	11,136518
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		- 9.926.166

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.976.766	2.152.884.570	4,463416
fevereiro-21	1.918.898.708	2.159.960.723	11,160481
março-21	1.818.665.188	2.167.036.875	16,075946
abril-21	1.842.932.341	2.174.113.027	15,232910
maio-21	1.867.147.284	2.181.189.180	14,397738
junho-21	1.886.890.034	2.188.265.332	13,772338
julho-21	2.134.605.389	2.195.341.485	2,766590
agosto-21	2.143.711.810	2.202.417.637	2,665517
setembro-21	2.129.575.118	2.209.493.789	3,617058
outubro-21	2.276.479.957	2.216.569.942	2,702825
novembro-21	2.265.530.496	2.223.646.094	1,883591
dezembro-21	2.260.271.378	2.230.722.247	1,324644
<i>alfa</i>	0.3817	AIC	9.261.687
<i>beta</i>	9,00E-04	BIC	9.278.564
<i>gama</i>	0	MAPE	7,505255
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		- 9.969.866

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.050.126	2.256.423.645	5,024478
fevereiro-22	1.957.871.168	2.265.185.812	13,566862
março-22	2.040.168.672	2.273.947.980	10,280768
abril-22	2.099.142.137	2.282.710.147	8,041670
maio-22	2.125.165.471	2.291.472.314	7,257641
junho-22	2.097.920.244	2.300.234.482	8,795375
julho-22	2.014.323.063	2.308.996.649	12,761975
agosto-22	1.847.234.446	2.317.758.817	20,300834
setembro-22	1.873.765.635	2.326.520.984	19,460617
outubro-22	1.866.052.284	2.335.283.152	20,093104
novembro-22	1.842.388.225	2.344.045.319	21,401339
dezembro-22	1.828.467.463	2.352.807.487	22,285717
<i>alfa</i>	0,457	AIC	9.791.941
<i>beta</i>	1,00E-04	BIC	9.809.087
<i>gama</i>	0	MAPE	14,105865
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		9.186.439

6.2.3 Método Holt Aditivo (Exponencial Duplo - SEH) – IGPDI e ‘Log’:

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	21,58456	21,50248	0,381723
fevereiro-19	21,48180	21,50582	0,111691
março-19	21,45263	21,50916	0,262818
abril-19	21,44448	21,51250	0,316188
maio-19	21,47064	21,51584	0,210078
junho-19	21,48639	21,51918	0,152376
julho-19	21,51247	21,52252	0,046695
agosto-19	21,49677	21,52586	0,135140
setembro-19	21,53748	21,52920	0,038459
outubro-19	21,59890	21,53254	0,308185
novembro-19	21,55382	21,53588	0,083303
dezembro-19	21,52943	21,53922	0,045452
<i>alfa</i>	0,2086	AIC	5.152.132
<i>beta</i>	1,00E-04	BIC	6.780.879
<i>gama</i>	0	MAPE	0,174342
<i>Resíduos</i>	ARIMA(3,0,2)(2,0,2)[12] with zero mean		-0.0003549602

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.220.989	2.179.758.657	8,554265
fevereiro-19	2.135.144.152	2.187.051.223	2,373382
março-19	2.073.761.614	2.194.368.187	5,496187
abril-19	2.056.929.142	2.201.709.630	6,575821
maio-19	2.111.448.412	2.209.075.634	4,419370
junho-19	2.144.966.990	2.216.466.283	3,225824
julho-19	2.201.643.580	2.223.881.657	0,999967
agosto-19	2.167.347.702	2.231.321.840	2,867096
setembro-19	2.257.401.026	2.238.786.914	0,831437
outubro-19	2.400.397.055	2.246.276.964	6,861135
novembro-19	2.294.589.965	2.253.792.072	1,810189
dezembro-19	2.239.301.895	2.261.332.323	0,974223
<i>alfa</i>	0,2086	AIC	5.152.132
<i>beta</i>	1,00E-04	BIC	6.780.879
<i>gama</i>	0	MAPE	3,749075
<i>Resíduos</i>	ARIMA(3,0,2)(2,0,2)[12] with zero mean		0,999645

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	21,56818	21,54497	0,107728
fevereiro-20	21,45334	21,54831	0,440731
março-20	21,43676	21,55166	0,533138
abril-20	21,28114	21,55500	1,270517
maio-20	21,26266	21,55834	1,371534
junho-20	21,38866	21,56169	0,802488
julho-20	21,45909	21,56503	0,491258
agosto-20	21,52283	21,56837	0,211143
setembro-20	21,52219	21,57172	0,229606
outubro-20	21,50533	21,57506	0,323197
novembro-20	21,50909	21,57840	0,321201
dezembro-20	21,45592	21,58175	0,583039
alfa	0.2378	AIC	5.799.299
beta	1,00E-04	BIC	7.458.359
gama	0	MAPE	0,557132
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		-1.113861e-05

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.777.997	2.274.372.438	2,348145
fevereiro-20	2.075.234.508	2.281.981.542	9,059978
março-20	2.041.110.787	2.289.639.000	10,854472
abril-20	1.746.954.809	2.297.299.179	23,956147
maio-20	1.714.967.557	2.304.984.987	25,597452
junho-20	1.945.257.119	2.312.719.635	15,888762
julho-20	2.087.201.478	2.320.457.033	10,052138
agosto-20	2.224.571.167	2.328.220.316	4,451862
setembro-20	2.223.147.897	2.336.032.933	4,832339
outubro-20	2.185.979.831	2.343.848.328	6,735440
novembro-20	2.194.214.586	2.351.689.869	6,696261
dezembro-20	2.080.595.525	2.359.581.241	11,823527

alfa	0.2378	AIC	5.799.299
beta	1,00E-04	BIC	7.458.359
gama	0	MAPE	11,024710
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0,999989

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	21,53374	21,48686	0,218180
fevereiro-21	21,37502	21,48983	0,534253
março-21	21,32137	21,49281	0,797662
abril-21	21,33462	21,49578	0,749729
maio-21	21,34768	21,49875	0,702692
junho-21	21,35820	21,50172	0,667481
julho-21	21,48155	21,50470	0,107651
agosto-21	21,48580	21,50767	0,101685
setembro-21	21,47919	21,51064	0,146207
outubro-21	21,54590	21,51362	0,150044
novembro-21	21,54107	21,51659	0,113773
dezembro-21	21,53875	21,51956	0,089175
alfa	0,2694	AIC	8.199.433
beta	1,00E-04	BIC	9.887.072
gama	0	MAPE	0,364878
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		-0.0002511639

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.974.114	2.145.975.362	4,799624
fevereiro-21	1.918.903.949	2.152.358.383	10,846448
março-21	1.818.667.633	2.158.781.977	15,754919
abril-21	1.842.925.331	2.165.203.090	14,884412
maio-21	1.867.151.790	2.171.643.302	14,021249
junho-21	1.886.897.910	2.178.102.670	13,369653
julho-21	2.134.610.433	2.184.603.097	2,288409
agosto-21	2.143.701.833	2.191.101.013	2,163259
setembro-21	2.129.578.692	2.197.618.256	3,096059
outubro-21	2.276.488.589	2.204.176.926	3,280665
novembro-21	2.265.519.660	2.210.733.063	2,478210
dezembro-21	2.260.269.747	2.217.308.700	1,937531

alfa	0,2694	AIC	8.199.433
beta	1,00E-04	BIC	9.887.072
gama	0	MAPE	7,410036
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0,99975

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	21,48550	21,51155	0,121098
fevereiro-22	21,39512	21,51468	0,555714
março-22	21,43630	21,51780	0,378756
abril-22	21,46479	21,52092	0,260816
maio-22	21,47712	21,52405	0,218035
junho-22	21,46421	21,52717	0,292468
julho-22	21,42355	21,53030	0,495813
agosto-22	21,33696	21,53342	0,912349
setembro-22	21,35122	21,53654	0,860491
outubro-22	21,34709	21,53967	0,894071
novembro-22	21,33433	21,54279	0,967656
dezembro-22	21,32674	21,54591	1,017223
alfa	0,2549	AIC	9.979.781
beta	1,00E-04	BIC	11.694.454
gama	0	MAPE	0,581207
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		-0.001120213

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.058.819	2.199.618.999	2,571363
fevereiro-22	1.957.864.157	2.206.514.592	11,268923
março-22	2.040.172.092	2.213.409.669	7,826729
abril-22	2.099.132.498	2.220.326.291	5,458378
maio-22	2.125.175.024	2.227.286.800	4,584581
junho-22	2.097.915.354	2.234.246.787	6,101897
julho-22	2.014.325.023	2.241.250.935	10,124967
agosto-22	1.847.242.826	2.248.254.558	17,836580
setembro-22	1.873.773.221	2.255.280.066	16,916163
outubro-22	1.866.050.496	2.262.350.152	17,517167
novembro-22	1.842.390.960	2.269.419.707	18,816649
dezembro-22	1.828.460.147	2.276.511.354	19,681483

alfa	0,2549	AIC	9.979.781
beta	1,00E-04	BIC	11.694.454
gama	0	MAPE	11,558740
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		-0.001120213

6.3.1 Método Holt Multi (Exponencial Duplo - SEH) – IPCA e ‘Em Nível’:

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.840.970.555	1.692.887.002	8,747397
fevereiro-19	1.657.009.049	1.696.928.020	2,352426
março-19	1.622.543.240	1.700.969.039	4,610654
abril-19	1.614.543.630	1.705.010.057	5,305918
maio-19	1.662.835.100	1.709.051.076	2,704189
junho-19	1.693.777.090	1.713.092.094	1,127494
julho-19	1.749.330.272	1.717.133.113	1,875053
agosto-19	1.718.671.603	1.721.174.132	0,145397
setembro-19	1.779.057.237	1.725.215.150	3,120891
outubro-19	1.902.031.656	1.729.256.169	9,991318
novembro-19	1.826.362.340	1.733.297.187	5,369255
dezembro-19	1.788.371.770	1.737.338.206	2,937457
alfa	0,305	AIC	8.104.053
beta	1,00E-04	BIC	8.120.341
gama	0	MAPE	4,023954
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		661.716

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-20	1.869.909.914	1.805.937.958	3,542312
fevereiro-20	1.665.098.820	1.809.999.644	8,005572
março-20	1.633.833.219	1.814.061.329	9,935062
abril-20	1.420.370.267	1.818.123.015	21,877109
maio-20	1.399.390.521	1.822.184.701	23,202597
junho-20	1.610.418.676	1.826.246.386	11,818105
julho-20	1.751.063.371	1.830.308.072	4,329583
agosto-20	1.903.088.078	1.834.369.758	3,746154
setembro-20	1.970.823.312	1.838.431.444	7,201349
outubro-20	1.989.100.369	1.842.493.129	7,957003
novembro-20	2.052.418.876	1.846.554.815	11,148549
dezembro-20	1.979.777.260	1.850.616.501	6,979337
<i>alfa</i>	0,3097	AIC	8.617.990
<i>beta</i>	1,00E-04	BIC	8.634.581
<i>gama</i>	0	MAPE	9,978561
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		1.635.892

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-21	2.127.521.083	1.993.247.393	6,736429
fevereiro-21	1.863.411.442	1.997.325.127	6,704651
março-21	1.798.387.854	2.001.402.860	10,143635
abril-21	1.844.786.660	2.005.480.594	8,012739
maio-21	1.904.591.749	2.009.558.327	5,223366
junho-21	1.973.741.052	2.013.636.061	1,981242
julho-21	2.223.561.962	2.017.713.794	10,202050
agosto-21	2.243.792.299	2.021.791.528	10,980399
setembro-21	2.206.743.739	2.025.869.261	8,928240
outubro-21	2.319.203.262	2.029.946.994	14,249449
novembro-21	2.315.946.455	2.034.024.728	13,860290
dezembro-21	2.275.533.924	2.038.102.461	11,649633
<i>alfa</i>	0,494	AIC	9.160.543
<i>beta</i>	1,00E-04	BIC	9.177.420
<i>gama</i>	0	MAPE	9,056010
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		2.287.897

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-22	2.168.718.063	2.290.414.979	5,313313
fevereiro-22	2.010.344.554	2.294.532.538	12,385441
março-22	2.105.051.580	2.298.650.097	8,422270
abril-22	2.181.862.606	2.302.767.655	5,250423
maio-22	2.194.776.679	2.306.885.214	4,859736
junho-22	2.171.386.951	2.311.002.773	6,041352
julho-22	2.083.925.804	2.315.120.331	9,986286
agosto-22	1.916.927.201	2.319.237.890	17,346676
setembro-22	1.940.686.950	2.323.355.448	16,470510
outubro-22	1.914.744.207	2.327.473.007	17,732915
novembro-22	1.867.793.793	2.331.590.566	19,891862
dezembro-22	1.842.880.471	2.335.708.124	21,099711
<i>alfa</i>	0,552	AIC	9.688.195
<i>beta</i>	1,00E-04	BIC	9.705.342
<i>gama</i>	0	MAPE	12,066708
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		3.914.221

