

UNIVERSIDADE FEDERAL DE MATO GROSSO
FACULDADE DE ADMINISTRAÇÃO E CIÊNCIAS CONTÁBEIS
DEPARTAMENTO DE CIÊNCIAS CONTÁBEIS

MELKZEDEC OJEDA CAMARGO

**PREVISÃO DE RECEITAS DO ICMS NO ESTADO DE MATO
GROSSO NO PERÍODO DE 1993 A 2019: ANÁLISE ARIMA COM X13-
ARIMA-SEATS**

CUIABÁ-MT
2021

MELKZEDEC OJEDA CAMARGO

**PREVISÃO DE RECEITAS DO ICMS NO ESTADO DE MATO GROSSO NO
PERÍODO DE 1993 A 2019: ANÁLISE ARIMA COM X13-ARIMA-SEATS**

Monografia apresentada à UFMT/Faculdade de Administração e Ciências Contábeis, Departamento de Ciências Contábeis, para obtenção do título de Bacharel em Ciências Contábeis.

Orientador: Paulo Sérgio Almeida dos Santos

CUIABÁ-MT

2021

Melkzedec Ojeda Camargo

Previsão de Receitas do ICMS no Estado de Mato Grosso no período de 1993 a 2019: análise ARIMA com X13-ARIMA-SEATS

Monografia defendida e aprovada em ___/___/___ pela banca examinadora constituída pelos professores:

Dr. Paulo Sérgio de Almeida dos Santos

Dr^a. Renildes de Oliveira Luciaro

Msc. Ney Mussa de Moraes

RESUMO

Fundamento: As políticas públicas são direcionadas por meio do controle adequado das receitas e despesas para uma gestão eficiente, em especial, a receita, que tem em sua base o orçamento e importância na alocação dos recursos arrecadados seguindo exigências da Lei de Responsabilidade Fiscal. O presente estudo frisa a importância do ICMS na base arrecadatória dos Estados e, principalmente, melhorar a projeção de receitas desse tributo visto que em Mato Grosso, segundo dados apurados no *site* da Secretaria de Fazenda – SEFAZ/MT, o erro de previsão do imposto varia de 10% a 13% com o modelo econométrico atualmente utilizado. **Objetivo:** realizar previsão de ICMS de Mato Grosso utilizando-se de análise ARIMA com a ferramenta X13ARIMA-SEATS para ajustar e modelar a série; **Método:** foi feita uma análise gráfica dos dados para verificar os componentes clássicos de séries temporais como tendência, sazonalidade, ciclos e, de forma mais profunda, uma análise e ajuste dos dados de forma a permitir uma previsão com maior acurácia possível; **Resultado:** dos resultados apurados, a utilização do X13ARIMA-SEATS resultou em uma acurácia de 4,83% em contraponto à taxa de erro de previsão do estado de Mato Grosso que, para o período de 1993 a 2019, apresentou um erro de 10 a 13%; **Conclusões:** Concluiu-se, assim, que o X13ARIMA-SEATS contribuiu para reduzir o erro de previsão na arrecadação do ICMS no estado.

Palavras-chave: Séries Temporais. Acurácia. Erro de Previsão. ICMS.

LISTA DE FIGURAS

FIGURA 1 - PROCESSO ESTOCÁSTICO	22
FIGURA 2 - O MÉTODO DE BOX-JENKINS	40
FIGURA 3 - AJUSTE SAZONAL AUTOMÁTICO.....	45
FIGURA 4 - OUTLIER DO TIPO LS	45
FIGURA 5 - OUTLIER DO TIPO AO	45
FIGURA 6 - AVALIAÇÃO DO AJUSTE SAZONAL E SIGNIFICÂNCIA DOS PARÂMETROS.....	47
FIGURA 7 - OUTPUT DO MODELO DE AJUSTE AUTOMÁTICO	48
FIGURA 8 - ACURÁCIA DO MODELO PREVISTO EM RELAÇÃO AO MODELO ATUAL.....	51

LISTA DE TABELAS

TABELA 1 - AUTORES / ESTADOS.....	24
TABELA 2 - ARGUMENTOS DA FUNÇÃO SEAS() PARA AJUSTE AUTOMÁTICO	44

LISTA DE GRÁFICOS

GRÁFICO 1 - ICMS MENSAL NO ESTADO DE MATO GROSSO, 1993-2019	37
GRÁFICO 2 - ARRECADAÇÃO DE ICMS DOS ESTADOS EM 1995 E 2013.....	37
GRÁFICO 3 - EVOLUÇÃO DAS RECEITAS NO PERÍODO DE 1993 A 2019.....	41
GRÁFICO 4 - SÉRIE HISTÓRICA ANUAL NO PERÍODO DE 1993 A 2018.....	42
GRÁFICO 5 - SÉRIE HISTÓRICA MENSAL	43
GRÁFICO 6 - GRÁFICO DA SÉRIE AJUSTADA DE ICMS NO PERÍODO DE 1993 A 2019	50
GRÁFICO 7 - GRÁFICO DA COMPONENTE SAZONAL (SI RATIO).....	51
GRÁFICO 8 - GRÁFICO DA PREVISÃO DO MODELO.....	52
GRÁFICO 9 - SÉRIE ORIGINAL DE ARRECADAÇÃO DE ICMS E PREVISÃO DO AJUSTE	53

SUMÁRIO

1	INTRODUÇÃO	8
2	JUSTIFICATIVA E IMPORTÂNCIA DO ESTUDO	11
3	REFERENCIAL TEÓRICO	12
3.1	TRIBUTAÇÃO	12
3.2	TRIBUTAÇÃO SOBRE O CONSUMO.....	14
3.3	ICMS.....	15
3.4	SÉRIES TEMPORAIS E PREVISÕES	18
3.5	ESTUDOS REALIZADOS.....	22
4	METODOLOGIA.....	26
4.1	MODELOS DE PREVISÃO ECONÔMICA EM SÉRIES TEMPORAIS	26
4.2	MODELAGEM DE SÉRIES TEMPORAIS	26
4.3	PROCESSOS ESTOCÁSTICOS	28
4.4	ENTENDENDO A ESTACIONARIEDADE.....	30
4.5	MODELOS OU PROCESSOS ESTACIONÁRIOS	31
4.6	MODELO AUTORREGRESSIVO (AR).....	32
4.7	VARIÂNCIA DO AR(1).....	32
4.8	MODELO AUTORREGRESSIVO GENÉRICO	34
4.9	MODELO DE MÉDIAS MÓVEIS (MA).....	35
4.10	MODELO AUTORREGRESSIVO E DE MÉDIAS MÓVEIS (ARMA)	36
4.11	DADOS E AMOSTRA.....	36
4.12	ETAPAS DA METODOLOGIA DE BOX-JENKINS	38
4.13	MODELO BOX E JENKINS	39
5	RESULTADOS E ANÁLISES	41
5.1	DIAGNÓSTICO DE AVALIAÇÃO DO MODELO.....	49
6	CONCLUSÃO.....	55
7	REFERÊNCIAS	59
8	APÊNDICES.....	62
	APÊNDICE A – VALOR DO ICMS (DEFLACIONADO) NO PERÍODO DE JANEIRO DE 1993 A JUNHO DE 2019	62

1 INTRODUÇÃO

Tanto na administração privada quanto na administração pública, é indispensável ter um controle adequado das receitas e despesas para uma gestão eficiente. Na administração pública, em especial, há uma atenção maior nas receitas pois são estas que direcionam o andamento das políticas públicas. Nesse sentido, uma previsão mais realista, no caso do presente trabalho, as receitas provenientes do ICMS, permitiria ao gestor um melhor planejamento financeiro e conseqüentemente uma melhoria nos processos de gestão.

Segundo Liebel (2004) um governo mantém um controle fiscal adequado quando tem planejamento orçamentário equilibrado, principalmente com a base orçamentária, que é a receita do ente federativo e onde o governo informa o quanto de dinheiro irá dispor no ano subseqüente para pagamento de servidores, amortizações dos juros e dívidas, bem como para realização de novas obras. Nesse sentido, as previsões dos órgãos governamentais tornam-se estratégicas. O autor aponta ainda que a elaboração do orçamento e seu adequado acompanhamento deve ser feita por exigência legal segundo a Lei de Responsabilidade Fiscal – LRF.

Ao analisar relatórios da receita pública do Estado de Mato Grosso, verificou-se que, a partir do ano de 2004, na metodologia de previsão da receita do ICMS, o fator tempo foi decisivo para adoção do modelo econométrico vigente àquela época. No Relatório do exercício de 2004, foi apresentado, em seu anexo, um documento da Fundação de Pesquisas Econômicas (Fipe) demonstrando a metodologia de previsão de arrecadação do ICMS usando um modelo econométrico de previsão de arrecadação por segmento. Esse modelo é utilizado pela Secretaria de Fazenda do Estado de Mato Grosso até os dias atuais.

Em estudo prévio em outras unidades federativas ficou demonstrado que o modelo vigente em MT não é uma unanimidade, o que levanta as seguintes questões: quais os modelos existentes? E, principalmente, qual é o modelo que pode apresentar maior acurácia para a realidade do Estado de MT?

Neste trabalho será avaliado se o modelo econométrico adotado pelo Governo Estadual está tendo acurácia na previsão de receitas. Uma análise dos relatórios das receitas, encontradas no sítio da Secretaria de Fazenda do Estado de Mato Grosso

apontou que as receitas estimadas divergem, em média, de 10 a 13% dos valores efetivamente arrecadados.

Este estudo propõe, como hipótese, que o modelo de previsão utilizando a metodologia de X13-ARIMA-SEATS apresenta maior acurácia do que o modelo de previsão utilizado pelo Governo do Estado de Mato Grosso na estimativa da receita do ICMS.

Tem, portanto, esta monografia, o objetivo de desenvolver uma análise crítica quanto ao modelo de previsão do ICMS utilizado pelo Estado de Mato Grosso no período de 1993 a 2019 e estimar um modelo preditivo da arrecadação de ICMS pelo governo de Mato Grosso utilizando a metodologia de X13-ARIMA-SEATS no mesmo período e comparar as estimativas com os valores efetivamente previstos de modo que permita a comparação se os modelos utilizados apresentaram melhor maior acurácia na previsão de receitas.

Tem como objetivos específicos: a) Desenvolver um estudo sobre as aplicações de modelos utilizados em alguns trabalhos selecionados no contexto do ICMS no Brasil; b) Comparar a projeção realizada pelo Estado de Mato Grosso com as projeções realizadas em outros Estados da Unidade Federativa; c) Analisar a previsão do ICMS por meio de um modelo de forma comparativa ao modelo utilizado atualmente pela Secretaria de Fazenda do Estado de Mato Grosso (SEFAZ-MT).