6.3.2 Método Holt Multi (Exponencial Duplo - SEH) – IGPDI e ‘Em Nível’:

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2019 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.171.266.263	8,979373
fevereiro-19	2.135.137.566	2.178.275.673	1,980379
março-19	2.073.755.203	2.185.285.084	5,103676
abril-19	2.056.934.206	2.192.294.494	6,174366
maio-19	2.111.458.745	2.199.303.904	3,994226
junho-19	2.144.967.519	2.206.313.314	2,780466
julho-19	2.201.649.908	2.213.322.725	0,527389
agosto-19	2.167.347.568	2.220.332.135	2,386335
setembro-19	2.257.404.411	2.227.341.545	1,349720
outubro-19	2.400.401.026	2.234.350.956	7,431691
novembro-19	2.294.600.577	2.241.360.366	2,375353
dezembro-19	2.239.293.703	2.248.369.776	0,403674
<i>alfa</i>	0.2924	AIC	8.201.334
<i>beta</i>	0.001	BIC	8.217.621
<i>gama</i>	0	MAPE	3,623887
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		- 10.504.202

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.280.164.892	2,088208
fevereiro-20	2.075.238.672	2.287.546.865	9,281042
março-20	2.041.118.756	2.294.928.837	11,059606
abril-20	1.746.954.345	2.302.310.810	24,121698
maio-20	1.714.962.602	2.309.692.782	25,749320
junho-20	1.945.252.524	2.317.074.755	16,047054
julho-20	2.087.209.781	2.324.456.727	10,206555
agosto-20	2.224.560.744	2.331.838.700	4,600574
setembro-20	2.223.148.468	2.339.220.672	4,962003
outubro-20	2.185.987.758	2.346.602.645	6,844571
novembro-20	2.194.207.736	2.353.984.617	6,787507
dezembro-20	2.080.598.376	2.361.366.590	11,890073
<i>alfa</i>	0.2921	AIC	8.721.120
<i>beta</i>	8,00E-04	BIC	8.737.711
<i>gama</i>	0	MAPE	11,136518
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		- 9.926.166

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.976.766	2.152.884.570	4,463416
fevereiro-21	1.918.898.708	2.159.960.723	11,160481
março-21	1.818.665.188	2.167.036.875	16,075946
abril-21	1.842.932.341	2.174.113.027	15,232910
maio-21	1.867.147.284	2.181.189.180	14,397738
junho-21	1.886.890.034	2.188.265.332	13,772338
julho-21	2.134.605.389	2.195.341.485	2,766590
agosto-21	2.143.711.810	2.202.417.637	2,665517
setembro-21	2.129.575.118	2.209.493.789	3,617058
outubro-21	2.276.479.957	2.216.569.942	2,702825
novembro-21	2.265.530.496	2.223.646.094	1,883591
dezembro-21	2.260.271.378	2.230.722.247	1,324644
<i>alfa</i>	0.3817	AIC	9.261.687
<i>beta</i>	9,00E-04	BIC	9.278.564
<i>gama</i>	0	MAPE	7,505255
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		- 9.969.866

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.050.126	2.256.423.645	5,024478
fevereiro-22	1.957.871.168	2.265.185.812	13,566862
março-22	2.040.168.672	2.273.947.980	10,280768
abril-22	2.099.142.137	2.282.710.147	8,041670
maio-22	2.125.165.471	2.291.472.314	7,257641
junho-22	2.097.920.244	2.300.234.482	8,795375
julho-22	2.014.323.063	2.308.996.649	12,761975
agosto-22	1.847.234.446	2.317.758.817	20,300834
setembro-22	1.873.765.635	2.326.520.984	19,460617
outubro-22	1.866.052.284	2.335.283.152	20,093104
novembro-22	1.842.388.225	2.344.045.319	21,401339
dezembro-22	1.828.467.463	2.352.807.487	22,285717
<i>alfa</i>	0,457	AIC	9.791.941
<i>beta</i>	1,00E-04	BIC	9.809.087
<i>gama</i>	0	MAPE	14,105865
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		9.186.439

6.3.3 Método Holt Multi (Exponencial Duplo - SEH) – IGPDI e 'Log':

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	21,58456	21,5025	0,381723
fevereiro-19	21,48180	21,5058	0,111691
março-19	21,45263	21,5092	0,262818
abril-19	21,44448	21,5125	0,316188
maio-19	21,47064	21,5158	0,210078
junho-19	21,48639	21,5192	0,152376
julho-19	21,51247	21,5225	0,046695
agosto-19	21,49677	21,5259	0,135140
setembro-19	21,53748	21,5292	0,038459
outubro-19	21,59890	21,5325	0,308185
novembro-19	21,55382	21,5359	0,083303
dezembro-19	21,52943	21,5392	0,045452
<i>alfa</i>	0,2086	AIC	5.152.132
<i>beta</i>	1,00E-04	BIC	6.780.879
<i>gama</i>	0	MAPE	0,174342
<i>Resíduos</i>	ARIMA(3,0,2)(2,0,2)[12] with zero mean		-0.0003549602

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.220.989	2.179.758.657	8,554265
fevereiro-19	2.135.144.152	2.187.051.223	2,373382
março-19	2.073.761.614	2.194.368.187	5,496187
abril-19	2.056.929.142	2.201.709.630	6,575821
maio-19	2.111.448.412	2.209.075.634	4,419370
junho-19	2.144.966.990	2.216.466.283	3,225824
julho-19	2.201.643.580	2.223.881.657	0,999967
agosto-19	2.167.347.702	2.231.321.840	2,867096
setembro-19	2.257.401.026	2.238.786.914	0,831437
outubro-19	2.400.397.055	2.246.276.964	6,861135
novembro-19	2.294.589.965	2.253.792.072	1,810189
dezembro-19	2.239.301.895	2.261.332.323	0,974223
<i>alfa</i>	0,2086	AIC	5.152.132
<i>beta</i>	1,00E-04	BIC	6.780.879
<i>gama</i>	0	MAPE	3,749075
<i>Resíduos</i>	ARIMA(3,0,2)(2,0,2)[12] with zero mean		0,999645

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	21,56818	21,5450	0,107728
fevereiro-20	21,45334	21,5483	0,440731
março-20	21,43676	21,5517	0,533138
abril-20	21,28114	21,5550	1,270517
maio-20	21,26266	21,5583	1,371534
junho-20	21,38866	21,5617	0,802488
julho-20	21,45909	21,5650	0,491258
agosto-20	21,52283	21,5684	0,211143
setembro-20	21,52219	21,5717	0,229606
outubro-20	21,50533	21,5751	0,323197
novembro-20	21,50909	21,5784	0,321201
dezembro-20	21,45592	21,5818	0,583039
alfa	0,2378	AIC	5,799,299
beta	1,00E-04	BIC	7,458,359
gama	0	MAPE	0,557132
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		-1.113861e-05

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.777.997	2.274.372.438	2,348145
fevereiro-20	2.075.234.508	2.281.981.542	9,059978
março-20	2.041.110.787	2.289.639.000	10,854472
abril-20	1.746.954.809	2.297.299.179	23,956147
maio-20	1.714.967.557	2.304.984.987	25,597452
junho-20	1.945.257.119	2.312.719.635	15,888762
julho-20	2.087.201.478	2.320.457.033	10,052138
agosto-20	2.224.571.167	2.328.220.316	4,451862
setembro-20	2.223.147.897	2.336.032.933	4,832339
outubro-20	2.185.979.831	2.343.848.328	6,735440
novembro-20	2.194.214.586	2.351.689.869	6,696261
dezembro-20	2.080.595.525	2.359.581.241	11,823527
alfa	0,2378	AIC	5,799,299
beta	1,00E-04	BIC	7,458,359
gama	0	MAPE	11,024710
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0,999989

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	21,5337	21,48686	0,218180
fevereiro-21	21,3750	21,48983	0,534253
março-21	21,3214	21,49281	0,797662
abril-21	21,3346	21,49578	0,749729
maio-21	21,3477	21,49875	0,702692
junho-21	21,3582	21,50172	0,667481
julho-21	21,4816	21,50470	0,107651
agosto-21	21,4858	21,50767	0,101685
setembro-21	21,4792	21,51064	0,146207
outubro-21	21,5459	21,51362	0,150044
novembro-21	21,5411	21,51659	0,113773
dezembro-21	21,5388	21,51956	0,089175
alfa	0,2694	AIC	8.199.433
beta	1,00E-04	BIC	9.887.072
gama	0	MAPE	0,364878
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		-0.0002511639

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.974.114	2.145.975.362	4,799624
fevereiro-21	1.918.903.949	2.152.358.383	10,846448
março-21	1.818.667.633	2.158.781.977	15,754919
abril-21	1.842.925.331	2.165.203.090	14,884412
maio-21	1.867.151.790	2.171.643.302	14,021249
junho-21	1.886.897.910	2.178.102.670	13,369653
julho-21	2.134.610.433	2.184.603.097	2,288409
agosto-21	2.143.701.833	2.191.101.013	2,163259
setembro-21	2.129.578.692	2.197.618.256	3,096059
outubro-21	2.276.488.589	2.204.176.926	3,280665
novembro-21	2.265.519.660	2.210.733.063	2,478210
dezembro-21	2.260.269.747	2.217.308.700	1,937531
alfa	0,2694	AIC	8.199.433
beta	1,00E-04	BIC	9.887.072
gama	0	MAPE	7,410036
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0,99975

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	21,48550	21,51155	0,121098
fevereiro-22	21,39512	21,51468	0,555714
março-22	21,43630	21,51780	0,378756
abril-22	21,46479	21,52092	0,260816
maio-22	21,47712	21,52405	0,218035
junho-22	21,46421	21,52717	0,292468
julho-22	21,42355	21,53030	0,495813
agosto-22	21,33696	21,53342	0,912349
setembro-22	21,35122	21,53654	0,860491
outubro-22	21,34709	21,53967	0,894071
novembro-22	21,33433	21,54279	0,967656
dezembro-22	21,32674	21,54591	1,017223
alfa	0,2549	AIC	9.979.781
beta	1,00E-04	BIC	11.694.454
gama	0	MAPE	0,581207
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		-0.001120213

Método de Previsão: SEH Multiplicativo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.058.819	2.199.618.999	2,571363
fevereiro-22	1.957.864.157	2.206.514.592	11,268923
março-22	2.040.172.092	2.213.409.669	7,826729
abril-22	2.099.132.498	2.220.326.291	5,458378
maio-22	2.125.175.024	2.227.286.800	4,584581
junho-22	2.097.915.354	2.234.246.787	6,101897
julho-22	2.014.325.023	2.241.250.935	10,124967
agosto-22	1.847.242.826	2.248.254.558	17,836580
setembro-22	1.873.773.221	2.255.280.066	16,916163
outubro-22	1.866.050.496	2.262.350.152	17,517167
novembro-22	1.842.390.960	2.269.419.707	18,816649
dezembro-22	1.828.460.147	2.276.511.354	19,681483
alfa	0,2549	AIC	9.979.781
beta	1,00E-04	BIC	11.694.454
gama	0	MAPE	11,558740
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0,998880

6.2.4 Método Holt Aditivo (Exponencial Duplo - SEH) – Nominal:

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.442.762.096	1.324.550.795	8,924633
fevereiro-19	1.302.747.113	1.330.168.384	2,061489
março-19	1.281.134.554	1.335.785.973	4,091331
abril-19	1.284.378.835	1.341.403.561	4,251124
maio-19	1.330.334.508	1.347.021.150	1,238781
junho-19	1.356.851.193	1.352.638.739	0,311425
julho-19	1.401.493.510	1.358.256.327	3,183286
agosto-19	1.379.547.941	1.363.873.916	1,149228
setembro-19	1.429.590.193	1.369.491.505	4,388394
outubro-19	1.527.797.488	1.375.109.093	11,103730
novembro-19	1.468.484.108	1.380.726.682	6,355887
dezembro-19	1.445.271.695	1.386.344.271	4,250562
alfa	0,2641	AIC	7.858.756
beta	0,0029	BIC	7.875.044
gama	0	MAPE	4,275822
<i>Resíduos</i>	ARIMA(0,0,1)(0,0,2)[12] with zero mean		3.890.803

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.528.545.913	1.458.302.924	4,816763
fevereiro-20	1.363.982.108	1.464.745.341	6,879232
março-20	1.341.716.873	1.471.187.759	8,800433
abril-20	1.167.235.598	1.477.630.177	21,006243
maio-20	1.146.429.893	1.484.072.595	22,751091
junho-20	1.314.298.500	1.490.515.013	11,822525
julho-20	1.432.797.299	1.496.957.431	4,286036
agosto-20	1.562.796.023	1.503.399.849	3,950790
setembro-20	1.622.304.570	1.509.842.266	7,448613
outubro-20	1.647.829.254	1.516.284.684	8,675453
novembro-20	1.714.906.910	1.522.727.102	12,620765
dezembro-20	1.668.933.614	1.529.169.520	9,139869
<i>alfa</i>	0,2783	AIC	8.366.614
<i>beta</i>	0,0034	BIC	8.383.205
<i>gama</i>	0	MAPE	10,183151
<i>Resíduos</i>	ARIMA(0,0,1)(0,0,2)[12] with zero mean		4.396.196

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	1.817.692.898	1.680.242.473	8,180392
fevereiro-21	1.596.024.898	1.684.506.732	5,252685
março-21	1.553.578.425	1.688.770.991	8,005382
abril-21	1.608.482.539	1.693.035.250	4,994149
maio-21	1.665.774.485	1.697.299.509	1,857364
junho-21	1.740.582.200	1.701.563.767	2,293093
julho-21	1.971.284.501	1.705.828.026	15,561737
agosto-21	2.008.315.461	1.710.092.285	17,439011
setembro-21	1.992.338.600	1.714.356.544	16,214950
outubro-21	2.118.159.797	1.718.620.803	23,247653
novembro-21	2.141.624.193	1.722.885.062	24,304531
dezembro-21	2.124.245.391	1.727.149.321	22,991415
<i>alfa</i>	0,6449	AIC	8.927.124
<i>beta</i>	9,00E-04	BIC	8.944.000
<i>gama</i>	0	MAPE	12,528530
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		4.405.429

Método de Previsão: SEH Aditivo (Suavização Exponencial de Holt), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.039.309.399	2.137.526.091	4,594877
fevereiro-22	1.900.594.766	2.146.963.145	11,475203
março-22	2.010.233.050	2.156.400.199	6,778294
abril-22	2.117.339.360	2.165.837.253	2,239221
maio-22	2.152.448.554	2.175.274.307	1,049328
junho-22	2.139.518.768	2.184.711.361	2,068584
julho-22	2.067.099.810	2.194.148.415	5,790338
agosto-22	1.888.519.662	2.203.585.469	14,297871
setembro-22	1.905.045.270	2.213.022.523	13,916589
outubro-22	1.874.127.530	2.222.459.577	15,673268
novembro-22	1.838.960.709	2.231.896.631	17,605471
dezembro-22	1.821.870.433	2.241.333.685	18,714895
<i>alfa</i>	0,7219	AIC	9.463.856
<i>beta</i>	0,0052	BIC	9.481.003
<i>gama</i>	0	MAPE	9,516995
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		5.070.714

6.4.1 Método Holt-Winters Aditivo (HW) – IPCA e ‘Em Nível’:

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.840.970.555	1.668.630.885	10,328208
fevereiro-19	1.657.009.049	1.562.243.745	6,065974
março-19	1.622.543.240	1.563.937.641	3,747310
abril-19	1.614.543.630	1.603.230.909	0,705620
maio-19	1.662.835.100	1.627.168.962	2,191914
junho-19	1.693.777.090	1.640.027.529	3,277357
julho-19	1.749.330.272	1.650.242.505	6,004437
agosto-19	1.718.671.603	1.690.440.392	1,670051
setembro-19	1.779.057.237	1.715.375.323	3,712419
outubro-19	1.902.031.656	1.664.726.247	14,254921
novembro-19	1.826.362.340	1.709.726.261	6,821915
dezembro-19	1.788.371.770	1.739.246.798	2,824497
<i>alfa</i>	0,2721	AIC	8.075.488
<i>beta</i>	0,0059	BIC	8.130.865
<i>gama</i>	1,00E-04	MAPE	5,133719
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		315.188,90

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.869.909.914	1.793.436.293	4,264083
fevereiro-20	1.665.098.820	1.682.068.062	1,008832
março-20	1.633.833.219	1.685.038.738	3,038833
abril-20	1.420.370.267	1.725.677.863	17,692039
maio-20	1.399.390.521	1.749.307.603	20,003176
junho-20	1.610.418.676	1.764.654.920	8,740306
julho-20	1.751.063.371	1.782.623.190	1,770414
agosto-20	1.903.088.078	1.818.458.357	4,653927
setembro-20	1.970.823.312	1.843.670.835	6,896702
outubro-20	1.989.100.369	1.798.634.189	10,589490
novembro-20	2.052.418.876	1.846.169.725	11,171733
dezembro-20	1.979.777.260	1.870.012.986	5,869707
<i>alfa</i>	0,2787	AIC	8.586.516
<i>beta</i>	0,0018	BIC	8.642.924
<i>gama</i>	1,00E-04	MAPE	7,974937
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		5.240.857

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.127.521.083	1.938.132.996	9,771677
fevereiro-21	1.863.411.442	1.829.657.932	1,844799
março-21	1.798.387.854	1.831.870.683	1,827794
abril-21	1.844.786.660	1.863.784.778	1,019330
maio-21	1.904.591.749	1.878.247.396	1,402603
junho-21	1.973.741.052	1.904.929.526	3,612287
julho-21	2.223.561.962	1.930.870.794	15,158506
agosto-21	2.243.792.299	1.965.697.330	14,147395
setembro-21	2.206.743.739	1.990.291.787	10,875388
outubro-21	2.319.203.262	1.955.739.531	18,584465
novembro-21	2.315.946.455	2.002.941.523	15,627263
dezembro-21	2.275.533.924	2.018.550.903	12,731065
<i>alfa</i>	0,3374	AIC	9.127.139
<i>beta</i>	0,0012	BIC	9.184.519
<i>gama</i>	1,00E-04	MAPE	8,883548
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		6.730.372

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.257.946.702	3,951760
fevereiro-22	2.010.344.554	2.142.234.098	6,156635
março-22	2.105.051.580	2.141.848.313	1,717990
abril-22	2.181.862.606	2.176.355.852	0,253026
maio-22	2.194.776.679	2.193.765.705	0,046084
junho-22	2.171.386.951	2.223.714.076	2,353141
julho-22	2.083.925.804	2.255.109.615	7,590931
agosto-22	1.916.927.201	2.297.985.445	16,582274
setembro-22	1.940.686.950	2.326.415.982	16,580398
outubro-22	1.914.744.207	2.295.900.702	16,601611
novembro-22	1.867.793.793	2.338.992.003	20,145354
dezembro-22	1.842.880.471	2.361.065.076	21,947070
<i>alfa</i>	0,3823	AIC	9.650.278
<i>beta</i>	0,0023	BIC	9.708.577
<i>gama</i>	1,00E-04	MAPE	9,493856
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		7.228.750

6.4.2 Método Holt-Winters Aditivo (HW) – IGPDI e 'Em Nível':

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.140.562.434	10,542553
fevereiro-19	2.135.137.566	2.004.922.859	6,494749
março-19	2.073.755.203	2.011.924.303	3,073222
abril-19	2.056.934.206	2.062.309.630	0,260651
maio-19	2.111.458.745	2.099.376.019	0,575539
junho-19	2.144.967.519	2.115.825.830	1,377320
julho-19	2.201.649.908	2.129.420.667	3,391967
agosto-19	2.167.347.568	2.184.898.410	0,803280
setembro-19	2.257.404.411	2.215.187.087	1,905813
outubro-19	2.400.401.026	2.145.903.179	11,859708
novembro-19	2.294.600.577	2.204.058.760	4,107958
dezembro-19	2.239.293.703	2.242.767.868	0,154905
<i>alfa</i>	0,2727	AIC	8.172.525
<i>beta</i>	0,0015	BIC	8.227.902
<i>gama</i>	1,00E-04	MAPE	3,712305
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		6.218.747

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.260.255.911	2,987431
fevereiro-20	2.075.238.672	2.116.558.513	1,952218
março-20	2.041.118.756	2.122.438.203	3,831416
abril-20	1.746.954.345	2.174.173.718	19,649735
maio-20	1.714.962.602	2.207.070.589	22,296885
junho-20	1.945.252.524	2.224.762.761	12,563597
julho-20	2.087.209.781	2.246.469.124	7,089318
agosto-20	2.224.560.744	2.294.516.521	3,048824
setembro-20	2.223.148.468	2.322.833.450	4,291525
outubro-20	2.185.987.758	2.257.922.280	3,185872
novembro-20	2.194.207.736	2.318.118.165	5,345303
dezembro-20	2.080.598.376	2.349.370.461	11,440175
<i>alfa</i>	0,2613	AIC	8.690.234
<i>beta</i>	0,0016	BIC	8.746.642
<i>gama</i>	1,00E-04	MAPE	8,140192
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		6.315.922

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPD	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
janeiro-21	2.248.976.766	2.128.298.536	5,670174
fevereiro-21	1.918.898.708	1.984.474.204	3,304427
março-21	1.818.665.188	1.987.462.967	8,493128
abril-21	1.842.932.341	2.025.340.407	9,006292
maio-21	1.867.147.284	2.045.632.210	8,725172
junho-21	1.886.890.034	2.074.919.420	9,062009
julho-21	2.134.605.389	2.101.515.531	1,574571
agosto-21	2.143.711.810	2.143.431.719	0,013067
setembro-21	2.129.575.118	2.174.047.974	2,045624
outubro-21	2.276.479.957	2.120.640.990	7,348673
novembro-21	2.265.530.496	2.171.271.691	4,341180
dezembro-21	2.260.271.378	2.197.341.428	2,863913
<i>alfa</i>	0,2852	AIC	9.225.820
<i>beta</i>	2,00E-04	BIC	9.283.200
<i>gama</i>	1,00E-04	MAPE	5,204019
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		7.779.196

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPD	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
janeiro-22	2.143.050.126	2.192.092.245	2,237229
fevereiro-22	1.957.871.168	2.044.877.554	4,254846
março-22	2.040.168.672	2.043.471.288	0,161618
abril-22	2.099.142.137	2.081.625.256	0,841500
maio-22	2.125.165.471	2.101.038.288	1,148346
junho-22	2.097.920.244	2.136.926.304	1,825335
julho-22	2.014.323.063	2.165.264.107	6,971022
agosto-22	1.847.234.446	2.213.145.864	16,533543
setembro-22	1.873.765.635	2.242.994.583	16,461428
outubro-22	1.866.052.284	2.190.938.982	14,828651
novembro-22	1.842.388.225	2.238.770.470	17,705354
dezembro-22	1.828.467.463	2.257.008.041	18,987109
<i>alfa</i>	0,2962	AIC	9.748.599
<i>beta</i>	2,00E-04	BIC	9.806.897
<i>gama</i>	1,00E-04	MAPE	8,496332
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		7.673.797

6.4.3 Método Holt-Winters Aditivo (HW) – IGPDI e ‘Log’:

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	21,58456	21,4709	0,529555
fevereiro-19	21,48180	21,4282	0,249951
março-19	21,45263	21,4303	0,104432
abril-19	21,44448	21,4464	0,009092
maio-19	21,47064	21,4590	0,054056
junho-19	21,48639	21,4906	0,019450
julho-19	21,51247	21,5106	0,008740
agosto-19	21,49677	21,5409	0,204820
setembro-19	21,53748	21,5252	0,056863
outubro-19	21,59890	21,4916	0,499171
novembro-19	21,55382	21,5133	0,188302
dezembro-19	21,52943	21,5361	0,030832
alfa	0.311	AIC	4.246.640
beta	0.0029	BIC	9.784.382
gama	0.0037	MAPE	0,162939
Resíduos	ARIMA(3,0,2)(2,0,1)[12] with zero mean		-0.001815105

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.220.989	2.111.912.981	12,041595
fevereiro-19	2.135.144.152	2.023.794.396	5,502029
março-19	2.073.761.614	2.027.866.313	2,263231
abril-19	2.056.929.142	2.060.944.068	0,194810
maio-19	2.111.448.412	2.087.097.121	1,166754
junho-19	2.144.966.990	2.153.951.717	0,417128
julho-19	2.201.643.580	2.197.508.378	0,188177
agosto-19	2.167.347.702	2.265.111.903	4,316087
setembro-19	2.257.401.026	2.229.938.849	1,231522
outubro-19	2.400.397.055	2.156.214.554	11,324592
novembro-19	2.294.589.965	2.203.493.737	4,134172
dezembro-19	2.239.301.895	2.254.220.333	0,661800
alfa	0.311	AIC	4.246.640
beta	0.0029	BIC	9.784.382
gama	0.0037	MAPE	3,620158
Resíduos	ARIMA(3,0,2)(2,0,1)[12] with zero mean		0,99819