Para o Governo do estado de Mato Grosso, a previsão da arrecadação da receita tributária é fundamental, principalmente no que diz respeito ao custeio, investimento e endividamento. Ou seja, no curto prazo, a previsão de receitas se apoia na gestão do fluxo de receitas e é, também, um indicador em relação às mudanças conjunturais.

Já no longo prazo as previsões podem fornecer apoio a nível macroeconômico para políticas públicas do Estado, de modo que possa amparar mudanças mais estruturais, tendo em vista a discrepância observada no método de arrecadação atual.

Além do contexto político e econômico, há, também, a exigência da legislação para previsão das receitas tributárias e estão no art. 12 da Lei de Responsabilidade Fiscal (LC 101/00).

O presente trabalho está estruturado da seguintes forma: no capítulo 3 tem-se o referencial teórico que subsidia o estudo em questão, onde é feita uma explanação sobre a tributação na seção 3.1, tributação sobre o consumo, na seção 3.2, ICMS, na seção 3.3, séries temporais e previsões, na seção 3.4, e, por fim, os estudos

realizados, na seção 3.5. Na seção 4 tem-se a apresentação da metodologia utilizada com detalhamento dos modelos de previsão econômica em séries temporais, na seção 4.1, modelagem de séries temporais, na seção 4.2, sobre processos estocásticos, na seção 4.3, entendendo a estacionaridade, na seção 4.4, modelos ou processos estacionários, na seção 4.5, modelos autorregressivos (AR), na seção 4.6, variância do AR(1), na seção 4.7, modelo autorregressivo genérico, na seção 4.8, modelos de médias móveis (MA) na seção 4.9, modelos autorregressivos e de médias móveis (ARMA) na seção 4.10, dados e amostra, na seção 4.11, etapas da metodologia de Box-Jenkins, na seção 4.12, modelo Box e Jenkins, na seção 4.13. As análises e tratamento dos dados constam na seção 5, de resultados e análises, na seção 5.1 versa sobre o diagnóstico de avaliação do modelo; por fim, tem a conclusão, na seção 6.

2 JUSTIFICATIVA E IMPORTÂNCIA DO ESTUDO

Este trabalho justifica-se dada a importância em verificar a acurácia da previsão da arrecadação de ICMS para apoio aos gestores públicos na formulação de políticas sociais. Quanto mais acertada ou próxima da realidade for a previsão, melhor o gestor poderá contribuir para a função alocativa do Estado, injetando recursos da melhor maneira possível. Uma segunda importância na elaboração do presente trabalho está no fato de responder à exigência da LRF, especialmente no que diz respeito à previsão de receitas.

3 REFERENCIAL TEÓRICO

3.1 TRIBUTAÇÃO

Segundo Siqueira, Nogueira e Barbosa (2004, p. 155), os sistemas tributários introduzem distorções nas economias de todos os países, principalmente os tributos sobre a renda e os tributos sobre venda de mercadorias, além de gerarem distorções pois influenciam o comportamento dos agentes econômicos, o que acaba por influenciar nas escolhas dos agentes, enquanto consumidores, gerando, desse modo, ineficiência e redução do bem-estar da sociedade em relação a um modelo de tributação que não apresenta tal distorção.

A teoria ótima da tributação é caracterizada pela estrutura tributária que permite ao governo arrecadar uma dada receita e alcançar objetivos distributivos, com menor custo em relação em termos de perda de eficiência e é influenciada pelas circunstâncias específicas de cada país. O sistema tributário ótimo depende de três fatores básicos: conjunto de instrumentos fiscais à disposição do governo, estrutura de preferências das famílias e os pesos sociais que são atribuídos ao bem-estar dos diferentes indivíduos da sociedade (SIQUEIRA; NOGUEIRA; BARBOSA, 2004).

Para Siqueira e Ramos (2004, p. 155), algumas questões surgem quando se fala em “impostos”: quais agentes vão arcar com a carga tributária? E como a carga tributária será distribuída entre os agentes econômicos? Quando se institui um imposto há, também, mudança no comportamento nesses agentes, que podem ser indivíduos, firmas e, talvez, o governo.

Em mercados competitivos, para Siqueira e Ramos (2004, p. 155), destaca-se a diferença entre um imposto específico sobre as vendas e de um imposto ad valorem. O imposto específico (ou unitário) é aquele em que se arrecada um montante fixo por unidade vendida, que, em se tratando de um país em subdesenvolvimento, aplica-se em produtos como cigarros, bebidas alcoólicas e combustíveis. Um exemplo do Brasil é o caso do IPI (Imposto sobre Produtos Industrializados) incidente sobre bebidas alcoólicas. Já um imposto ad valorem ocorre quando é estabelecido como um percentual do preço do produto ou da base de incidência. No Brasil, um exemplo seria o ICMS (Imposto sobre Circulação de Mercadorias e Serviços).

No que diz respeito à cumulatividade dos tributos, para Siqueira e Ramos (2004, p. 170), um tributo é cumulativo quando é cobrado em diversas etapas do processo produtivo em que se cobra o tributo em uma base que contém o tributo cobrada em etapas anteriores e essa cobrança não é acompanhada de mecanismos de compensação das cobranças realizadas em etapas anteriores da cadeia de produção, produzindo, assim, uma incidência em cascata. Esse tipo de situação gera distorções sobre a alocação dos recursos e reduz a capacidade de competição dos produtores nacionais.

Para Lagemann (2004, p. 405) a discussão sobre tributação ótima está baseada sobre um suposto conflito entre fisco e contribuinte. A solução ideal (ou tributo lump sum) seria que fosse possível medir o potencial de adquirir renda que constituísse a única característica de diferencial pessoal entre os contribuintes. Porém, como não é possível, opta-se pela segunda melhor solução (second best) onde o fisco se satisfaz com o controle indireto dos contribuintes através de indicadores. Já no que diz respeito do imposto sobre o consumo, o autor parte da premissa da Regra de Ramsey em que caracteriza a situação ótima do sistema sob a ótica da eficiência – onde a economia é representada pela modelagem com um único consumidor ou com vários consumidores com mesmos gostos e hábitos.

Segundo Sampaio (2004, p. 188), os impostos sobre o consumo, em especial nos países subdesenvolvidos, correspondem a uma parcela substancial da arrecadação total. Apesar de que esse tipo de tributação seja considerado como característica de subdesenvolvimento, estudos recentes apontam uma inversão dessa tendência, redesenhando, assim, o papel da tributação indireta, ao demonstrar que impostos sobre o consumo podem contribuir para o crescimento da poupança nacional. A autora aponta que em presença de fortes disparidades de renda, um desenho adequado da tributação indireta pode aumentar o nível de bem-estar e contribuir, dessa forma, para a redução das desigualdades.

Para Sampaio (2004, p. 189), os impostos cumulativos (ou em cascata) são aplicados sobre o faturamento e incidem em todos os estágios do processo produtivos. E por se tratar de um imposto de tributação múltipla, pode levar a uma excessiva verticalização da produção. A comutatividade, que é o grau em que o tributo é repassado para o consumidor, depende das condições de mercado, do grau de piramidização dos preços, da relação entre os insumos tributáveis e não tributáveis e a quantidade de estágios do processo produtivo.

Já os impostos sobre o valor agregado, segundo Sampaio (2004, p. 190), substitui o imposto cumulativo sobre as vendas. Essa substituição, realizada na grande maioria dos países, é considerada uma das mais importantes inovações dos sistemas tributários contemporâneos e é a base da maioria das reformas tributárias bem sucedidas. Os principais tipos de impostos sobre o valor agregado são: IVA-P (IVA-Produto), IVA-R (IVA-Renda) e o IVA-C (IVA-Consumo) e esses impostos podem ser implementados de acordo com dois princípios: (i) princípio de origem e o (ii) princípio de destino. Há, também, dois métodos de cálculo: o método da nota-crédito (credit invoice) e o método de subtração.

E, por fim, os impostos seletivos, de acordo com Sampaio (2004, p. 197), são aqueles aplicados a determinados produtos e esse tipo de imposto representam uma fonte significativa de geração de receitas tanto do ponto de vista da administração quando sob a ótica da eficiência. Os impostos seletivos tem efeitos distorcidos reduzidos, sua cobrança é relativamente fácil e apresenta restritas possibilidades de evasão fiscal. Se o objetivo é o aumento das receitas, esse tipo de imposto é de fácil definição, possuem volumes elevados de vendas, possuem demandas inelásticas e ausência de substitutos. E mais: esse tipo de tributação geram receitas para os entes subnacionais de governo, pois representam a única fonte de recursos para esses entes federativos e, além de que, podem ser regionalizados facilmente, o que permite a existência de múltiplas alíquotas considerando as disparidades inter-regionais. A tributação seletiva é largamente utilizada para fins distributivos.

3.2 TRIBUTAÇÃO SOBRE O CONSUMO

Para Sampaio (2004, p. 198), tributação sobre o consumo, sob o ponto de vista da eficiência, a preocupação é na redução do gravame excessivo e o modo de minimizar as perdas em termos de bem-estar. Há um duplo embate sobre o assunto, quanto aos que defendem a tributação uniforme e quanto aos que defendem um sistema de alíquotas diferenciadas. Aos que defendem a tributação uniforme apontam que nesse tipo de desenho tributário, as elasticidades exigidas para sua implementação não estão disponíveis, o que compromete esse tipo de desenho. E mais, torna-se muito complexo administrativamente acompanhar as alíquotas

diferenciadas o que faz com que seja mais fácil a adoção de um sistema uniforme. Aos que defendem as alíquotas diferenciadas defendem que, pelo fato das elasticidades serem distintas e os bens serem complementares ou substitutos, a tributação uniforme não reduz o gravame excessivo e por isso pela sua não recomendação. É imperativo afirmar, segundo a autora, que todas as formas de tributação tornam as decisões dos agentes econômicas distorcidas e que remetem às limitações das decisões de *second best*.

3.3 ICMS

O ICMS é um tributo indireto e um imposto incidente sobre o consumo. Possui base ampla e generalizada, de caráter arrecadatório com incidência sobre a parcela do valor agregado nas transações de mercadorias que se sujeitam ao imposto. É indireto pois o contribuinte de fato, que é o contribuinte da mercadoria, é quem paga o ônus do imposto repassado pelo contribuinte de direito (CASTANHO, 2011). Segundo Sampaio (2004, p. 199) a federação brasileira é caracterizada pela forte tributação sobre o consumo e que representa uma parte significativa da arrecadação e o ICMS (Imposto sobre Circulação de Bens e Serviços) é o que gera maior arrecadação. Por se tratar de um tributo sob competência dos estados, é um dos poucos exemplos no mundo em que um imposto do tipo IVA é gerido por meio de uma esfera subnacional de governo.