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	21,56818	21,5585	0,044947
fevereiro-20	21,45334	21,4648	0,053343
março-20	21,43676	21,4562	0,090743
abril-20	21,28114	21,5061	1,046029
maio-20	21,26266	21,5107	1,153101
junho-20	21,38866	21,5269	0,642266
julho-20	21,45909	21,5461	0,403832
agosto-20	21,52283	21,5593	0,169300
setembro-20	21,52219	21,5878	0,303922
outubro-20	21,50533	21,5695	0,297550
novembro-20	21,50909	21,5857	0,355003
dezembro-20	21,45592	21,5860	0,602751
alfa	0.245	AIC	5.899.492
beta	2,00E-04	BIC	11.540.296
gama	0.1475	MAPE	0,430232
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		-0.0004368323

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.777.997	2.305.330.760	0,973710
fevereiro-20	2.075.234.508	2.099.132.498	1,138470
março-20	2.041.110.787	2.081.240.610	1,928168
abril-20	1.746.954.809	2.187.663.683	20,145184
maio-20	1.714.967.557	2.197.750.117	21,967127
junho-20	1.945.257.119	2.233.688.295	12,912776
julho-20	2.087.201.478	2.276.943.932	8,333207
agosto-20	2.224.571.167	2.307.268.052	3,584191
setembro-20	2.223.147.897	2.373.899.978	6,350397
outubro-20	2.185.979.831	2.330.876.001	6,216383
novembro-20	2.194.214.586	2.368.967.398	7,376750
dezembro-20	2.080.595.525	2.369.701.891	12,200115
alfa	0.245	AIC	5.899.492
beta	2,00E-04	BIC	11.540.296
gama	0.1475	MAPE	8,593873
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		0,99956

Método de Previsão: HW Aditivo (Holt-Winters), h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	21,53374	21,5063	0,127684
fevereiro-21	21,37502	21,4033	0,132036
março-21	21,32137	21,3919	0,329751
abril-21	21,33462	21,4101	0,352311
maio-21	21,34768	21,4196	0,335814
junho-21	21,35820	21,4608	0,477849
julho-21	21,48155	21,4919	0,047972
agosto-21	21,48580	21,5077	0,101592
setembro-21	21,47919	21,5294	0,233123
outubro-21	21,54590	21,5128	0,153815
novembro-21	21,54107	21,5225	0,086189
dezembro-21	21,53875	21,5120	0,124489
alfa	0.3132	AIC	8.116.284
beta	1,00E-04	BIC	13.854.257
gama	0.1692	MAPE	0,208552
Resíduos	ARIMA(0,0,0)(1,0,2)[12] with zero mean		-0.0002037716

Método de Previsão: HW Aditivo (Holt-Winters), h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.974.114	2.188.057.498	2,784050
fevereiro-21	1.918.903.949	1.973.905.689	2,786442
março-21	1.818.667.633	1.951.589.489	6,810954
abril-21	1.842.925.331	1.987.314.367	7,265536
maio-21	1.867.151.790	2.006.404.197	6,940396
junho-21	1.886.897.910	2.090.669.110	9,746698
julho-21	2.134.610.433	2.156.732.108	1,025703
agosto-21	2.143.701.833	2.191.057.191	2,161302
setembro-21	2.129.578.692	2.239.189.932	4,895129
outubro-21	2.276.488.589	2.202.392.266	3,364356
novembro-21	2.265.519.660	2.223.881.657	1,872312
dezembro-21	2.260.269.747	2.200.543.033	2,714181
alfa	0.3132	AIC	8.116.284
beta	1,00E-04	BIC	13.854.257
gama	0.1692	MAPE	4,363922
Resíduos	ARIMA(0,0,0)(1,0,2)[12] with zero mean		0,99980

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	21,48550	21,51293	0,127505
fevereiro-22	21,39512	21,42469	0,138018
março-22	21,43630	21,42883	0,034860
abril-22	21,46479	21,45188	0,060181
maio-22	21,47712	21,45904	0,084254
junho-22	21,46421	21,49569	0,146448
julho-22	21,42355	21,51815	0,439629
agosto-22	21,33696	21,54811	0,979900
setembro-22	21,35122	21,55565	0,948382
outubro-22	21,34709	21,52739	0,837538
novembro-22	21,33433	21,54691	0,986592
dezembro-22	21,32674	21,55934	1,078883
alfa	0.3259	AIC	7.691.012
beta	1,00E-04	BIC	13.520.899
gama	0.0495	MAPE	0,488516
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		0.001448533

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDl	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.058.819	2.202.656.569	2,705721
fevereiro-22	1.957.864.157	2.016.622.663	2,913709
março-22	2.040.172.092	2.024.988.787	0,749797
abril-22	2.099.132.498	2.072.206.876	1,299369
maio-22	2.125.175.024	2.087.097.121	1,824443
junho-22	2.097.915.354	2.165.008.230	3,098966
julho-22	2.014.325.023	2.214.184.498	9,026324
agosto-22	1.847.242.826	2.281.525.192	19,034739
setembro-22	1.873.773.221	2.298.792.909	18,488820
outubro-22	1.866.050.496	2.234.738.375	16,498033
novembro-22	1.842.390.960	2.278.789.004	19,150437
dezembro-22	1.828.460.147	2.307.291.125	20,752950
alfa	0.3259	AIC	7.691.012
beta	1,00E-04	BIC	13.520.899
gama	0.0495	MAPE	9,628609
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		1,001450

6.4.4 Método Holt-Winters Aditivo (HW) – Nominal:

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.442.762.096	1.318.342.365	9,437589
fevereiro-19	1.302.747.113	1.266.133.164	2,891793
março-19	1.281.134.554	1.269.756.952	0,896046
abril-19	1.284.378.835	1.303.221.195	1,445830
maio-19	1.330.334.508	1.315.381.411	1,136788
junho-19	1.356.851.193	1.326.230.189	2,308876
julho-19	1.401.493.510	1.337.339.533	4,797135
agosto-19	1.379.547.941	1.359.073.412	1,506506
setembro-19	1.429.590.193	1.379.761.234	3,611419
outubro-19	1.527.797.488	1.356.882.298	12,596169
novembro-19	1.468.484.108	1.384.860.503	6,038414
dezembro-19	1.445.271.695	1.401.661.413	3,111328
alfa	0.2253	AIC	7.826.957
beta	0.0084	BIC	7.882.335
gama	1,00E-04	MAPE	4,148158
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		2.675.725,00

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.528.545.913	1.458.031.635	4,836265
fevereiro-20	1.363.982.108	1.401.988.699	2,710906
março-20	1.341.716.873	1.408.137.365	4,716904
abril-20	1.167.235.598	1.440.520.296	18,971249
maio-20	1.146.429.893	1.455.976.044	21,260388
junho-20	1.314.298.500	1.469.504.615	10,561798
julho-20	1.432.797.299	1.487.325.934	3,666220
agosto-20	1.562.796.023	1.507.151.582	3,692027
setembro-20	1.622.304.570	1.528.526.369	6,135203
outubro-20	1.647.829.254	1.510.879.116	9,064268
novembro-20	1.714.906.910	1.541.302.833	11,263463
dezembro-20	1.668.933.614	1.554.414.813	7,367326
<i>alfa</i>	0,2301	AIC	8.331.147
<i>beta</i>	0,0082	BIC	8.387.555
<i>gama</i>	1,00E-04	MAPE	8,687168
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		3.718.490

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição III ««
Treino: 2003 a 2021 - Teste: 2021		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	1.817.692.898	1.667.043.423	9,036926
fevereiro-21	1.596.024.898	1.606.736.592	0,666674
março-21	1.553.578.425	1.609.413.850	3,469302
abril-21	1.608.482.539	1.632.696.218	1,483049
maio-21	1.665.774.485	1.645.792.676	1,214115
junho-21	1.740.582.200	1.667.788.222	4,364702
julho-21	1.971.284.501	1.693.687.020	16,390129
agosto-21	2.008.315.461	1.713.080.481	17,234157
setembro-21	1.992.338.600	1.735.036.035	14,829811
outubro-21	2.118.159.797	1.724.437.522	22,831925
novembro-21	2.141.624.193	1.758.130.673	21,812572
dezembro-21	2.124.245.391	1.762.878.546	20,498681
<i>alfa</i>		AIC	8.904.816
<i>beta</i>		BIC	8.962.195
<i>gama</i>		MAPE	11,152670
<i>Resíduos</i>	ARIMA(2,0,1)(0,0,1)[12] with zero mean		5.183.351

Método de Previsão: HW Aditivo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.039.309.399	2.130.005.572	4,258025
fevereiro-22	1.900.594.766	2.071.148.197	8,234729
março-22	2.010.233.050	2.077.760.855	3,250028
abril-22	2.117.339.360	2.108.780.635	0,405861
maio-22	2.152.448.554	2.130.986.495	1,007142
junho-22	2.139.518.768	2.162.204.144	1,049178
julho-22	2.067.099.810	2.198.977.430	5,997225
agosto-22	1.888.519.662	2.231.283.844	15,361747
setembro-22	1.905.045.270	2.262.044.547	15,782151
outubro-22	1.874.127.530	2.263.566.550	17,204664
novembro-22	1.838.960.709	2.296.873.501	19,936352
dezembro-22	1.821.870.433	2.317.833.379	21,397696
<i>alfa</i>	0,5904	AIC	9.438.036
<i>beta</i>	0,0116	BIC	9.496.335
<i>gama</i>	0,00E+00	MAPE	9,490400
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		5.484.882

6.5.1 Método Holt-Winters Multiplicativo (HW) – IPCA e ‘Em Nível’:

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-19	1.840.970.555	1.690.126.425	8,925021
fevereiro-19	1.657.009.049	1.543.815.000	7,332099
março-19	1.622.543.240	1.530.221.501	6,033227
abril-19	1.614.543.630	1.589.586.176	1,570060
maio-19	1.662.835.100	1.589.941.986	4,584640
junho-19	1.693.777.090	1.632.600.241	3,747203
julho-19	1.749.330.272	1.649.324.568	6,063434
agosto-19	1.718.671.603	1.674.622.160	2,630411
setembro-19	1.779.057.237	1.720.033.576	3,431541
outubro-19	1.902.031.656	1.665.117.620	14,228066
novembro-19	1.826.362.340	1.717.447.095	6,341694
dezembro-19	1.788.371.770	1.742.772.567	2,616475
<i>alfa</i>	0.4065	AIC	8.102.707
<i>beta</i>	0.0055	BIC	8.158.085
<i>gama</i>	0.0028	MAPE	5,625323
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0.00304146

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-20	1.869.909.914	1.789.010.555	4,522017
fevereiro-20	1.665.098.820	1.630.398.911	2,128308
março-20	1.633.833.219	1.652.514.520	1,130477
abril-20	1.420.370.267	1.746.804.557	18,687511
maio-20	1.399.390.521	1.761.507.192	20,557207
junho-20	1.610.418.676	1.796.743.241	10,370128
julho-20	1.751.063.371	1.820.936.230	3,837194
agosto-20	1.903.088.078	1.849.517.439	2,896466
setembro-20	1.970.823.312	1.913.701.490	2,984887
outubro-20	1.989.100.369	1.832.384.974	8,552537
novembro-20	2.052.418.876	1.848.692.516	11,020024
dezembro-20	1.979.777.260	1.918.337.329	3,202770
<i>alfa</i>	0.1627	AIC	8.621.879
<i>beta</i>	0.0133	BIC	8.678.287
<i>gama</i>	4,00E-04	MAPE	7,490794
<i>Resíduos</i>	ARIMA(0,0,1)(1,0,0)[12] with zero mean		0.003173771

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-21	2.127.521.083	1.948.651.991	9,179119
fevereiro-21	1.863.411.442	1.790.885.991	4,049697
março-21	1.798.387.854	1.771.279.185	1,530457
abril-21	1.844.786.660	1.854.024.207	0,498243
maio-21	1.904.591.749	1.829.148.578	4,124497
junho-21	1.973.741.052	1.890.221.803	4,418489
julho-21	2.223.561.962	1.927.524.607	15,358422
agosto-21	2.243.792.299	1.945.586.775	15,327280
setembro-21	2.206.743.739	2.018.612.393	9,319835
outubro-21	2.319.203.262	1.946.800.629	19,128956
novembro-21	2.315.946.455	1.982.202.637	16,837018
dezembro-21	2.275.533.924	2.016.778.025	12,830163
<i>alfa</i>	0.3232	AIC	9.144.619
<i>beta</i>	9,00E-04	BIC	9.201.998
<i>gama</i>	1,00E-04	MAPE	9,383515
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,0)[12] with zero mean		0.006696318

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.254.542.768	3,806745
fevereiro-22	2.010.344.554	2.034.722.068	1,198076
março-22	2.105.051.580	2.025.392.238	3,933033
abril-22	2.181.862.606	2.098.926.443	3,951361
maio-22	2.194.776.679	2.116.252.984	3,710506
junho-22	2.171.386.951	2.182.018.277	0,487224
julho-22	2.083.925.804	2.243.984.603	7,132794
agosto-22	1.916.927.201	2.281.041.534	15,962635
setembro-22	1.940.686.950	2.334.423.700	16,866550
outubro-22	1.914.744.207	2.281.942.003	16,091460
novembro-22	1.867.793.793	2.314.969.352	19,316695
dezembro-22	1.842.880.471	2.325.340.522	20,747931
<i>alfa</i>	0.3911	AIC	9.680.593
<i>beta</i>	7,00E-04	BIC	9.738.892
<i>gama</i>	0.0555	MAPE	9,433751
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0.007194137

6.5.2 Método Holt-Winters Multiplicativo (HW) – IGPDI e ‘Em Nível’:

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.127.626.707	11,214639
fevereiro-19	2.135.137.566	1.928.515.172	10,714066
março-19	2.073.755.203	1.930.870.907	7,399992
abril-19	2.056.934.206	2.017.549.186	1,952122
maio-19	2.111.458.745	2.043.858.943	3,307459
junho-19	2.144.967.519	2.049.348.077	4,665847
julho-19	2.201.649.908	2.069.178.407	6,402130
agosto-19	2.167.347.568	2.119.131.467	2,275277
setembro-19	2.257.404.411	2.149.635.110	5,013376
outubro-19	2.400.401.026	2.064.303.307	16,281412
novembro-19	2.294.600.577	2.141.252.718	7,161596
dezembro-19	2.239.293.703	2.166.791.040	3,346085
<i>alfa</i>	0.3197	AIC	8.196.022
<i>beta</i>	0.0167	BIC	8.251.399
<i>gama</i>	1,00E-04	MAPE	6,644500
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,0)[12] with zero mean		0.001262093

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.282.905.603	1,965648
fevereiro-20	2.075.238.672	2.057.804.271	0,847233
março-20	2.041.118.756	2.077.320.009	1,742690
abril-20	1.746.954.345	2.159.417.640	19,100673
maio-20	1.714.962.602	2.190.276.311	21,701084
junho-20	1.945.252.524	2.205.698.298	11,807860
julho-20	2.087.209.781	2.243.305.323	6,958283
agosto-20	2.224.560.744	2.277.266.822	2,314445
setembro-20	2.223.148.468	2.322.579.011	4,281040
outubro-20	2.185.987.758	2.272.066.082	3,788548
novembro-20	2.194.207.736	2.325.182.901	5,632897
dezembro-20	2.080.598.376	2.352.371.918	11,553171
<i>alfa</i>	0.2587	AIC	8.716.116
<i>beta</i>	0.0034	BIC	8.772.524
<i>gama</i>	1,00E-04	MAPE	7,641131
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,0)[12] with zero mean		0.003536717

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.976.766	2.117.112.076	6,228517
fevereiro-21	1.918.898.708	1.941.381.593	1,158087
março-21	1.818.665.188	1.932.290.479	5,880342
abril-21	1.842.932.341	1.980.829.164	6,961571
maio-21	1.867.147.284	1.995.804.710	6,446394
junho-21	1.886.890.034	2.017.504.796	6,474074
julho-21	2.134.605.389	2.053.561.009	3,946529
agosto-21	2.143.711.810	2.097.745.520	2,191223
setembro-21	2.129.575.118	2.127.661.514	0,089939
outubro-21	2.276.479.957	2.080.382.782	9,426014
novembro-21	2.265.530.496	2.134.952.283	6,116212
dezembro-21	2.260.271.378	2.137.865.616	5,725606
<i>alfa</i>	0.3243	AIC	9.248.906
<i>beta</i>	0.0106	BIC	9.306.286
<i>gama</i>	1,00E-04	MAPE	5,053709
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0.001115089

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPD	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.050.126	2.219.971.605	3,464976
fevereiro-22	1.957.871.168	2.026.964.188	3,408695
março-22	2.040.168.672	2.001.313.777	1,941469
abril-22	2.099.142.137	2.056.206.337	2,088108
maio-22	2.125.165.471	2.079.480.745	2,196930
junho-22	2.097.920.244	2.104.010.673	0,289468
julho-22	2.014.323.063	2.162.856.422	6,867463
agosto-22	1.847.234.446	2.195.589.873	15,866143
setembro-22	1.873.765.635	2.255.636.989	16,929646
outubro-22	1.866.052.284	2.200.844.364	15,211983
novembro-22	1.842.388.225	2.253.448.137	18,241374
dezembro-22	1.828.467.463	2.262.371.780	19,179178
<i>alfa</i>	0,3546	AIC	9.774.957
<i>beta</i>	0,0069	BIC	9.833.256
<i>gama</i>	1,00E-04	MAPE	8,807119
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0.001888505

6.5.3 Método Holt-Winters Multiplicativo (HW) – IGPD e ‘Log’:

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	21,58456	21,4792	0,490568
fevereiro-19	21,48180	21,4053	0,357435
março-19	21,45263	21,4106	0,196351
abril-19	21,44448	21,4320	0,058464
maio-19	21,47064	21,4443	0,122877
junho-19	21,48639	21,4674	0,088600
julho-19	21,51247	21,4659	0,217042
agosto-19	21,49677	21,4941	0,012422
setembro-19	21,53748	21,5062	0,145586
outubro-19	21,59890	21,4695	0,602622
novembro-19	21,55382	21,4987	0,256527
dezembro-19	21,52943	21,5254	0,018629
<i>alfa</i>	0,1112	AIC	4.786.934
<i>beta</i>	0,0074	BIC	10.324.676
<i>gama</i>	4,00E-04	MAPE	0,213927
<i>Resíduos</i>	ARIMA(1,0,1)(1,0,0)[12] with zero mean		-3.772345e-05

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.220.989	2.129.578.692	11,112165
fevereiro-19	2.135.144.152	1.977.877.229	7,951299
março-19	2.073.761.614	1.988.387.807	4,293620
abril-19	2.056.929.142	2.031.316.618	1,260883
maio-19	2.111.448.412	2.056.538.363	2,670023
junho-19	2.144.966.990	2.104.555.252	1,920203
julho-19	2.201.643.580	2.101.421.800	4,769237
agosto-19	2.167.347.702	2.161.568.603	0,267357
setembro-19	2.257.401.026	2.187.816.825	3,180531
outubro-19	2.400.397.055	2.109.084.913	13,812253
novembro-19	2.294.589.965	2.171.469.578	5,669911
dezembro-19	2.239.301.895	2.230.340.274	0,401805
<i>alfa</i>	0,1112	AIC	4.786.934
<i>beta</i>	0,0074	BIC	10.324.676
<i>gama</i>	4,00E-04	MAPE	4,775774
<i>Resíduos</i>	ARIMA(1,0,1)(1,0,0)[12] with zero mean		0,999962

6.5.4 Método Holt-Winters Multiplicativo (HW) – Nominal:

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.442.762.096	1.329.448.257	8,523373
fevereiro-19	1.302.747.113	1.218.063.920	6,952278
março-19	1.281.134.554	1.208.246.155	6,032579
abril-19	1.284.378.835	1.302.512.420	1,392201
maio-19	1.330.334.508	1.296.134.486	2,638617
junho-19	1.356.851.193	1.309.694.349	3,600599
julho-19	1.401.493.510	1.341.359.799	4,483041
agosto-19	1.379.547.941	1.358.859.196	1,522508
setembro-19	1.429.590.193	1.392.615.695	2,655040
outubro-19	1.527.797.488	1.348.348.649	13,308786
novembro-19	1.468.484.108	1.404.012.278	4,591971
dezembro-19	1.445.271.695	1.388.436.838	4,093442
<i>alfa</i>	0,2985	AIC	7.838.404
<i>beta</i>	0,0124	BIC	7.893.781
<i>gama</i>	1,00E-04	MAPE	4,982870
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with zero mean		0.004631908

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.528.545.913	1.478.582.520	3,379141
fevereiro-20	1.363.982.108	1.343.398.799	1,532182
março-20	1.341.716.873	1.342.649.822	0,069486
abril-20	1.167.235.598	1.430.165.993	18,384607
maio-20	1.146.429.893	1.425.668.655	19,586512
junho-20	1.314.298.500	1.446.093.698	9,113877
julho-20	1.432.797.299	1.486.052.905	3,583695
agosto-20	1.562.796.023	1.495.555.640	4,496013
setembro-20	1.622.304.570	1.549.229.409	4,716872
outubro-20	1.647.829.254	1.532.469.980	7,527669
novembro-20	1.714.906.910	1.559.704.758	9,950739
dezembro-20	1.668.933.614	1.563.280.832	6,758401
<i>alfa</i>	0,2067	AIC	8.346.255
<i>beta</i>	0,0115	BIC	8.402.663
<i>gama</i>	5,00E-04	MAPE	7,424933
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,0)[12] with zero mean		0.005515839

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	1.817.692.898	1.639.707.384	10,854712
fevereiro-21	1.596.024.898	1.487.506.247	7,295341
março-21	1.553.578.425	1.475.474.467	5,293481
abril-21	1.608.482.539	1.527.858.441	5,276935
maio-21	1.665.774.485	1.527.982.945	9,017872
junho-21	1.740.582.200	1.578.802.042	10,247020
julho-21	1.971.284.501	1.635.916.121	20,500341
agosto-21	2.008.315.461	1.676.335.672	19,803897
setembro-21	1.992.338.600	1.721.390.751	15,740055
outubro-21	2.118.159.797	1.711.053.951	23,792695
novembro-21	2.141.624.193	1.758.371.936	21,795858
dezembro-21	2.124.245.391	1.741.037.016	22,010352
<i>alfa</i>	0,2519	AIC	8.878.403
<i>beta</i>	0,0105	BIC	8.935.783
<i>gama</i>	1,00E-04	MAPE	14,302380
<i>Resíduos</i>	ARIMA(0,0,2)(1,0,0)[12] with zero mean		0.006146859

Método de Previsão: HW Multiplicativo (Holt-Winters), h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.039.309.399	2.206.085.125	7,559805
fevereiro-22	1.900.594.766	1.974.820.100	3,758587
março-22	2.010.233.050	1.931.713.892	4,064741
abril-22	2.117.339.360	1.997.842.615	5,981289
maio-22	2.152.448.554	2.025.588.071	6,262896
junho-22	2.139.518.768	2.121.915.537	0,829591
julho-22	2.067.099.810	2.212.506.768	6,572046
agosto-22	1.888.519.662	2.216.070.735	14,780714
setembro-22	1.905.045.270	2.250.666.717	15,356403
outubro-22	1.874.127.530	2.270.251.295	17,448455
novembro-22	1.838.960.709	2.315.946.374	20,595713
dezembro-22	1.821.870.433	2.315.985.170	21,334970
<i>alfa</i>	0.6681	AIC	9.441.710
<i>beta</i>	0.0137	BIC	9.500.009
<i>gama</i>	2,00E-04	MAPE	10,378767
<i>Resíduos</i>	ARIMA(2,0,2)(1,0,0)[12] with non-zero mean		0.006439559

6.6.1 Método ARIMA – IPCA e ‘Em Nível’:

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.840.970.555	1.666.949.908	10,439465
fevereiro-19	1.657.009.049	1.669.303.506	0,736502
março-19	1.622.543.240	1.669.877.154	2,834575
abril-19	1.614.543.630	1.670.016.971	3,321723
maio-19	1.662.835.100	1.670.051.049	0,432080
junho-19	1.693.777.090	1.670.059.354	1,420173
julho-19	1.749.330.272	1.670.061.379	4,746466
agosto-19	1.718.671.603	1.670.061.872	2,910654
setembro-19	1.779.057.237	1.670.061.993	6,526419
outubro-19	1.902.031.656	1.670.062.022	13,889881
novembro-19	1.826.362.340	1.670.062.029	9,358952
dezembro-19	1.788.371.770	1.670.062.031	7,084152
<i>ar1</i>	0.2437	AIC	7594.51
<i>ma1</i>	-0.7833	BIC	7604.26
		MAPE	5,308420
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		15.030.138,00

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.869.909.914	1.778.927.287	5,114466
fevereiro-20	1.665.098.820	1.776.608.731	6,276560
março-20	1.633.833.219	1.776.039.542	8,006935
abril-20	1.420.370.267	1.775.899.810	20,019685
maio-20	1.399.390.521	1.775.865.506	21,199521
junho-20	1.610.418.676	1.775.857.085	9,315975
julho-20	1.751.063.371	1.775.855.018	1,396040
agosto-20	1.903.088.078	1.775.854.510	7,164639
setembro-20	1.970.823.312	1.775.854.386	10,978880
outubro-20	1.989.100.369	1.775.854.355	12,008080
novembro-20	2.052.418.876	1.775.854.348	15,573604
dezembro-20	1.979.777.260	1.775.854.346	11,483088
<i>ar1</i>	0.2455	AIC	8067.39
<i>ma1</i>	-0.7805	BIC	8077.32
		MAPE	10,711456
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		15.720.779