Em se tratando do montante de arrecadação, é um imposto que constitui a principal fonte de recursos próprios dos entes subnacionais e tem participação média de 90% da arrecadação tributária dos Estados e aproximadamente 25% da carga tributária dos níveis de governo, considerando as três esferas (CASTANHO, 2011).

O Brasil, acompanhando o movimento dos países europeus que, em sua maioria, adotam o IVA (Imposto sobre o Valor Agregado) sobre os impostos mais importantes de seus respectivos sistemas tributários, adotou, em nosso sistema tributário com vigência a partir de 1967 (com significativa reforma na tributação sobre as vendas), que onerava as vendas de mercadorias de forma cumulativa, o ICM (Imposto sobre Circulação de Mercadorias) com características mais modernas de não-cumulatividade e seletividade que incidiam sobre o valor agregado em cada etapa

do processo de produção e circulação de mercadorias e, na maioria dos casos, as empresas repassavam ao consumidor através dos preços dos produtos (RESENDE, 1993 apud CASTANHO, 2011).

Sendo o Brasil o primeiro país a introduzir o IVA, em 1967, não podemos afirmar que esse pioneirismo resultou em um sistema tributário eficiente, igualitário e gerenciável, pois, implementado pelo método da nota-crédito, o ICMS rapidamente chegou a um nível de complexidade o que dificultou seus impactos econômicos, ocasionando a adoção de diferentes alíquotas, concessão de inúmeras isenções e privilégios fiscais acabou por transformar este imposto praticamente em impostos cumulativos (em cascata), perdendo-se, em sua essência, os benefícios ligados à taxação do valor agregado e abrindo brechas para a evasão e elisão fiscal, levando o país a aumentar as alíquotas básicas deste imposto contrastando com às alíquotas adotadas quando de sua introdução (SAMPAIO, 2004, p.200).

O ICMS no Brasil, segundo Sampaio (2004, p. 201-203), apresenta diversas distorções, principalmente no que diz respeito à formação de capital e ao comércio inter-regional e internacional. Inicialmente, foi implementado como uma forma híbrida do princípio de origem e de destino e não incidindo sobre exportações industriais (mas era cobrado das exportações agrícolas). Porém, arranjos particulares provenientes de acordos entre os estados, levaram a isenção de vários itens, o que levou a aproximar do princípio de destino. Não obstante, a Lei Kandir reforçou esse movimento quando desonerou as exportações agrícolas. Assim, é importante coordenar as políticas tributárias no âmbito da federação e a utilização de alíquotas diferenciadas para o comércio interestadual pode corrigir, pelo menos em parte, esse tipo de problema.

A Constituição Federal de 1988, em seu art. 153, § 2º, III, aponta que o ICMS possui seletividade em função das mercadorias serem essenciais ou não. Logo, para produtos básicos, o imposto tem incidência menor do que para produtos supérfluos. A legislação flexibiliza a regra em relação a alguns setores, tais como combustíveis, serviços de energia elétrica e telefonia que não se submetem ao princípio da essencialidade. Nesse diapasão, o Senado Federal (com iniciativa do Presidente da República) tem competência para estabelecer alíquotas mínimas e máximas em operações internas (CASTANHO, 2011).

Na maioria das operações, a base de cálculo do ICMS se dá com o valor da operação, ou prestação de serviços; valor total da operação em caso de fornecimentos

de mercadorias com serviços não compreendidos em competência municipal (CASTANHO, 2011).

O campo de incidência do ICMS foi ampliado com a implantação do sistema tributário pela Constituição de 1988 onde foram eliminados os impostos únicos existentes até então e também da tributação sobre serviços e incorporação dessas bases ao novo ICMS. A competência para arrecadação desse imposto fica a cargo dos Estados e do Distrito Federal (art. 155, II, CF/88) e observe que o ICMS é o principal imposto sobre o consumo no Brasil, correspondendo a aproximadamente 25% de toda a arrecadação tributária nacional (CASTANHO, 2011).

No que diz respeito às alíquotas do ICMS, há variação entre os Estados e Distrito Federal e sua fixação se dá por resolução aprovada pelo Senado Federal, conforme dispõe o Art. 155, § 2º, incisos IV e V da Constituição de 1988 e no caso das cobranças sobre as operações interestaduais, a receita proveniente da arrecadação é dividida entre o Estado que produz o bem e o Estado que o comercializa. Essa regra possui exceções, como é o caso do petróleo, dos combustíveis e da energia elétrica, pois, nesses casos, a receita de arrecadação é destinado ao estado produtor do bem (CASTANHO, 2011).

A lei que definiu normas gerais para o ICMS, qual seja, a Lei Complementar nº 87, de 13/09/96, conhecida também como Lei Kandir, atribui ao contribuinte do imposto (ou o depositário) a responsabilidade pelo pagamento do mesmo; nesse caso, o contribuinte assume a condição de substituto tributário. Essa responsabilidade quanto à atribuição de substituto tributário em relação a operações com mercadorias e serviços fica a cargo da legislação de cada Estado. Na substituição tributária, o imposto passou basicamente de um tributo multifásico para um tributo monofásico, ou seja, a tributação que incidia em cada etapa do processo produtivo passou a ser tributada sobre aquele que oferece maior segurança no recolhimento de todo o tributo relativo à cadeia produtiva e que será, então, o sujeito passivo responsável pelo recolhimento, inclusive sobre fatos geradores que possam porventura ocorrer posteriormente (CASTANHO, 2011).

O conceito de contribuinte do ICMS, estabelecido na Lei Complementar nº 87/96, em seu art. 4º, é qualquer pessoa física ou jurídica que, com habitualidade (ou volume), e com finalidade comercial, realize operações relacionadas à circulação de mercadorias e/ou prestações de serviços de transporte interestadual, intermunicipal e

comunicação, mesmo que as operações são iniciadas no exterior (CASTANHO, 2011).

A Lei Kandir incentiva a desoneração sobre a exportação e também sobre a produção e investimentos. Quanto à exportação, a lei estabelece que não se incida tributo sobre operações e prestações de serviços que são destinadas ao exterior (incluindo produtos primários e produtos industrializados semielaborados, ou serviços) e estabelece, também, o direito da empresa em creditar a si mesma o imposto incidente sobre as mercadorias e insumos que entram em seu estabelecimento e que são destinados à integração ou consumo em processo de produção de mercadorias industrializadas inclusive aquelas que são destinadas ao exterior. Em relação à desoneração sobre a produção e investimento, a lei garante às empresas o direito de crédito do tributo sobre a entrada de mercadorias destinadas ao uso ou consumo do estabelecimento (inclusive energia elétrica) e sobre bens que são destinados para o ativo permanente da empresa (CASTANHO, 2011).

3.4 SÉRIES TEMPORAIS E PREVISÕES

Para Fava (2000, p. 199), a econometria aplicada, quando envolvem dados acerca da realidade econômica, apresenta-se sob duas formas: séries de tempo e dados de *cross section*, em que a observação da variável é realizada em um único instante de tempo (conhecida como *cross section* ou corte transversal no tempo), variando apenas as unidades que são observadas como, por exemplo, regiões geográficas, classes socioeconômicas, empresas etc. Já nas séries temporais, a variável econômica é observada pela sua trajetória temporal.

Um importante conceito de séries temporais, de acordo com Ehlers (2005) é que se trata de um conjunto de observações que são feitas ao longo do tempo sequencialmente. Frise-se que, nas séries temporais, a ordem das observações é relevante. As séries temporais podem ser contínuas ou discretas. São contínuas quando são realizadas continuamente no tempo e discretas quando são feitas em tempos específicos, em mesmos espaços de tempo.

Para Rossi (2014) os métodos das séries temporais têm suas características peculiares pois utilizam-se de um comportamento passado de uma variável para

realizar previsões geralmente incondicionais e de curto prazo sobre a variável. Geralmente precisam de muitas observações principalmente se for na fase de análise que antecede a modelagem.

Segundo Gujarati (2011, p. 732) para estudar as séries temporais, tem que se ter noção do “vocabulário dos analistas de séries temporais” de alguns conceitos importantes como processos estocásticos, processos estacionários, processos puramente aleatórios, processos não estacionários, variáveis integradas, modelos de passeios aleatórios, cointegração, tendências determinísticas e estocásticas, testes de raiz unitária. Para o autor, há dois métodos de previsão de variáveis econômicas, como o PIB, a inflação, as taxas de juros, os preços das ações e outros, que se tornaram muito populares. São eles, o processo estocástico regressivo integrado de média móvel (ARIMA), ou também conhecido como metodologia Box Jenkins e vetores autorregressivos (VAR). Neste trabalho, será limitado ao primeiro método.

Segundo Rossi (2014) uma série temporal (ou série histórica) é a realização de um processo estocástico. Ou seja, trata-se de uma sequência de observações arranjadas cronologicamente, por exemplo, vendas anuais de um produto, dados mensais de desemprego, preço das ações em bolsa diariamente etc. Para Gujarati (2011, p.734), processos estocásticos são entendidos por uma coleção de variáveis aleatórias ordenadas no tempo. Assim, se deixarmos que Y denote uma variável aleatória, e se ela for contínua, ela será denotada por $Y(t)$, porém, se for discreta, será denotada por Y_t . Essa distinção entre processo estocástico e sua realização é a mesma analogia quando se fala em população e amostra em cortes transversais, pois, se utilizarmos dados amostrais para fazer inferências sobre a população, utilizamos, geralmente, em séries temporais, a realização para fazer inferências sobre o processo estocástico subjacente.

Nas séries temporais estudam-se a propriedade da série, geralmente são estudados o padrão de tendência, existência de padrão sazonal, outliers, alterações estruturais etc. Estuda-se, também, a explicação em que se usa a variação em uma série para explicar a variação de outra série. São estudados a predição, ou seja, a capacidade de prever valores futuros com base em valores passados (EHLERS, 2005).

Quando os dados de uma ou mais séries temporais são analisadas, segundo Ehlers (2005), as representações gráficas podem revelar padrões de comportamento importantes, tais como tendências de crescimento/decrescimento, padrões cíclicos,

alterações estruturais etc. e que podem ser facilmente identificados. Ou seja, em qualquer análise, o gráfico temporal deverá ser analisado primeiro.

Algumas séries temporais financeiras, tais como preços de ações, apresentam o fenômeno do passeio aleatório que, por exemplo, a melhor previsão do preço de uma variável amanhã seja igual ao preço de hoje mais um choque puramente aleatório (ou termo de erro). Caso isso ocorra, seria inútil prognosticar os preços das variáveis (GUJARATI, 2011, p.731). Já para Morettin (2006, p.18) as séries econômicas e financeiras possuem algumas características que lhe são peculiares como, por exemplo, tendências, sazonalidades, pontos influentes (atípicos), heterocedasticidade condicional, não-linearidade.