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.127.521.083	1.917.503.986	10,952629
fevereiro-21	1.863.411.442	1.893.179.611	1,572390
março-21	1.798.387.854	1.883.678.339	4,527869
abril-21	1.844.786.660	1.879.967.077	1,871332
maio-21	1.904.591.749	1.878.517.431	1,388026
junho-21	1.973.741.052	1.877.951.190	5,100764
julho-21	2.223.561.962	1.877.730.012	18,417555
agosto-21	2.243.792.299	1.877.643.618	19,500435
setembro-21	2.206.743.739	1.877.609.872	17,529407
outubro-21	2.319.203.262	1.877.596.691	23,519778
novembro-21	2.315.946.455	1.877.591.542	23,346660
dezembro-21	2.275.533.924	1.877.589.531	21,194430
<i>ar1</i>	0.3906	AIC	8561.47
<i>ma1</i>	-0.8212	BIC	8571.58
		MAPE	12,410106
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		16.346.932

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.232.533.353	2,858425
fevereiro-22	2.010.344.554	2.215.243.563	9,249503
março-22	2.105.051.580	2.208.291.636	4,675110
abril-22	2.181.862.606	2.205.496.386	1,071586
maio-22	2.194.776.679	2.204.372.464	0,435307
junho-22	2.171.386.951	2.203.920.555	1,476170
julho-22	2.083.925.804	2.203.738.849	5,436808
agosto-22	1.916.927.201	2.203.665.789	13,011891
setembro-22	1.940.686.950	2.203.636.413	11,932525
outubro-22	1.914.744.207	2.203.624.601	13,109329
novembro-22	1.867.793.793	2.203.619.852	15,239746
dezembro-22	1.842.880.471	2.203.617.942	16,370237
<i>ar1</i>	0.4021	AIC	9048.3
<i>ma1</i>	-0.7866	BIC	9058.58
		MAPE	7,905553
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		16.803.280

6.6.2 Método ARIMA – IGPDI e ‘Em Nível’:

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.137.866.947	10,681928
fevereiro-19	2.135.137.566	2.142.456.032	0,341592
março-19	2.073.755.203	2.143.483.984	3,253058
abril-19	2.056.934.206	2.143.714.244	4,048116
maio-19	2.111.458.745	2.143.765.823	1,507025
junho-19	2.144.967.519	2.143.777.376	0,055516
julho-19	2.201.649.908	2.143.779.964	2,699435
agosto-19	2.167.347.568	2.143.780.544	1,099321
setembro-19	2.257.404.411	2.143.780.674	5,300157
outubro-19	2.400.401.026	2.143.780.703	11,970456
novembro-19	2.294.600.577	2.143.780.709	7,035228
dezembro-19	2.239.293.703	2.143.780.711	4,455353
<i>ar1</i>	0.2240	AIC	7690.58
<i>ma1</i>	-0.7888	BIC	7700.33
		MAPE	4,370599
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		19.591.024

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPD	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.237.882.298	4,017065
fevereiro-20	2.075.238.672	2.237.558.669	7,254335
março-20	2.041.118.756	2.237.484.463	8,776182
abril-20	1.746.954.345	2.237.467.447	21,922692
maio-20	1.714.962.602	2.237.463.546	23,352378
junho-20	1.945.252.524	2.237.462.651	13,059888
julho-20	2.087.209.781	2.237.462.446	6,715316
agosto-20	2.224.560.744	2.237.462.399	0,576620
setembro-20	2.223.148.468	2.237.462.388	0,639739
outubro-20	2.185.987.758	2.237.462.386	2,300581
novembro-20	2.194.207.736	2.237.462.385	1,933201
dezembro-20	2.080.598.376	2.237.462.385	7,010800
<i>ar1</i>	0.2293	AIC	8169.05
<i>ma1</i>	-0.7911	BIC	8178.99
		MAPE	8,129900
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		20.211.233

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPD	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.976.766	2.103.121.509	6,935180
fevereiro-21	1.918.898.708	2.110.366.994	9,072748
março-21	1.818.665.188	2.112.697.800	13,917400
abril-21	1.842.932.341	2.113.447.599	12,799714
maio-21	1.867.147.284	2.113.688.802	11,664041
junho-21	1.886.890.034	2.113.766.395	10,733275
julho-21	2.134.605.389	2.113.791.356	0,984678
agosto-21	2.143.711.810	2.113.799.386	1,415102
setembro-21	2.129.575.118	2.113.801.969	0,746198
outubro-21	2.276.479.957	2.113.802.800	7,695948
novembro-21	2.265.530.496	2.113.803.067	7,177936
dezembro-21	2.260.271.378	2.113.803.153	6,929133
<i>ar1</i>	0.3217	AIC	8659.93
<i>ma1</i>	-0.8237	BIC	8670.04
		MAPE	7,505946
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		17.679.000

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPD	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.050.126	2.190.454.376	2,164129
fevereiro-22	1.957.871.168	2.165.124.511	9,572352
março-22	2.040.168.672	2.155.934.744	5,369646
abril-22	2.099.142.137	2.152.600.662	2,483439
maio-22	2.125.165.471	2.151.391.045	1,219005
junho-22	2.097.920.244	2.150.952.192	2,465510
julho-22	2.014.323.063	2.150.792.974	6,345097
agosto-22	1.847.234.446	2.150.735.209	14,111489
setembro-22	1.873.765.635	2.150.714.252	12,877053
outubro-22	1.866.052.284	2.150.706.649	13,235388
novembro-22	1.842.388.225	2.150.703.890	14,335570
dezembro-22	1.828.467.463	2.150.702.889	14,982796
<i>ar1</i>	0.3628	AIC	9145.79
<i>ma1</i>	-0.8347	BIC	9156.06
		MAPE	8,263456
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		17.412.169

6.6.3 Método ARIMA – IGPDI e ‘Log’:

Método de Previsão: ARIMA [1,1,1], h = 12		»» Partição I ««	
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	21,58456	21,48476	0,464515
fevereiro-19	21,48180	21,48607	0,019873
março-19	21,45263	21,48622	0,156333
abril-19	21,44448	21,48624	0,194357
maio-19	21,47064	21,48624	0,072605
junho-19	21,48639	21,48624	0,000698
julho-19	21,51247	21,48624	0,122078
agosto-19	21,49677	21,48624	0,049008
setembro-19	21,53748	21,48624	0,238478
outubro-19	21,59890	21,48624	0,524336
novembro-19	21,55382	21,48624	0,314527
dezembro-19	21,52943	21,48624	0,201012
ar1	0.1157	AIC	-410.5
ma1	-0.7607	BIC	-400.75
		MAPE	0,196485
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0.01263348

Método de Previsão: ARIMA [1,1,1], h = 12		»» Partição I ««	
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.220.989	2.141.473.542	10,494991
fevereiro-19	2.135.144.152	2.144.280.711	0,426090
março-19	2.073.761.614	2.144.602.377	3,303212
abril-19	2.056.929.142	2.144.645.269	4,090006
maio-19	2.111.448.412	2.144.645.269	1,547895
junho-19	2.144.966.990	2.144.645.269	0,015001
julho-19	2.201.643.580	2.144.645.269	2,657703
agosto-19	2.167.347.702	2.144.645.269	1,058564
setembro-19	2.257.401.026	2.144.645.269	5,257548
outubro-19	2.400.397.055	2.144.645.269	11,925132
novembro-19	2.294.589.965	2.144.645.269	6,991585
dezembro-19	2.239.301.895	2.144.645.269	4,413626
ar1	0.1157	AIC	-410.5
ma1	-0.7607	BIC	-400.75
		MAPE	4,348446
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		1,0127

Método de Previsão: ARIMA [1,1,1], h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	21,56818	21,53067	0,174217
fevereiro-20	21,45334	21,53082	0,359856
março-20	21,43676	21,53084	0,436955
abril-20	21,28114	21,53084	1,159732
maio-20	21,26266	21,53084	1,245562
junho-20	21,38866	21,53084	0,660355
julho-20	21,45909	21,53084	0,333243
agosto-20	21,52283	21,53084	0,037202
setembro-20	21,52219	21,53084	0,040175
outubro-20	21,50533	21,53084	0,118481
novembro-20	21,50909	21,53084	0,101018
dezembro-20	21,45592	21,53084	0,347966
ar1	0.1211	AIC	-444.68
ma1	-0.7624	BIC	-434.74
		MAPE	0,417897
<i>Resíduos</i>	ARIMA(3,0,3)(2,0,2)[12] with zero mean		0.01271325

Método de Previsão: ARIMA [1,1,1], h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.777.997	2.242.080.351	3,822238
fevereiro-20	2.075.234.508	2.242.416.688	7,455447
março-20	2.041.110.787	2.242.461.537	8,979006
abril-20	1.746.954.809	2.242.461.537	22,096554
maio-20	1.714.967.557	2.242.461.537	23,522989
junho-20	1.945.257.119	2.242.461.537	13,253490
julho-20	2.087.201.478	2.242.461.537	6,923644
agosto-20	2.224.571.167	2.242.461.537	0,797801
setembro-20	2.223.147.897	2.242.461.537	0,861270
outubro-20	2.185.979.831	2.242.461.537	2,518737
novembro-20	2.194.214.586	2.242.461.537	2,151517
dezembro-20	2.080.595.525	2.242.461.537	7,218229
ar1	0.1211	AIC	-444.68
ma1	-0.7624	BIC	-434.74
		MAPE	8,300077
<i>Resíduos</i>	ARIMA(3,0,3)(2,0,2)[12] with zero mean		1,0128

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	21,53374	21,46830	0,304822
fevereiro-21	21,37502	21,47076	0,445909
março-21	21,32137	21,47125	0,698050
abril-21	21,33462	21,47135	0,636802
maio-21	21,34768	21,47137	0,576069
junho-21	21,35820	21,47137	0,527074
julho-21	21,48155	21,47137	0,047412
agosto-21	21,48580	21,47137	0,067206
setembro-21	21,47919	21,47137	0,036421
outubro-21	21,54590	21,47137	0,347113
novembro-21	21,54107	21,47137	0,324618
dezembro-21	21,53875	21,47137	0,313813
ar1	0.1988	AIC	-467.51
ma1	-0.7895	BIC	-457.40
		MAPE	0,360442
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		0.01129507

Método de Previsão: ARIMA [1,1,1], h = 12			
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.974.114	2.106.513.399	6,762868
fevereiro-21	1.918.903.949	2.111.701.801	9,129975
março-21	1.818.667.633	2.112.736.788	13,918873
abril-21	1.842.925.331	2.112.948.072	12,779431
maio-21	1.867.151.790	2.112.990.332	11,634627
junho-21	1.886.897.910	2.112.990.332	10,700116
julho-21	2.134.610.433	2.112.990.332	1,023199
agosto-21	2.143.701.833	2.112.990.332	1,453462
setembro-21	2.129.578.692	2.112.990.332	0,785066
outubro-21	2.276.488.589	2.112.990.332	7,737766
novembro-21	2.265.519.660	2.112.990.332	7,218648
dezembro-21	2.260.269.747	2.112.990.332	6,970189
ar1	0.1988	AIC	-467.51
ma1	-0.7895	BIC	-457.40
		MAPE	7,509518
<i>Resíduos</i>	ARIMA(2,0,0)(1,0,0)[12] with non-zero mean		1,01136

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««	
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI		Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error	
janeiro-22	21,48550	22	0,080362	
fevereiro-22	21,39512	21	0,461425	
março-22	21,43630	21	0,260558	
abril-22	21,46479	21	0,125815	
maio-22	21,47712	21	0,067933	
junho-22	21,46421	21	0,127863	
julho-22	21,42355	21	0,317053	
agosto-22	21,33696	21	0,719953	
setembro-22	21,35122	21	0,653601	
outubro-22	21,34709	21	0,672818	
novembro-22	21,33433	21	0,732190	
dezembro-22	21,32674	21	0,767506	
ar1	0.2357	AIC	-495.13	
ma1	-0.799	BIC	-484.85	
		MAPE	0,415590	
<i>Resíduos</i>	ARIMA(2,0,2)(1,0,0)[12] with non-zero mean			0.01102999

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição I ««	
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI		Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error	
janeiro-22	2.143.058.819	2.180.412.683	1,713156	
fevereiro-22	1.957.864.157	2.162.000.960	9,442031	
março-22	2.040.172.092	2.157.681.279	5,446086	
abril-22	2.099.132.498	2.156.667.407	2,667769	
maio-22	2.125.175.024	2.156.430.186	1,449394	
junho-22	2.097.915.354	2.156.365.495	2,710586	
julho-22	2.014.325.023	2.156.365.495	6,587031	
agosto-22	1.847.242.826	2.156.365.495	14,335356	
setembro-22	1.873.773.221	2.156.365.495	13,105027	
outubro-22	1.866.050.496	2.156.365.495	13,463163	
novembro-22	1.842.390.960	2.156.365.495	14,560358	
dezembro-22	1.828.460.147	2.156.365.495	15,206390	

ar1	0.2357	AIC	-495.13	
ma1	-0.799	BIC	-484.85	
		MAPE	8,390529	
<i>Resíduos</i>	ARIMA(2,0,2)(1,0,0)[12] with non-zero mean			1,0111

6.6.4 Método ARIMA – Nominal:

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição I ««	
Treino: 2003 a 2018 - Teste: 2019		Correção: nenhuma		Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error	
janeiro-19	1.442.762.096	1.306.375.986	10,440035	
fevereiro-19	1.302.747.113	1.308.194.490	0,416404	
março-19	1.281.134.554	1.308.542.355	2,094529	
abril-19	1.284.378.835	1.308.608.898	1,851589	
maio-19	1.330.334.508	1.308.621.628	1,659218	
junho-19	1.356.851.193	1.308.624.063	3,685331	
julho-19	1.401.493.510	1.308.624.528	7,096687	
agosto-19	1.379.547.941	1.308.624.618	5,419684	
setembro-19	1.429.590.193	1.308.624.635	9,243717	
outubro-19	1.527.797.488	1.308.624.638	16,748336	
novembro-19	1.468.484.108	1.308.624.639	12,215838	
dezembro-19	1.445.271.695	1.308.624.639	10,442036	
ar1	0.1913	AIC	7362.32	
ma1	-0.6746	BIC	7372.08	
		MAPE	6,776117	
<i>Resíduos</i>	ARIMA(0,0,3)(0,0,2)[12] with non-zero mean			13.523.553

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.528.545.913	1.445.757.519	5,726299
fevereiro-20	1.363.982.108	1.445.845.063	5,661945
março-20	1.341.716.873	1.445.860.838	7,202904
abril-20	1.167.235.598	1.445.863.681	19,270702
maio-20	1.146.429.893	1.445.864.193	20,709711
junho-20	1.314.298.500	1.445.864.286	9,099456
julho-20	1.432.797.299	1.445.864.302	0,903750
agosto-20	1.562.796.023	1.445.864.305	8,087323
setembro-20	1.622.304.570	1.445.864.306	12,203100
outubro-20	1.647.829.254	1.445.864.306	13,968458
novembro-20	1.714.906.910	1.445.864.306	18,607735
dezembro-20	1.668.933.614	1.445.864.306	15,428094
<i>ar1</i>	0.1802	AIC	7.830
<i>ma1</i>	-0.6560	BIC	7839.94
		MAPE	11,405790
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		13.818.246

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	1.817.692.898	1.634.989.226	11,174610
fevereiro-21	1.596.024.898	1.619.438.556	1,445789
março-21	1.553.578.425	1.612.314.452	3,642964
abril-21	1.608.482.539	1.609.050.743	0,035313
maio-21	1.665.774.485	1.607.555.566	3,621580
junho-21	1.740.582.200	1.606.870.593	8,321243
julho-21	1.971.284.501	1.606.556.791	22,702447
agosto-21	2.008.315.461	1.606.413.032	25,018624
setembro-21	1.992.338.600	1.606.347.173	24,029141
outubro-21	2.118.159.797	1.606.317.001	31,864370
novembro-21	2.141.624.193	1.606.303.179	33,326275
dezembro-21	2.124.245.391	1.606.296.846	32,244883
<i>ar1</i>	0.4581	AIC	8337.11
<i>ma1</i>	-0.7504	BIC	8347.22
		MAPE	16,452270
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		13.513.961

Método de Previsão: ARIMA [1,1,1], h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.039.309.399	2.114.511.005	3,556454
fevereiro-22	1.900.594.766	2.111.533.214	9,989824
março-22	2.010.233.050	2.110.622.295	4,756381
abril-22	2.117.339.360	2.110.343.640	0,331497
maio-22	2.152.448.554	2.110.258.399	1,999289
junho-22	2.139.518.768	2.110.232.323	1,387830
julho-22	2.067.099.810	2.110.224.346	2,043600
agosto-22	1.888.519.662	2.110.221.906	10,506110
setembro-22	1.905.045.270	2.110.221.160	9,722957
outubro-22	1.874.127.530	2.110.220.931	11,188089
novembro-22	1.838.960.709	2.110.220.861	12,854586
dezembro-22	1.821.870.433	2.110.220.840	13,664466
<i>ar1</i>	0.3059	AIC	8863.79
<i>ma1</i>	-0.5312	BIC	8870.65
		MAPE	6,833424
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		12.031.624

6.7.1 Método SARIMA – IPCA e ‘Em Nível’:

Método de Previsão: SARIMA (0,1,2)(0,0,2)[12] with drift , h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-19	1.840.970.555	1.675.274.859	9,890657
fevereiro-19	1.657.009.049	1.672.574.348	0,930619
março-19	1.622.543.240	1.643.720.156	1,288353
abril-19	1.614.543.630	1.697.118.183	4,865575
maio-19	1.662.835.100	1.687.445.410	1,458436
junho-19	1.693.777.090	1.692.829.912	0,055952
julho-19	1.749.330.272	1.717.272.398	1,866790
agosto-19	1.718.671.603	1.725.264.294	0,382126
setembro-19	1.779.057.237	1.718.574.469	3,519357
outubro-19	1.902.031.656	1.727.072.917	10,130362
novembro-19	1.826.362.340	1.747.284.499	4,525756
dezembro-19	1.788.371.770	1.746.808.096	2,379407
<i>ma1</i>	-0,5931	AIC	7577,62
<i>ma2</i>	-0,1813	BIC	7597,13
<i>sma1</i>	0,2486	MAPE	3,441116
<i>sma2</i>	0,1823		
<i>drift</i>	4.223,697		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		670628,5

Método de Previsão: SARIMA(1,1,1)(0,0,2)[12] with drift , h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-20	1.869.909.914	1.831.187.731	2,114594
fevereiro-20	1.665.098.820	1.776.514.105	6,271568
março-20	1.633.833.219	1.763.490.347	7,352302
abril-20	1.420.370.267	1.775.698.634	20,010623
maio-20	1.399.390.521	1.791.010.491	21,865867
junho-20	1.610.418.676	1.794.762.361	10,271203
julho-20	1.751.063.371	1.828.450.779	4,232403
agosto-20	1.903.088.078	1.813.418.259	4,944795
setembro-20	1.970.823.312	1.834.305.180	7,442498
outubro-20	1.989.100.369	1.873.289.937	6,182195
novembro-20	2.052.418.876	1.859.720.610	10,361678
dezembro-20	1.979.777.260	1.835.129.333	7,882165
<i>ma1</i>	0,2316	AIC	8048,47
<i>ma2</i>	-0,8349	BIC	8068,35
<i>sma1</i>	0,2542	MAPE	9,077658
<i>sma2</i>	0,1675		
<i>drift</i>	4.538,558		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		612250,5

Método de Previsão: SARIMA(1,1,1)(0,0,1)[12] with drift , h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: IPCA	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'em Nível'
			Absolute Percent Error
janeiro-21	2.127.521.083	1.923.332.158	10,616415
fevereiro-21	1.863.411.442	1.858.228.991	0,278892
março-21	1.798.387.854	1.844.814.570	2,516606
abril-21	1.844.786.660	1.793.999.545	2,830944
maio-21	1.904.591.749	1.787.567.680	6,546553
junho-21	1.973.741.052	1.840.895.957	7,216328
julho-21	2.223.561.962	1.878.107.996	18,393722
agosto-21	2.243.792.299	1.920.545.501	16,830989
setembro-21	2.206.743.739	1.937.858.500	13,875380
outubro-21	2.319.203.262	1.938.668.876	19,628643
novembro-21	2.315.946.455	1.963.599.687	17,943921
dezembro-21	2.275.533.924	1.949.848.588	16,703109
<i>ma1</i>	0,3910	AIC	8544,05
<i>ma2</i>	-0,8817	BIC	8560,91
<i>sma1</i>	0,2497	MAPE	11,115125
<i>sma2</i>			
<i>drift</i>	4.709,261		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		232409,1

Método de Previsão: SARIMA(0,1,2)(0,0,1)[12] with drift, h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IPCA	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.168.718.063	2.298.360.254	5,640638
fevereiro-22	2.010.344.554	2.236.766.107	10,122719
março-22	2.105.051.580	2.225.467.090	5,410797
abril-22	2.181.862.606	2.259.388.820	3,431291
maio-22	2.194.776.679	2.284.094.131	3,910410
junho-22	2.171.386.951	2.292.675.017	5,290242
julho-22	2.083.925.804	2.357.321.938	11,597743
agosto-22	1.916.927.201	2.355.631.007	18,623622
setembro-22	1.940.686.950	2.345.859.331	17,271811
outubro-22	1.914.744.207	2.383.787.690	19,676395
novembro-22	1.867.793.793	2.380.803.226	21,547746
dezembro-22	1.842.880.471	2.379.989.061	22,567692
<i>ma1</i>	-0.4823	AIC	9028.78
<i>ma2</i>	-0.1976	BIC	9045.91
<i>sma1</i>	0.2822	MAPE	12,090926
<i>sma2</i>			
<i>drift</i>	6.320.055		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		353837.5

6.7.2 Método SARIMA – IGPDI e ‘Em Nível’:

Método de Previsão: SARIMA(1,1,2)(1,0,0)[12] , h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	2.366.232.359	2.153.861.986	9,859981
fevereiro-19	2.135.137.566	2.109.122.287	1,233465
março-19	2.073.755.203	2.073.974.361	0,010567
abril-19	2.056.934.206	2.138.580.332	3,817772
maio-19	2.111.458.745	2.121.942.198	0,494050
junho-19	2.144.967.519	2.107.005.904	1,801685
julho-19	2.201.649.908	2.151.628.421	2,324820
agosto-19	2.167.347.568	2.131.259.873	1,693256
setembro-19	2.257.404.411	2.129.698.719	5,996421
outubro-19	2.400.401.026	2.126.404.671	12,885429
novembro-19	2.294.600.577	2.148.649.906	6,792669
dezembro-19	2.239.293.703	2.122.050.165	5,525013
<i>ma1</i>	-0.1674	AIC	7677.78
<i>ma2</i>	-0.4386	BIC	7694.04
<i>sma1</i>	-0.2578	MAPE	4,369594
<i>sma2</i>	0.2982		
<i>drift</i>			
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		14.297.417

Método de Previsão: SARIMA(0,1,2)(0,0,2)[12] with drift, h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.779.488	2.299.936.318	1,210606
fevereiro-20	2.075.238.672	2.229.908.439	6,936149
março-20	2.041.118.756	2.204.050.687	7,392386
abril-20	1.746.954.345	2.214.186.984	21,101770
maio-20	1.714.962.602	2.223.404.424	22,867717
junho-20	1.945.252.524	2.217.919.343	12,293811
julho-20	2.087.209.781	2.252.472.389	7,336943
agosto-20	2.224.560.744	2.229.136.805	0,205284
setembro-20	2.223.148.468	2.252.466.826	1,301611
outubro-20	2.185.987.758	2.291.344.404	4,598028
novembro-20	2.194.207.736	2.268.231.583	3,263505
dezembro-20	2.080.598.376	2.233.509.328	6,846220
<i>ma1</i>	-0.5958	AIC	8153.97
<i>ma2</i>	-0.1526	BIC	8170.53
<i>sma1</i>	0.2463	MAPE	7,946169
<i>sma2</i>	0.1693		
<i>drift</i>			
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		15.860.923

Método de Previsão: SARIMA(2,1,1)(1,0,0)[12] with drift, h = 12		»» Partição III ««	
Treino: 2003 a 2020 - Teste: 2021		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	2.248.976.766	2.135.431.568	5,317201
fevereiro-21	1.918.898.708	2.063.900.980	7,025641
março-21	1.818.665.188	2.055.272.554	11,512214
abril-21	1.842.932.341	1.963.214.115	6,126778
maio-21	1.867.147.284	1.953.288.171	4,410045
junho-21	1.886.890.034	2.025.831.158	6,858475
julho-21	2.134.605.389	2.070.535.115	3,094382
agosto-21	2.143.711.810	2.113.781.364	1,415967
setembro-21	2.129.575.118	2.113.337.424	0,768344
outubro-21	2.276.479.957	2.101.637.928	8,319322
novembro-21	2.265.530.496	2.104.225.955	7,665742
dezembro-21	2.260.271.378	2.068.457.190	9,273297
<i>ma1</i>	0.2800	AIC	8644.5
<i>ma2</i>	-0.0044	BIC	8661.36
<i>sma1</i>	-0.8322	MAPE	5,982284
<i>sma2</i>	0.3148		
<i>drift</i>			
<i>Resíduos</i>	ARIMA(0,0,0) with non-zero mean		13.045.811