Para Fava (2000, p. 200), as séries temporais podem ser decompostas em tendência, ciclo, sazonalidade e termo errático, podendo resultar na combinação de todos os componentes ou um subconjunto deles. A tendência (T), para a autora, toma os dados em um movimento contínuo para uma determinada direção, durando por um longo período de tempo. O ciclo (C) oscila em torno da tendência, durante um determinado período de tempo (geralmente maior do que um ano) e não é regular, não necessariamente. Por sua vez a sazonalidade (S) é basicamente um movimento que oscila com certa regularidade em subperíodos de tempo fixo, normalmente em torno de um ano. E, por fim, no componente errático (E), os dados apresentam um movimento irregular provenientes de fatores basicamente aleatórios. E, por se tratar de séries econômicas, o termo errático sempre estará presente. A autora enfatiza que a combinação pode se dar de forma aditiva ou multiplicativa. A decomposição desse tipo de série se faz através das médias móveis ou pela explicitação dos componentes como funções determinadas no tempo. A autora ressalta a difusão do método X-11 (atualmente, método X-13ARIMA-SEATS) destinado ao tratamento da sazonalidade.

É importante frisar que a estimação de componentes que são expressos como função não aleatória no tempo ou função determinística pode ser feita utilizando um modelo de regressão linear. Nesse tipo de abordagem, as séries temporais são resultados de uma combinação de funções determinísticas do tempo e de um termo aleatório; e é a presença do termo aleatório ε_t que faz com que a série de tempo se desvie do traçado indicado pela função determinística.

Uma abordagem alternativa, que toma as séries temporais como sendo totalmente geradas por um mecanismo aleatório chamado processo estocástico, onde

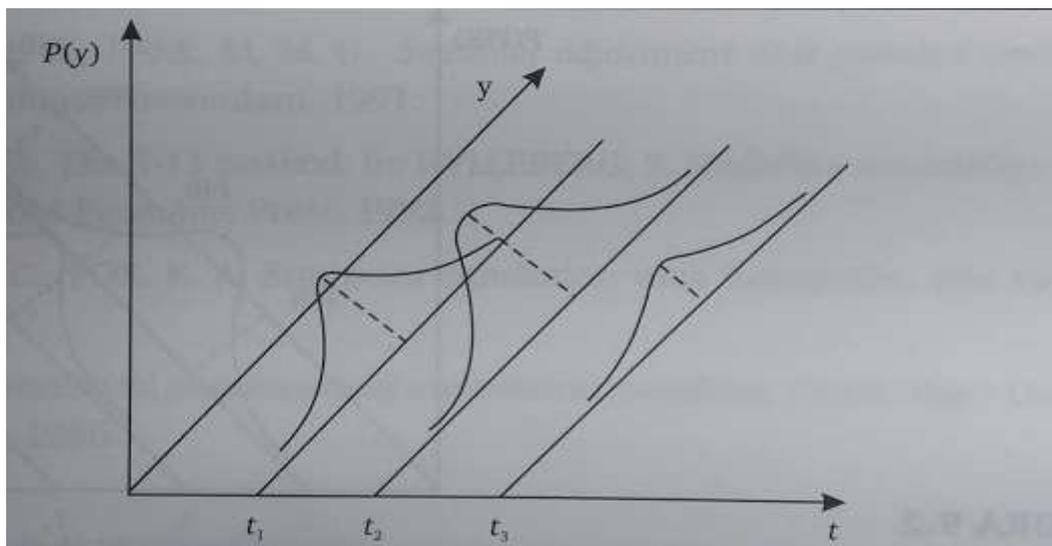
em cada instante t há uma família de valores que a série pode assumir, em que são associados às probabilidades de ocorrência conforme se verifica na Figura 1.

Em se tratando de dessazonalização, o trabalho de Ferreira, Gondin Jr. e Mattos (2015) aponta que a remoção da sazonalidade de uma série temporal pode ocorrer através de várias metodologias (ou softwares) que permitem a retirada do componente sazonal de uma série temporal. Citaram, como exemplos, a *Seasonal Dummies*, Holt-Winters, *Structural Models*, *Dainties*, TRAMO-SEATS, X-11, X-11ARIMA, X-12ARIMA, X-13ARIMA-SEATS. Em especial, o programa de Dessazonalização X-13-ARIMA-SEATS (que foi uma junção dos softwares X-12-ARIMA e TRAMO/SEATS), foi criado em 2012 e desenvolvido por U.S. Census Bureau, tem como destaque o fato do pré-ajuste da série temporal, corrigindo as séries antes de ser feito um ajuste sazonal. Exemplificando a importância desse programa, é que alguns eventos não atípicos como, por exemplo, greves, catástrofes etc. podem afetar o padrão sazonal de uma série temporal e, assim, podendo gerar um ajuste de qualidade inferior, porém, com o tratamento adequado desses eventos, ou seja, um pré-ajuste, deve ser feito, se necessário.

Nesse sentido, para Ferreira, Gondin Jr. e Mattos (2015), a decomposição clássica de uma série temporal se dá em quatro componentes que não são observáveis visualmente como a tendência, sazonalidade, ciclo e erro; a ocorrência desse eventos podem ocasionar a conclusões equivocadas da série temporal em estudo.

Para Fava (2000, p201), a abordagem denominada *processo estocástico*, onde para cada instante de tempo t , existe uma família de valores que a série pode assumir e que estão associadas à probabilidade de ocorrência que pode ser visualizada conforme figura abaixo:

FIGURA 1 - PROCESSO ESTOCÁSTICO



FONTE: FAVA (2000, P. 201)

Em definição, processo estocástico “é uma sequência ordenada (no tempo) de variáveis aleatórias $\{y(t), t \in T\}$ definidas no mesmo espaço de probabilidade (S, ζ, P) ” (FAVA, 2000, p.202).

3.5 ESTUDOS REALIZADOS

Chain et al (2015) estimou um modelo de previsão da arrecadação de ICMS de Minas Gerais no período de janeiro de 1998 a agosto de 2011 considerando valores atípicos na previsão do tributo e comparou as principais medidas de erro do modelo estimado com os modelos que desconsideraram essa característica. No trabalho verificou-se, também, a validade da previsão dos dados 12 meses à frente. O resultado do trabalho corroborou com a hipótese de que os *outliers*, se adequadamente tratados, tenderiam a reduzir o erro na previsão da arrecadação de ICMS de Minas Gerais. Uma dificuldade apresentada foi a identificação das causas geradores atípicos na literatura.

Azevedo (2017) procurou analisar a metodologia de previsão com modelos de séries temporais e se estes aumentavam a acurácia das estimativas de receita de ICMS de alguns estados da federação, no período de 1995 a 2011, utilizando a metodologia ARIMA e comparou as estimativas apuradas com os valores previstos pelos estados para verificar se as estimativas previstas pelos estados apresentaram

maior acurácia na previsão de receitas. Os resultados apontaram que as estimativas feitas pelos estados apresentaram erro de -11,3% em 2012 e de -11,6% em 2013 já as estimativas apresentadas no trabalho apontaram um erro de previsão médio em 2012 de 0,9% e de -2,2% em 2013.

Castanho (2011), em seu trabalho, que foi baseado na análise de uma série temporal para arrecadação do ICMS do Estado do Espírito Santo, compreendido entre 2000 a 2009, avaliou vários modelos para definir qual o modelo que melhor se ajusta às características econômicas do ICMS no estado, considerando os setores mais relevantes da economia, bem como a base na teoria econômica. O trabalho apontou que não há apenas um modelo adequado para previsões de receita do ICMS, pois deve-se levar em conta o horizonte de previsão desejado e o comportamento recente da série. O autor destacou que para previsões de curto prazo (em períodos com relativa estabilidade econômica), os modelos de alisamento exponencial de Holt-Winters apresentaram excelentes resultados. Já para as previsões de médio prazo (três a doze meses a frente), os modelos estocásticos de Box-Jenkins apresentaram boa eficiência pela sua capacidade de captar e reproduzir o comportamento estrutural da série. Os modelos econométricos aplicam-se tanto no médio quanto no longo prazo e podem orientar na definição de políticas e planejamento governamental, considerando que as variáveis sejam relevantes e bem identificadas bem como a existência de dados com qualidade e quantidade necessárias.

Clemente e Clemente (2011) realizaram um trabalho de previsão de arrecadação do ICMS do Estado do Paraná para um horizonte de doze meses (de agosto de 2011 a julho de 2012), considerando a série mensal e janeiro de 2000 a julho de 2011, utilizando a metodologia Box-Jenkins para modelar a série mensal, por meio de testes de estacionariedade do tipo Dickey-Fuller e o melhor modelo para previsão apresentado foi o SARIMA. O autor apresentou, como resultado, um crescimento de 13,2% de crescimento até janeiro de 2012.

Pessoa e Coronel (2012), em seu trabalho, realizaram a modelagem da série de ICMS do Estado de Minas Gerais no período de 1998 a 2011, utilizando como metodologia de análise modelos autorregressivos integrados de médias móveis (ARIMA) e dada a presença de memória longa mediante modelos autorregressivos fracionalmente integrados de médias móveis (ARFIMA). O autor apontou que os modelos estimados tiveram bom ajuste aos dados e mostraram-se bastante úteis para prever valores futuros da série de ICMS. Já Santos e Lima (2006) realizaram, no

mesmo estado, a geração de um modelo de previsão para arrecadação do ICMS utilizando a metodologia de Box-Jenkins destacando o modelo SARIMA, por ser o mais eficiente. Foi projetado para o período de junho/2004 a maio/2005 e o resultado mostrou-se satisfatório para previsão de arrecadação do ICMS no estado, concluindo que a previsão foi adequada.

Em seu trabalho, Queiros (2012) realizou a previsão de arrecadação mensal do ICMS para cinco estados brasileiros, no período de 1997 a 2011, visando construir um modelo de previsão de curto prazo para o ICMS, aplicando a metodologia das séries temporais, em particular a metodologia Box-Jenkins (ou metodologia ARIMA) e os resultados da previsão, de modo geral, mostraram-se satisfatórios. O autor fez notas que essa metodologia não é adequada para realizar previsões de longo alcance e também não é recomendado para tomara de decisões de políticas públicas, pois, nesses casos, necessita-se trabalhar modelos com variáveis exógenas predeterminadas.

Na Tabela 1 a seguir estão relacionados os trabalhos que apresentam modelos para estudos de previsão de receitas de ICMS em alguns estados:

TABELA 1 - AUTORES / ESTADOS

Análise	Modelos Propostos	Acurácia	Fonte
ICMS dos Estados: SP, RJ, MG, RS, PR, BA	Metodologia ARIMA (Box-Jenkins)	0,9%	(AZEVEDO, SILVA, GATSIOS, 2017)
ICMS do Estado de Minas Gerais	Metodologia ARIMA (Box-Jenkins)	2,72%	(CHAIN, COSTA, BENEDICTO, 2015)
ICMS do Estado do Espírito Santo	Metodologia ARIMA (Box-Jenkins) Modelo Econométrico Causal Dinâmico	5%	(CASTANHO, 2011)
ICMS do Estado do Paraná	Metodologia ARIMA (Box-Jenkins)	5%	(CLEMENTE E CLEMENTE, 2011)
ICMS dos Estados: RS, SP, GO, AM, BA	Metodologia ARIMA (Box-Jenkins)	1,7%	(QUEIROS, 2012)
ICMS do Estado de Minas Gerais	Metodologia ARIMA (Box-Jenkins)	3%	(SANTOS E LIMA, 2006)

FONTE: AUTORIA PRÓPRIA (2021)

Note que na Tabela 1 são várias regiões do Brasil adotaram o modelo de Box-Jenkins para fins de apuração da receita de ICMS e nenhum trabalho estudado utilizou o Modelo de X13-ARIMA-SEATS. Os trabalhos apresentaram acurácia, em média, em torno dos 3%, bem diferente da média apurada no Estado de Mato Grosso que apresentou variações de 10 a 13% de margem de erro, considerando o modelo atualmente utilizado.

4 METODOLOGIA

4.1 MODELOS DE PREVISÃO ECONÔMICA EM SÉRIES TEMPORAIS

Os dados mensais foram coletados na base de dados do Banco Central do Brasil, onde disponibilizam de uma seção com séries temporais¹, bem como relatório de receita dos estados e municípios (fluxos), no caso em tela, receitas de arrecadação do ICMS do Estado de Mato Grosso no período de 1993 a 2019. Uma outra fonte de captação de dados encontra-se no sítio da Secretaria de Fazenda do Estado de Mato Grosso, onde tem uma seção específica de receitas públicas e que evidenciam as séries históricas do ICMS em valores nominais e corrigidos.

Uma nota quanto aos valores referentes ao período de janeiro de 1993 a junho de 1994, cuja arrecadação estava em unidade monetária em Cruzeiro e foi convertida para o Real (R\$) para manter a consistência da análise. Os dados foram deflacionados utilizando-se o índice IPCA.

O modelo a ser utilizado neste trabalho será o ARIMA e a ferramenta X13-ARIMA-SEATS utilizando o software R Studio para as modelagens necessárias.

4.2 MODELAGEM DE SÉRIES TEMPORAIS

Para Rossi (2014) modelagens de séries históricas são divididas em duas grandes abordagens. A primeira parte da ideia de que a série observada segue uma determinada estrutura; essa é a abordagem clássica na qual se incluem o método da decomposição, os modelos do amortecimento exponencial, modelos de Holt e Holt-Winters. A segunda abordagem começa pela identificação do processo estocástico gerador das observações, o que exige análises mais apuradas, onde são estudados os comportamentos das funções de autocorrelação e autocorrelação parcial, e, nesse contexto, são inseridos os modelos de Box-Jenkins (ARMA, ARIMA, SARIMA), que

¹ A série pode ser consultada na página do Banco Central: www.bcb.gov.br – série nº 4351.

consideram os processos estocásticos estacionários, não-estacionários e também os efeitos da sazonalidade. Este último modelo, segundo Fava (2000, p. 206), tem como objetivo principal a realização de previsão, permitindo que valores futuros das séries sejam previstos tomando por base valores atuais e passados – explora-se a correlação temporal que geralmente existe entre os valores das séries. Neste trabalho será utilizado a abordagem com a utilização dos Modelos de Box-Jenkins, especificamente o Modelo ARIMA.

Neste diapasão, Gujarati (2011, p. 767) aponta que a previsão econômica utilizando as séries temporais podem ser divididas em cinco abordagens: (1) métodos de suavização exponencial, (2) modelos de regressão uniequacionais, (3) modelos de regressão de equação simultânea, (4) processo autorregressivo integrado de média móvel (ARIMA) e (5) modelos de vetores autorregressivos (VAR). No presente trabalho será utilizada a abordagem de processo autorregressivo integrado de média móvel (ARIMA).

O conjunto de processos estocásticos, conhecido também como modelos ARIMA, por envolverem apenas séries de tempo, são classificados como modelos univariados e é essa a relação temporal considerada formalmente pelo enfoque de Box-Jenkins (FAVA, 2000, p. 206).

Segundo Ehlers (2005, p. 39), nos métodos univariados de previsão ocorre a decomposição de uma série temporal em componentes de fácil interpretação e podem ser decompostos de duas formas: por alisamento exponencial simples ou pelo método de Holt-Winters.

Segundo Fava (2000, p. 202), ao se tentar descobrir qual o modelo que traduz o mecanismo de geração da série (processo gerador da série), pode-se dizer que o conjunto de valores que a variável pode assumir corresponde à *população* e que a realização do processo estocástico é uma *amostra* dessa população. Uma forma bastante difundida para tratar dessa questão foi a proposta por Box e Jenkins (1976). Note, que, quando se trabalha com séries econômicas, só é possível ter uma realização de um processo estocástico, ou seja, apenas uma observação em cada instante de tempo.

4.3 PROCESSOS ESTOCÁSTICOS

Para Gujarati (2011, p. 735) há dois tipos de processos estocásticos: processos estocásticos estacionários² e processos estocásticos não-estacionários. No primeiro caso, recebeu uma grande atenção por parte dos analistas de séries temporais, e em definição, se sua média e variância forem constantes ao longo do tempo e o valor da covariância entre os dois períodos de tempo depender apenas da distância/intervalo/defasagem entre os períodos e não o tempo real em que a covariância é computada. A estacionariedade fraca é explicada pelas propriedades abaixo, considerando o Y_t como série temporal estocástica:

Média:
$$E(Y_t) = \mu$$

Variância:
$$var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

Covariância:
$$\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$$

em que γ_k , a covariância, ou autocovariância, na defasagem k , é a covariância entre os valores de Y_t e Y_{t+k} . Se $k = 0$, obtém-se γ_0 que é a variância de $Y (= \sigma^2)$. Agora, se $k = 1$, o γ_1 é a covariância entre os dois valores subjacentes de Y . Para Fava (2000, p. 203) as duas primeiras condições demonstram que a média e a variância de $y(t)$ são invariantes no tempo. Já a última condição impõe que as autocovariâncias são independentes do tempo e variam apenas em relação à distância (k) que separa as observações consideradas.

Em um processo estacionário, que é quando não se desvia muito o seu valor médio em virtude da variância finita, a velocidade da reversão à média depende das autocovariâncias e isso será rápido, se as autocovariâncias forem pequenas, e lento quando são grandes. E isso não é o caso de um processo estocástico não estacionário. Uma série temporal quando não é estacionária, é denominada como série temporal não estacionária (estacionariedade fraca). Ou seja, uma série temporal não estacionária tem uma média que sofre variação no tempo, ou uma variação que varia com o tempo, ou então, ambas (GUJARATI, 2011, p.735).

Gujarati (2011, p. 735) ressalta a importância das séries temporais pois, se elas não são estacionárias, o comportamento da série pode ser estudado apenas pelo

² Segundo Gujarati (2011, p. 734) os processos estocásticos são conhecidos também como: processo estocástico fracamente estacionário, ou covariância-estacionário, ou estacionário de segunda ordem, ou em sentido amplo.

período de tempo que se está analisando, logo, não será possível sua generalização para outros períodos. E considerando o propósito da previsão, essa série temporal (não estacionária) poderá ter pouco valor prático.

Para Ehlers (2005, p. 39-40) no alisamento exponencial simples, em uma série temporal sem sazonalidade e sem tendência sistemática, do tipo x_1, \dots, x_n , é simples tomar a estimativa x_{n+1} como uma soma ponderada de observações passadas conforme representado abaixo:

$$\hat{x}_n(1) = a_0x_n + a_1x_{n-1} + \dots$$

Em que $\{a_j\}$ são os pesos. Parece simples dar às observações mais recentes maior peso em relação às observações mais distantes do passado: $a_0 > a_1 > \dots$ Neste tipo de procedimento adotam-se pesos que diminuem a uma taxa geométrica dados por $a_j = \alpha(1 - \alpha)^j, j = 0, 1, \dots$ e é denominado *constante de alisamento* quando $0 < \alpha < 1$. Ou seja, para previsão 1 passo a frente em $t = n$ é igual a

$$\hat{x}_n(1) = \alpha x_n + \alpha(1 - \alpha)x_{n-1} + \alpha(1 - \alpha)^2x_{n-2} + \dots$$

Note que o parâmetro α controla o grau de “envelhecimento” das observações.

Agora, para se fazer previsões dentro da amostra, para Ehlers (2005, p. 40), usando como previsão inicial $\hat{x}_0(1) = x_1$ e $t = 0$ e os erros de previsão 1 passo a frente sendo definidos como $e_t = x_t - \hat{x}_{t-1}(1)$ a equação pode ser definida como

$$\hat{x}_t(1) = \alpha x_t + (1 - \alpha)\hat{x}_t(1), t = 1, 2, \dots$$

E na forma de correção de erro:

$$\hat{x}_t = \hat{x}_{t-1}(1) + \alpha e_t, t = 1, 2, \dots$$

Ehlers (2005, p. 40) aponta que o valor de α é dada pela propriedade da série temporal e não da escala das observações medidas. Esse valor de α reflete a influência das observações passadas nas previsões. Porém, valores pequenos produzem melhor previsões de muitas observações passadas e já valores próximos de 1 dependem de observações mais recentes e, em caso extremo, $\alpha = 1$.

Segundo Rossi (2014), o processo de modelagem Box-Jenkins foi difundido com a publicação do livro *Time Series Analysis, Forecasting and Control*, em 1970, por Box e Jenkins e essa modelagem tem como base a estrutura do processo estocástico gerador das observações. Suas aplicações são diversas tais como em transportes, estudo de fenômenos econômicos e industriais etc. que firmaram essa forma de modelagem por dados de séries históricas.