Método de Previsão: SARIMA(0,1,2)(0,0,1)[12], h = 12		»» Partição IV ««	
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.050.126	2.225.255.967	3,694220
fevereiro-22	1.957.871.168	2.131.150.214	8,130776
março-22	2.040.168.672	2.109.898.362	3,304884
abril-22	2.099.142.137	2.139.256.456	1,875152
maio-22	2.125.165.471	2.152.732.543	1,280562
junho-22	2.097.920.244	2.146.443.134	2,260618
julho-22	2.014.323.063	2.205.863.849	8,683255
agosto-22	1.847.234.446	2.202.091.940	16,114563
setembro-22	1.873.765.635	2.203.583.076	14,967325
outubro-22	1.866.052.284	2.251.306.771	17,112483
novembro-22	1.842.388.225	2.249.201.210	18,086998
dezembro-22	1.828.467.463	2.258.907.388	19,055227
<i>ma1</i>	-0.5496	AIC	9129.93
<i>ma2</i>	-0.2211	BIC	9147.06
<i>sma1</i>	0.2644	MAPE	9,547172
<i>sma2</i>			
<i>drift</i>	4.522.671		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		569551.1

6.7.3 Método SARIMA – IGPDI e ‘Log’:

Método de Previsão: SARIMA(2,1,1)(1,0,0)[12] with drift , h = 12		»» Partição I ««	
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'Log'
			Absolute Percent Error
janeiro-19	21,58456	21,50381	0,375515
fevereiro-19	21,48180	21,49014	0,038808
março-19	21,45263	21,47988	0,126863
abril-19	21,44448	21,50548	0,283649
maio-19	21,47064	21,50216	0,146590
junho-19	21,48639	21,49929	0,060002
julho-19	21,51247	21,51745	0,023144
agosto-19	21,49677	21,51292	0,075071
setembro-19	21,53748	21,51487	0,105090
outubro-19	21,59890	21,51620	0,384362
novembro-19	21,55382	21,52640	0,127378
dezembro-19	21,52943	21,51964	0,045493
<i>ar1</i>	0.0984	AIC	-418.67
<i>ar2</i>	-0.0356	BIC	-399.16
<i>ma1</i>	-0.8006	MAPE	0,149330
<i>sar1</i>	0.2242		
<i>drift</i>	0.0032		
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		0.000840957

Método de Previsão: SARIMA(2,1,1)(1,0,0)[12] with drift , h = 12		»» Partição I ««	
Treino: 2003 a 2018 - Teste: 2019		Correção: IGPDI	
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Dados: 'Log'
			Absolute Percent Error
janeiro-19	2.366.220.989	2.182.659.665	8,409984
fevereiro-19	2.135.144.152	2.153.025.717	0,830532
março-19	2.073.761.614	2.131.048.609	2,688207
abril-19	2.056.929.142	2.186.307.752	5,917676
maio-19	2.111.448.412	2.179.061.246	3,102842
junho-19	2.144.966.990	2.172.816.306	1,281715
julho-19	2.201.643.580	2.212.635.111	0,496762
agosto-19	2.167.347.702	2.202.634.542	1,602029
setembro-19	2.257.401.026	2.206.933.870	2,286754
outubro-19	2.400.397.055	2.209.871.045	8,621589
novembro-19	2.294.589.965	2.232.527.079	2,779939
dezembro-19	2.239.301.895	2.217.486.092	0,983808
<i>ar1</i>	0.0984	AIC	-418.67
<i>ar2</i>	-0.0356	BIC	-399.16
<i>ma1</i>	-0.8006	MAPE	3,250153
<i>sar1</i>	0.2242		
<i>drift</i>	0.0032		
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		1,00084

Método de Previsão: SARIMA(1,1,1)(0,0,2)[12] with drift , h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	21,56818	21,56044	0,035899
fevereiro-20	21,45334	21,54026	0,403523
março-20	21,43676	21,53611	0,461318
abril-20	21,28114	21,53675	1,186855
maio-20	21,26266	21,54529	1,311795
junho-20	21,38866	21,55144	0,755309
julho-20	21,45909	21,55996	0,467858
agosto-20	21,52283	21,55889	0,167263
setembro-20	21,52219	21,57077	0,225212
outubro-20	21,50533	21,58739	0,380129
novembro-20	21,50909	21,57959	0,326698
dezembro-20	21,45592	21,57654	0,559033
<i>ar1</i>	0.1041	AIC	-454.51
<i>ar2</i>	-0.0306	BIC	-434.63
<i>ma1</i>	-0.8065	MAPE	0,523408
<i>sar1</i>	0.2293		
<i>drift</i>	0.0033		
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		0.0008023174

Método de Previsão: SARIMA(1,1,1)(0,0,2)[12] with drift , h = 12		»» Partição II ««	
Treino: 2003 a 2019 - Teste: 2020		Correção: IGPD	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	2.327.777.997	2.309.830.541	0,777003
fevereiro-20	2.075.234.508	2.263.685.332	8,324957
março-20	2.041.110.787	2.254.310.504	9,457425
abril-20	1.746.954.809	2.255.753.725	22,555606
maio-20	1.714.967.557	2.275.100.354	24,620136
junho-20	1.945.257.119	2.289.135.334	15,022188
julho-20	2.087.201.478	2.308.722.089	9,594945
agosto-20	2.224.571.167	2.306.253.077	3,541758
setembro-20	2.223.147.897	2.333.814.756	4,741887
outubro-20	2.185.979.831	2.372.926.879	7,878332
novembro-20	2.194.214.586	2.354.490.046	6,807226
dezembro-20	2.080.595.525	2.347.319.792	11,362928
<i>ar1</i>	0.1041	AIC	-454.51
<i>ar2</i>	-0.0306	BIC	-434.63
<i>ma1</i>	-0.8065	MAPE	10,390366
<i>sar1</i>	0.2293		
<i>drift</i>	0.0033		
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		1,000803

Método de Previsão: SARIMA, h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	21,48550	21,5217	0,167970
fevereiro-22	21,39512	21,4731	0,363106
março-22	21,43630	21,4582	0,102105
abril-22	21,46479	21,4631	0,008060
maio-22	21,47712	21,4684	0,040804
junho-22	21,46421	21,4731	0,041447
julho-22	21,42355	21,5081	0,393247
agosto-22	21,33696	21,5113	0,810227
setembro-22	21,35122	21,5115	0,744905
outubro-22	21,34709	21,5313	0,855637
novembro-22	21,33433	21,5320	0,918121
dezembro-22	21,32674	21,5334	0,959626
<i>ar1</i>	0.2058	AIC	-508.56
<i>ar2</i>	0.0211	BIC	-488.01
<i>ma1</i>	-0.8465	MAPE	0,450438
<i>sar1</i>	0.2680		
<i>drift</i>	0.0027		
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		0.0007271763

Método de Previsão: SARIMA, h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: IGPDI	Dados: 'Log'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.143.058.819	2.221.947.721	3,550439
fevereiro-22	1.957.864.157	2.116.627.803	7,500782
março-22	2.040.172.092	2.085.365.549	2,167172
abril-22	2.099.132.498	2.095.504.138	0,173150
maio-22	2.125.175.024	2.106.639.793	0,879848
junho-22	2.097.915.354	2.116.670.135	0,886051
julho-22	2.014.325.023	2.192.109.151	8,110186
agosto-22	1.847.242.826	2.198.959.212	15,994675
setembro-22	1.873.773.221	2.199.421.042	14,806070
outubro-22	1.866.050.496	2.243.538.177	16,825552
novembro-22	1.842.390.960	2.245.109.204	17,937579
dezembro-22	1.828.460.147	2.248.164.629	18,668761
<i>ar1</i>	0.2058	AIC	-508.56
<i>ar2</i>	0.0211	BIC	-488.01
<i>ma1</i>	-0.8465	MAPE	8,958356
<i>sar1</i>	0.2680		
<i>drift</i>	0.0027		
<i>Resíduos</i>	ARIMA(0,0,0)(1,0,1)[12] with zero mean		1,000727

6.7.4 Método SARIMA – Nominal:

Método de Previsão: SARIMA (0,1,2)(0,0,2)[12] with drift , h = 12			»» Partição I ««
Treino: 2003 a 2018 - Teste: 2019		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-19	1.442.762.096	1.307.333.189	10,359173
fevereiro-19	1.302.747.113	1.306.204.696	0,264705
março-19	1.281.134.554	1.286.743.944	0,435937
abril-19	1.284.378.835	1.329.106.106	3,365215
maio-19	1.330.334.508	1.323.106.862	0,546263
junho-19	1.356.851.193	1.331.407.410	1,911044
julho-19	1.401.493.510	1.352.065.178	3,655765
agosto-19	1.379.547.941	1.362.967.694	1,216481
setembro-19	1.429.590.193	1.357.920.818	5,277876
outubro-19	1.527.797.488	1.366.943.116	11,767452
novembro-19	1.468.484.108	1.386.147.569	5,939955
dezembro-19	1.445.271.695	1.390.812.851	3,915613
<i>ma1</i>	-0.6244	AIC	7329.09
<i>ma2</i>	-0.1804	BIC	7348.60
<i>sma1</i>	0.2363	MAPE	4,054623
<i>sma2</i>	0.2075		
<i>drift</i>	5.411.590		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		352292.5

Método de Previsão: SARIMA(0,1,2)(0,0,2)[12] with drift, h = 12			»» Partição II ««
Treino: 2003 a 2019 - Teste: 2020		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-20	1.528.545.913	1.479.185.373	3,337008
fevereiro-20	1.363.982.108	1.437.820.293	5,135425
março-20	1.341.716.873	1.430.609.543	6,213622
abril-20	1.167.235.598	1.444.368.493	19,187132
maio-20	1.146.429.893	1.460.436.224	21,500859
junho-20	1.314.298.500	1.465.864.846	10,339722
julho-20	1.432.797.299	1.496.647.333	4,266204
agosto-20	1.562.796.023	1.487.005.129	5,096882
setembro-20	1.622.304.570	1.505.745.162	7,740978
outubro-20	1.647.829.254	1.539.452.351	7,039965
novembro-20	1.714.906.910	1.530.487.015	12,049752
dezembro-20	1.668.933.614	1.513.376.446	10,278815
<i>ma1</i>	-0.6357	AIC	7794.09
<i>ma2</i>	-0.1580	BIC	7813.97
<i>sma1</i>	0.2598	MAPE	9,348864
<i>sma2</i>	0.1756		
<i>drift</i>	5.793.895		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		328729.4

Método de Previsão: SARIMA(1,1,1)(0,0,2) [12] with drift, h = 12			»» Partição III ««
Treino: 2003 a 2020 - Teste: 2021		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-21	1.817.692.898	1.638.292.642	10,950440
fevereiro-21	1.596.024.898	1.550.608.176	2,928962
março-21	1.553.578.425	1.532.896.579	1,349200
abril-21	1.608.482.539	1.467.467.549	9,609411
maio-21	1.665.774.485	1.465.539.864	13,662857
junho-21	1.740.582.200	1.520.696.258	14,459557
julho-21	1.971.284.501	1.554.083.096	26,845502
agosto-21	2.008.315.461	1.596.808.102	25,770621
setembro-21	1.992.338.600	1.622.755.512	22,775032
outubro-21	2.118.159.797	1.639.681.406	29,181181
novembro-21	2.141.624.193	1.655.751.200	29,344565
dezembro-21	2.124.245.391	1.650.197.329	28,726750
<i>ma1</i>	0.5000	AIC	8302.52
<i>ma2</i>	-0.9294	BIC	8322.74
<i>sma1</i>	0.2970	MAPE	17,967007
<i>sma2</i>	0.1676		
<i>drift</i>	5958159.0		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		-200467.3

Método de Previsão: SARIMA(0,1,2)(0,0,1)[12] with drift, h = 12			»» Partição IV ««
Treino: 2003 a 2021 - Teste: 2022		Correção: nenhuma	Dados: 'em Nível'
Mês / Ano	Arrecadação Real	Arrecadação Prevista	Absolute Percent Error
janeiro-22	2.039.309.399	2.160.513.384	5,609962
fevereiro-22	1.900.594.766	2.088.114.691	8,980346
março-22	2.010.233.050	2.077.898.115	3,256419
abril-22	2.117.339.360	2.085.200.550	1,541281
maio-22	2.152.448.554	2.101.717.097	2,413810
junho-22	2.139.518.768	2.148.271.581	0,407435
julho-22	2.067.099.810	2.238.616.628	7,661733
agosto-22	1.888.519.662	2.274.396.359	16,966115
setembro-22	1.905.045.270	2.274.766.716	16,253159
outubro-22	1.874.127.530	2.314.501.359	19,026726
novembro-22	1.838.960.709	2.342.775.094	21,505026
dezembro-22	1.821.870.433	2.341.526.433	22,193044
<i>ma1</i>	-0.3568	AIC	8302.52
<i>ma2</i>	-0.1146	BIC	8322.74
<i>sma1</i>	0.3311	MAPE	10,484588
<i>sma2</i>	0.2179		
<i>drift</i>	8.778.289		
<i>Resíduos</i>	ARIMA(0,0,0) with zero mean		279131.4