Por exemplo, ao se observar uma série temporal, que em nosso caso, previsão de arrecadação de ICMS no Estado de Mato Grosso, podemos verificar se ela segue um processo AR puro (e, se isso acontece, qual o valor de p), ou um processo MA puro (e, se isso acontece, qual o valor de q), um processo ARMA (e, se isso acontece, quais os valores de p e q) ou um processo ARIMA, no caso dos valores p , d e q precisarem ser conhecidos? A metodologia Box Jenkins é bastante útil para se responder esse tipo de questão. O método consiste em quatro etapas, que serão detalhadas posteriormente, são elas: Etapa 1 (Identificação), Etapa 2 (Estimação), Etapa 3 (Verificação do Diagnóstico), Etapa 4 (Previsão) (GUJARATI, 2011, adaptado).

4.4 ENTENDENDO A ESTACIONARIEDADE

Gujarati (2011, p. 731) faz algumas advertências sobre a utilização das séries temporais, principalmente porque apresentam desafios aos econométricos e aos praticantes de econometria. O autor menciona que o trabalho empírico baseado nos dados de séries temporais supõe que a série temporal subjacente seja estacionária. Por vezes, ocorre a autocorrelação quando a série temporal subjacente não é estacionária. Quando se faz uma regressão para uma variável de série temporal em relação a outras variáveis de série temporal, geralmente obtém-se um R^2 muito elevado, embora não haja relação significativa entre as duas variáveis. Outras vezes, não são esperadas relação entre as duas variáveis, ainda que a regressão aponte uma relação significativa. É nesses casos que acontece o problema da regressão espúria ou regressão sem sentido. O autor reafirma a importância de descobrir se a relação entre as variáveis econômicas é espúria ou sem sentido. Ressalta-se que séries temporais financeiras podem exibir o 'fenômeno do passeio aleatório' como, por exemplo, preço de ações; ou seja, as vezes o preço de uma ação amanhã pode ser igual ao preço de hoje mais um choque totalmente aleatório o que, em caso de previsão de preços dos ativos seria um exercício inútil. Quando ocorrem séries temporais em modelos de regressão, usualmente são utilizadas para previsões e temos que saber se a previsão é válida em casos de as séries temporais fundamentadas não sejam estacionárias.

Nesse diapasão, Gujarati (2011, p. 231) aponta que os modelos de regressão que envolvam dados de séries temporais são geralmente utilizados para previsões, logo, devemos saber se a previsão é válida ou não caso as séries temporais escolhidas não sejam estacionárias. Os testes de causalidade têm por premissa que as séries temporais na análise sejam estacionárias, todavia, os testes de estacionariedade deveriam preceder os testes de causalidade.

4.5 MODELOS OU PROCESSOS ESTACIONÁRIOS

Segundo Morettin (2006, p. 31) um processo é estacionário se ele oscila ao redor de uma média constante, com variância também constante. Essa é uma das suposições básicas que são feitas em análises de séries temporais, ou seja, o processo estocástico que geram dados são, também, um processo estacionário. O autor distingue duas formas de estacionariedade: forte e fraca.

Para Fava (2000, p. 205), a metodologia Box Jenkins (1976) tem como foco a realização de previsão de valores de séries baseados nos seus valores presentes e passados. Para isso, faz-se uma exploração de correlação temporal que existe (geralmente) entre os valores exibidos na série. Nessa metodologia a relação temporal tem representação formal por um conjunto de processos estocásticos denominados modelos ARIMA, especificamente, modelos univariados por envolverem apenas uma série de tempo. Nesse tipo de modelo, há uma combinação de três filtros, quais sejam, o componente Autorregressivo (AR), filtro de Integração (I) e o componente de Médias Móveis (MA). A abreviatura MA tem vem do inglês *Moving Average*. Basicamente uma série de tempo pode conter os três filtros ou alguns deles, o que resulta em diversos modelos passíveis de análise pelo enfoque de Box-Jenkins.

Em seu trabalho, Fava (2000, p. 206) apresenta alguns modelos que podem ser utilizados dentro da metodologia de Box-Jenkins. Para os modelos estacionários, há o Modelo autorregressivo (AR), Modelo de Médias Móveis (MA), Modelo autorregressivo de médias móveis (ARMA). Já para os modelos não-estacionários, há os modelos autorregressivos integrados de médias móveis (ARIMA).

4.6 MODELO AUTORREGRESSIVO (AR)

Para Fava (2000, p. 206), dentro da metodologia de Box-Jenkins, para modelos estacionários, o Modelo autorregressivo (AR), y_t é descrito por seus valores passados e pelo *ruído branco* ε_t . Diz-se modelo regressivo de ordem 1 aquela em que y_t depende somente de y_{t-1} e de ε_t e sua representação algébrica é dada por (considere que y_t seja a série original menos sua média, logo, a média de y_t é igual a zero):

$$y_t = \phi y_{t-1} + \varepsilon_t$$

Em que ϕ é um parâmetro de $E(\varepsilon_t) = 0$; $E(\varepsilon_t^2) = \sigma^2$; $E(\varepsilon_t \varepsilon_s) = 0$ para $t \neq s$. Sabendo que trata-se de um modelo fracamente estacionário, a variância de y_t (γ_0) deve ser constante e as autocovariâncias (γ_k) devem ser independentes de t (FAVA, 2000, p.206).

Segundo Gujarati (2011, p. 735) o ‘ruído branco’ (ou processo puramente aleatório) é um tipo especial de processo estocástico, ou série temporal; é processo estocástico quando tem média zero, variância constante σ^2 e é serialmente não-correlacionado. Se o processo é também independente, é chamado de ‘estritamente de ruído branco’.

Para Rossi (2014), quanto à variância do AR(1), não é fácil identificar um processo estocástico pelo gráfico de uma série histórica. Logo, nesses casos, requer-se a análise de suas propriedades estatísticas através de duas funções como ferramentas básicas de análise: função de autocorrelação (*fac*) e autocorrelação parcial (*pac*).

4.7 VARIÂNCIA DO AR(1)

Para Fava (2000, p. 206) para que ocorra a *condição de estacionariedade*, é necessário que $|\Phi| < 1$, ou seja, esta restrição imposta sobre o parâmetro Φ_1 impõe que a variância de y_t seja não negativa e finita:

$$\gamma_0 = E[y_t^2] = E[\phi y_{t-1} + \varepsilon_t]^2 = \phi^2 V(y_{t-1}) + V(\varepsilon_t)$$

$$\gamma_0 = \phi^2 \Upsilon_0 + \sigma_\varepsilon^2$$

$$\gamma_0 = \frac{\sigma_\varepsilon^2}{1 - \phi^2}$$

Processo autorregressivo de primeira ordem – *Autocovariâncias do AR(1)*

Fava (2000, p.206) apresenta as autocovariâncias do AR(1), que podem ser:

De 1ª ordem:

$$\Upsilon_1 = E[y_t y_{t-1}] = E[(\phi y_{t-1} + \varepsilon_t) y_{t-1}]$$

$$\Upsilon_1 = \phi E[y_{t-1}^2] + E[y_{t-1} \varepsilon_t]$$

$$\Upsilon_1 = \phi \gamma_0$$

De 2ª ordem

$$\Upsilon_2 = E[y_t y_{t-2}] = E[(\phi y_{t-1} + \varepsilon_t) y_{t-2}]$$

$$\Upsilon_2 = E[(\phi(\phi y_{t-2} + \varepsilon_{t-1}) + \varepsilon_t) y_{t-2}]$$

$$\Upsilon_2 = \phi^2 E[y_{t-2}^2] + \phi E[y_{t-2} \varepsilon_{t-1}] + E[y_{t-2} \varepsilon_t]$$

$$\Upsilon_2 = \phi^2 \gamma_0$$

Ou autocovariância de ordem k

$$\gamma_k = E[y_t y_{t-k}]$$

$$\gamma_k = \phi^k \gamma_0$$

A autora aponta que as autocovariâncias não dependem de t e sim de k . Como $|\phi| < 1$, pela condição de estacionariedade, quanto maior for a distância entre as observações (k), menor a autocovariâncias (FAVA, 2000, p. 206).

Segundo Rossi (2014), ao se analisar as equações a seguir, para definição de processo autorregressivo de primeira ordem AR(1) dada pela equação (1):

$$X_t - b_1 X_{t-1} = K + Z_t$$

$$X_{t-1} - b_1 X_{t-2} = K + Z_{t-1}$$

$$X_t - b_1^2 X_{t-2} = K + K b_1 + Z_t + b_1 Z_{t-1}$$

$$X_t = K + K b_1 + K b_1^2 + \dots + Z_t + b_1 Z_{t-1} + b_1^2 Z_{t-2} + \dots$$

$$X_t = K + K b_1 + K b_1^2 + K b_1^3 + \dots$$

Note que Z_t , na equação (1), é um ruído branco. Para se calcular a média do processo, é necessário a eliminação do termo $t - 1$ da equação (1), de modo que $t = t - 1$. Dessa forma, obtém-se a equação (2). Multiplicando a equação (2) por b_1 , e somar com a equação à primeira equação, encontra-se a equação (3). Perceba que na equação (3) o termo X_{t-1} foi eliminado. Ao se repetir o processo de eliminação o

termo em $t - 2$ e assim sucessivamente, chega-se à equação (4). Ao aplicar à equação (4) o operador $E(\cdot)$ de valor esperado, obtém-se a equação (5). Logo, para Rossi (2014), para que o processo estacionário acima seja na média, é preciso que a soma convirja para um valor finito, que ocorrerá quando $|b_1| < 1$, o que se torna uma condição de estacionariedade de um processo regressivo de ordem 1. O valor esperado pode ser escrito utilizando a expressão de uma soma de uma progressão geométrica $\mu_{X_t} = E(X_t) = \frac{K}{1-b_1}$, que é independente de t . Ao violar a condição, fazendo $|b_1| = 1$ e $K \neq 0$ obtém-se, perde-se a estacionariedade no processo AR(1), conforme abaixo:

$$\mu_{X_t} = E(X_t) = E(X_{t-1}) + K$$

$$\mu_{X_t} = \mu_{X_{t-1}} + K$$

4.8 MODELO AUTORREGRESSIVO GENÉRICO

Para Fava (2000, p.207) um modelo autorregressivo, cuja representação genérica se dá por AR(p) toma como pressuposto o resultado da soma ponderada de seus valores passados p , além do ruído y_t branco ε_t :

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

Na utilização do operador de defasagem B , o modelo pode ser reapresentado da seguinte forma:

$$y_t = \phi_1 B y_t + \phi_2 B^2 y_t + \dots + \phi_p B^p y_t + \varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) y_t = \varepsilon_t$$

$$\phi(B) y_t = \varepsilon_t$$

E a representação da variância e das autocovariâncias são dadas por:

$$\gamma_0 = \phi_1 \gamma_1 + \phi_2 \gamma_2 + \dots + \phi_p \gamma_p + \sigma_\varepsilon^2$$

4.9 MODELO DE MÉDIAS MÓVEIS (MA)

Nesse modelo, Fava (2000, p.207) aponta que a série y_t é resultado de uma combinação linear dos ruídos brancos, ou choques aleatórios, ocorridos no período corrente bem como nos períodos passados. Nesse caso, o modelo de médias móveis de primeira ordem MA(1) se verifica conforme demonstração a seguir:

$$y_t = \varepsilon_t - \theta\varepsilon_{t-1}$$

Na demonstração acima, notar que θ é um parâmetro (FAVA, 2000, p.207). E como a média de y_t é zero e que ε_t é um ruído branco, a obtenção de sua variância dar-se-á:

$$\gamma_0 = E[y_t^2] = E[(\varepsilon_t - \theta\varepsilon_{t-1})^2] = E[\varepsilon_t^2 + \varepsilon_t^2] + \theta^2 E[\varepsilon_{t-1}^2] - 2\theta E[\varepsilon_t \varepsilon_{t-1}]$$

$$\gamma_0 = \sigma_\varepsilon^2 + \theta^2 \sigma_\varepsilon^2$$

$$\gamma_0 = (1 + \theta^2)\sigma_\varepsilon^2$$

Definição das formas das autocovariâncias. Lembrando que são nulas as autocovariâncias de ordem maior ou igual 2 (FAVA, 2000, P. 207):

$$\gamma_1 = E[y_t y_{t-1}] = E[(\varepsilon_t - \theta\varepsilon_{t-1})(\varepsilon_{t-1} - \theta\varepsilon_{t-2})]$$

$$\gamma_1 = -\theta\sigma_\varepsilon^2$$

$$\gamma_2 = E[y_t y_{t-2}] = E[(\varepsilon_t - \theta\varepsilon_{t-1})(\varepsilon_{t-2} - \theta\varepsilon_{t-3})]$$

$$\gamma_2 = 0$$

Em que $\gamma_k = 0, k \geq 2$. A autora destaca que não é necessária a imposição de nenhuma restrição sobre o parâmetro θ nas expressões da variância e das autocovariâncias para obter a estacionariedade e fraca, diferentemente do que ocorre no parâmetro ϕ do modelo AR(1) (FAVA, 2000, p. 208).

Para transformar o MA(1) em um modelo autorregressivo (transformação ou “inversão”), substitui-se ε_{t-1} na equação $y_t = \varepsilon_t - \theta\varepsilon_{t-1}$ por $y_{t-1} + \theta\varepsilon_{t-2}$ e fazer substituições sucessivas dos ε defasados que aparecem em cada etapa do processo, em que y é estacionária e sua representação no formato autorregressivo requer que $|\theta| < 1$, caso contrário, o resultado tenderá a ser explosivo. A essa restrição que se impõe, dá-se o nome de *condição de invertibilidade*:

$$y_t = \varepsilon_t - \theta y_{t-1} - \theta^2 y_{t-2} - \theta^3 y_{t-3} - \dots$$

4.10 MODELO AUTORREGRESSIVO E DE MÉDIAS MÓVEIS (ARMA)

Segundo FAVA (2000, p. 209) o Modelo autorregressivo de médias Móveis (ARMA) combina os dois modelos anteriores, o modelo autorregressivo (AR) e o modelo de médias móveis (MA), onde y_t é descrito por seus valores passados e pelos choques aleatórios correntes e passados. Note que, na equação a seguir, o modelo ARMA (1,1) é a especificação mais simples de processo dessa natureza:

$$y_t = \theta y_{t-1} + \varepsilon_t - \theta \varepsilon_{t-1}$$

Características apontadas por Fava (2000, p. 209), considerando a média $E(y_t) = 0$, supondo que a série está centrada, e considerando as variância e covariâncias conforme abaixo:

$$\text{Variância: } \gamma_0 = \frac{(1+\theta^2-2\phi)\sigma_\varepsilon^2}{1-\phi^2}$$

$$\text{Autocovariâncias: } \gamma_1 = \phi\gamma_0 - \theta\sigma_\varepsilon^2 = \frac{(1-\phi\theta)(\phi-\theta)}{1-\phi^2}\sigma_\varepsilon^2 \text{ onde } \gamma_k = \phi\gamma_{k-1} \text{ para } k \geq 2.$$

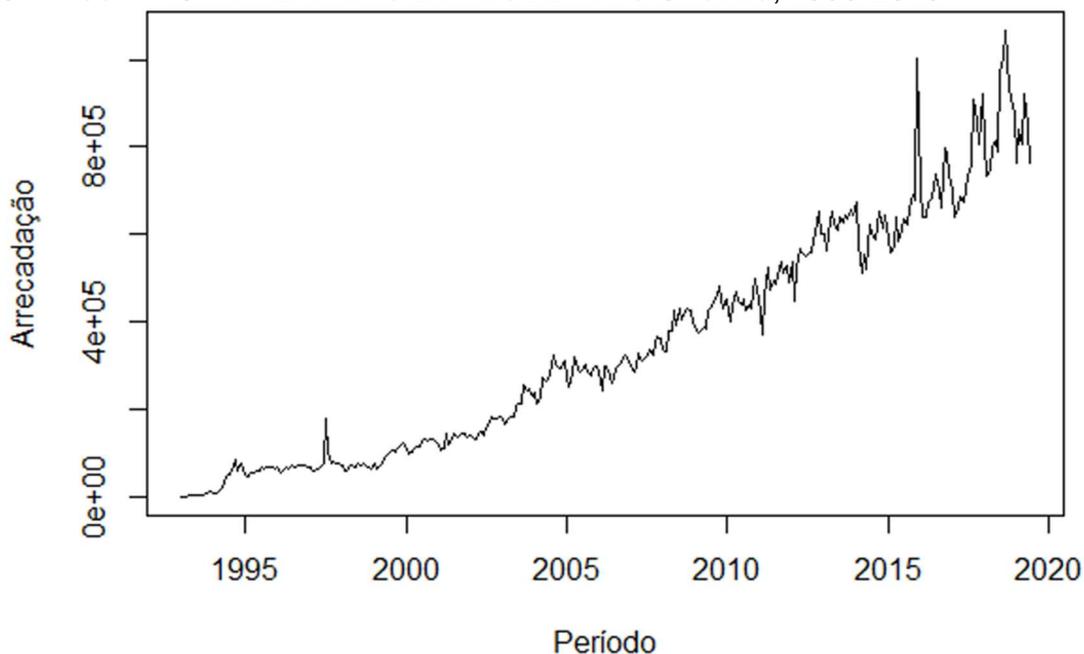
Segundo a autora, a variância ARMA (1,1), para se tornar finita e não-negativa, $|\phi| < 1$, aplica-se a esse modelo a condição de estacionariedade. O modelo ARMA (1,1) tem sua condição de invertibilidade, do mesmo modo que a condição observada para o modelo MA(1) $|\theta| < 1$, de modo que possa ser expresso como um AR(∞) (FAVA, 2000, P. 210).

4.11 DADOS E AMOSTRA

Podemos verificar, pela figura a seguir, a representação de arrecadação de ICMS mensal de Mato Grosso no período de janeiro de 1993 a junho de 2019, que a série apresenta tendência crescente e não há picos de sazonalidade tão evidentes.

Segundo Chain (2015), a sazonalidade é comum quando se tem dados que indicam atividade econômica, como, por exemplo, o PIB, consumo de energia, nível de empregos etc. Requer aplicação de testes estatísticos para verificação de presença de sazonalidade na série.

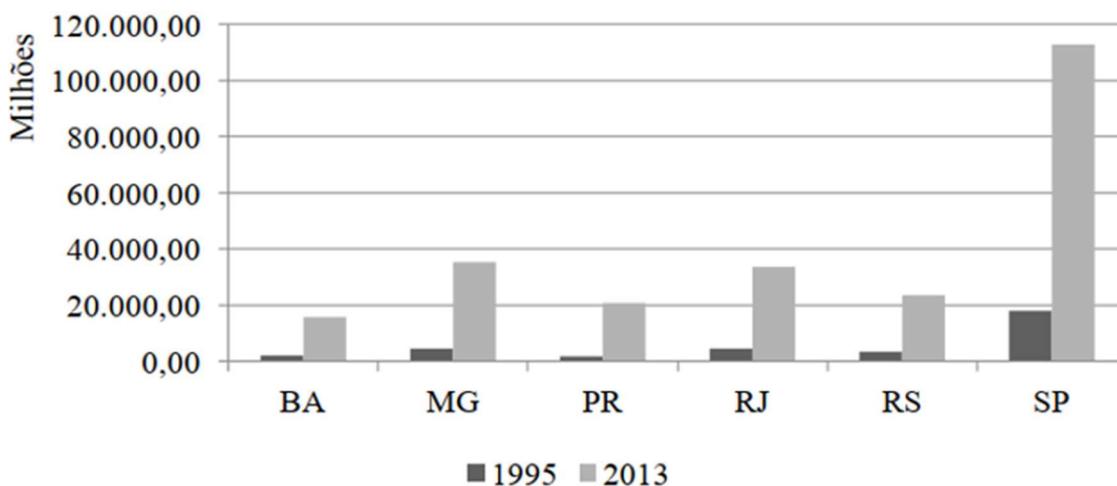
GRÁFICO 1 - ICMS MENSAL NO ESTADO DE MATO GROSSO, 1993-2019



FONTE: SECRETARIA DE FAZENDA DO ESTADO DE MATO GROSSO (SEFAZ-MT, 2020)

Para destacar a importância desse tributo, no caso, Imposto – ICMS, veja no gráfico a seguir, retirado do trabalho de Azevedo (2017, p.12) onde foi apresentado uma significativa e crescente taxa de arrecadação o tributo quando comparado em períodos distintos, no caso no ano de 1995 e em 2013:

GRÁFICO 2 - ARRECAÇÃO DE ICMS DOS ESTADOS EM 1995 E 2013



FONTE: AZEVEDO (2017, P.12)

Em Mato Grosso, a arrecadação saltou de R\$ 706.470 mil, em 1995 para R\$ 7,4 milhões em 2013, para fins de comparação com o mesmo período do trabalho de Azevedo (2015) e, em valores atualizados para 2018, a arrecadação chegou ao valor de R\$ 12,1 milhões.

4.12 ETAPAS DA METODOLOGIA DE BOX-JENKINS

Para Fava (2000, p. 211), na etapa da identificação, o primeiro passo é descobrir qual entre as várias versões do modelo ARIMA descreve o comportamento da série. Ou seja, dada uma série y_t , como saber se ela foi gerada por um processo AR, MA, ARMA ou ARIMA³? O processo de identificação baseia-se em determinar quais dos filtros AR, I e MA compõe o processo gerador da série, bem como são suas respectivas ordens. O processo de identificação não é de grande valia com o auxílio de um gráfico, que, no máximo, poderá indicar se é estacionária ou não. O processo de identificação necessita de outros instrumentos, são eles: a função de autocorrelação e a função de autocorrelação parcial.

Para Gujarati (2011, p. 771), no estágio da identificação, os valores adequados de p , d e q são identificados com o auxílio do correlograma (função de correlação amostral – ACF) e do correlograma parcial (função de correlação amostral parcial – PACF). O conceito da ACF (ρ_k) (populacional) e da ACF (\hat{p}_k) (amostral) é análogo ao conceito de coeficiente de regressão parcial. Se em um modelo de regressão múltipla com k variáveis, o k -ésimo regressor, β_k , mede a taxa de variação no valor médio do regressando para uma alteração unitária no k -ésimo regressor, X_k , mantendo influência de todos os regressores que são constantes.

Da mesma forma, segundo Gujarati (2011, p. 772) as séries temporais são medidas pela correlação entre as observações na correlação amostral parcial p_{kk} , após a verificação das correlações nas defasagens intermediárias (defasagens menores do que k). O autor aponta que deverão ser aplicados os testes de

³ Ainda: se for um modelo AR, qual seria o valor de p ? qual a ordem do modelo? Se for um ARIMA, qual o valor de p , de d e de q ?

diagnósticos para descobrir se o modelo ARMA selecionado é preciso ou não (GUJARATI, 2011).

Para Fava (2000, p. 213) na função de autocorrelação (FAC), o coeficiente de autocorrelação serial de ordem k (onde a sequência de pares $(k, \rho_k), k = 1, 2, \dots$) é dado por:

$$\rho_k = \frac{Cov(y_t, y_{t-k})}{V(y_t)} = \frac{\gamma_k}{\gamma_0}$$

Para a autora, o coeficiente de autocorrelação ρ_k envolve parâmetros geralmente desconhecidos e necessita-se trabalhar com o coeficiente de autocorrelação amostral r_k dados por:

$$r_k = \frac{\sum_{t=k+1}^n (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2}$$

Para se analisar estatisticamente a FAC amostral, é necessário conhecer a distribuição de r_k . Se $\rho_k = 0$ para $k \neq 0$, a variância de r_k é aproximadamente igual a $1/n$. Caso n seja grande, a distribuição de r_k é aproximadamente Normal: $r_k \rightarrow N\left(0; \frac{1}{n}\right)$.

Na etapa da estimação, segundo Gujarati (2011, p. 771), após os valores apropriados de p e q serem identificados, devemos estimar os parâmetros autorregressivos e dos termos de média móvel incluídos no modelo. Já para Fava (2000, p. 211), após a identificação dos parâmetros do modelo identificado, começa a estimação: os parâmetros ϕ se houver um componente autorregressivo, os parâmetros θ se houver o filtro de médias móveis e a variância do ruído branco σ_ε^2 .

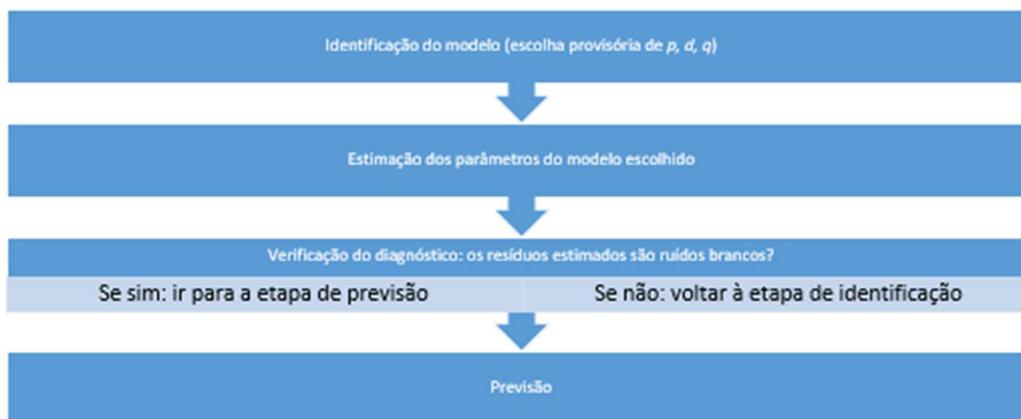
4.13 MODELO BOX E JENKINS

O modelo de Box e Jenkins é um modelo que traduz o mecanismo de geração de uma série que se está observando (FAVA, 2000, p. 202).

Na etapa de diagnóstico, para Gujarati (2011, p. 771), é onde que a metodologia é mais arte que ciência. Ou seja, após a escolha do modelo ARIMA específico, e após ter estimado os parâmetros, deve-se verificar se o modelo selecionado se ajusta aos dados razoavelmente bem para que seja possível outro

modelo ARIMA também possa fazer o trabalho. É uma etapa que requer uma certa habilidade para escolher o modelo ARIMA correto. Um simples teste após o modelo selecionado é o de verificar se os resíduos estimados, com base nesse modelo, são ruídos brancos; se forem, o ajuste específico é aceito. Caso contrário, deve-se recomeçar. A metodologia de Box Jenkins é basicamente um processo iterativo, conforme **Erro! Fonte de referência não encontrada.** abaixo:

FIGURA 2 - O MÉTODO DE BOX-JENKINS



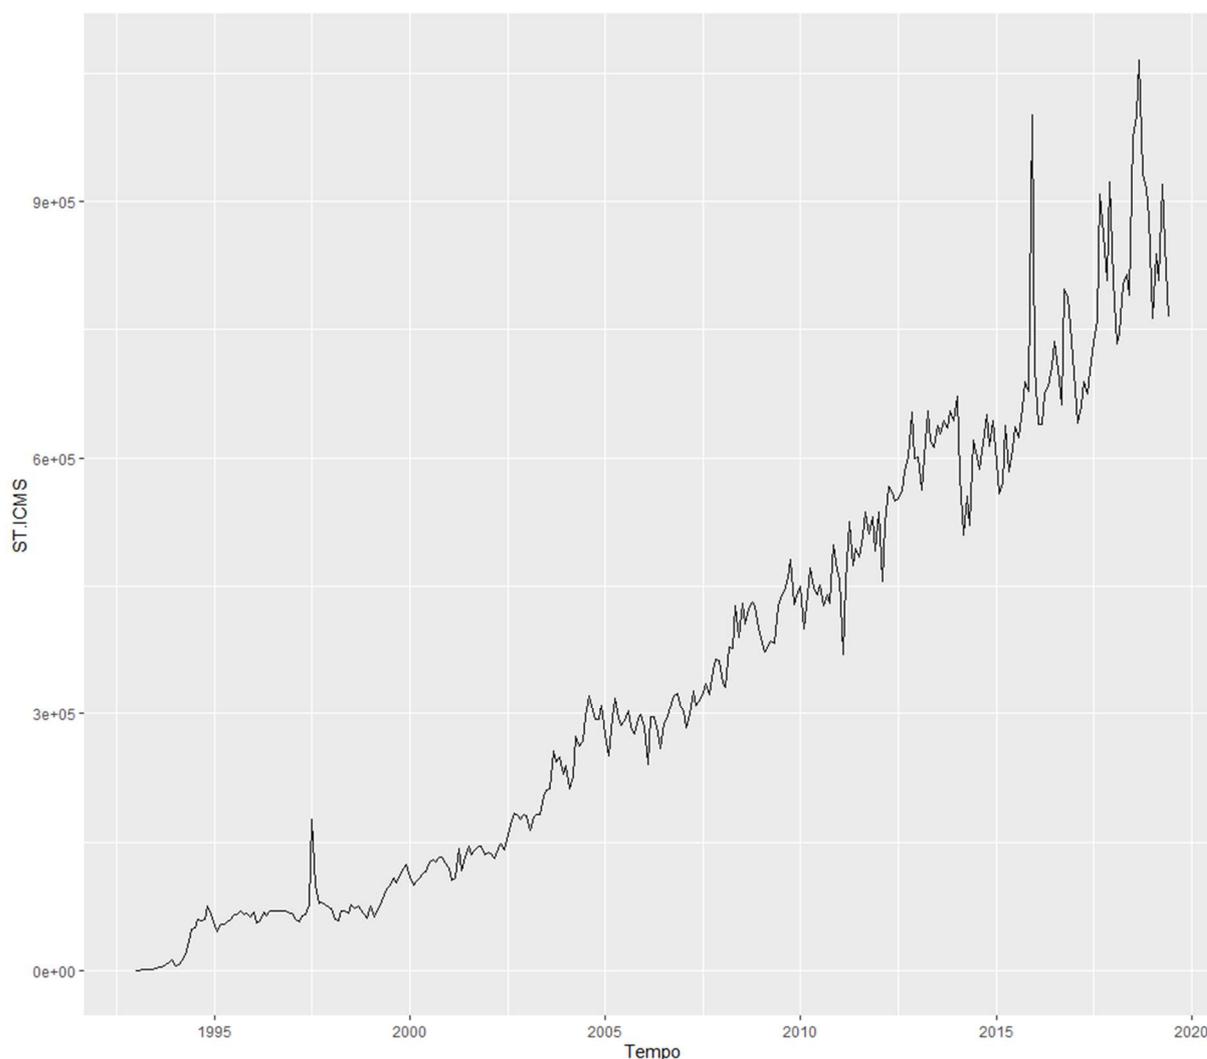
FONTE: GUJARATI (2011, P. 772)

Para Gujarati (2011, p. 771), na etapa de previsão, o sucesso do modelo ARIMA e, conseqüente sua popularidade, se dá ao fato de que por esse método, as previsões obtidas são mais confiáveis do que as previsões obtidas pelos modelos econométricos tradicionais, especialmente nas previsões de curto prazo. Obviamente que cada caso deverá ser analisado.

5 RESULTADOS E ANÁLISES

Primeiramente, vamos explorar os dados para verificar o comportamento da série histórica do período de janeiro de 1993 a junho de 2019, conforme se verifica no Gráfico 3. Importante essa verificação, basicamente análise exploratória dos dados, pois é a partir dessa análise que podemos partir para escolha de metodologias mais robustas e modelos mais adequados para previsão da série.

GRÁFICO 3 - EVOLUÇÃO DAS RECEITAS NO PERÍODO DE 1993 A 2019



FONTE: ELABORAÇÃO PRÓPRIA (2021)

Podemos inferir, pelo Gráfico 3, que os dados apresentam tendência com muita clareza, mas não podemos afirmar, ao menos visualmente, presença de sazonalidade.

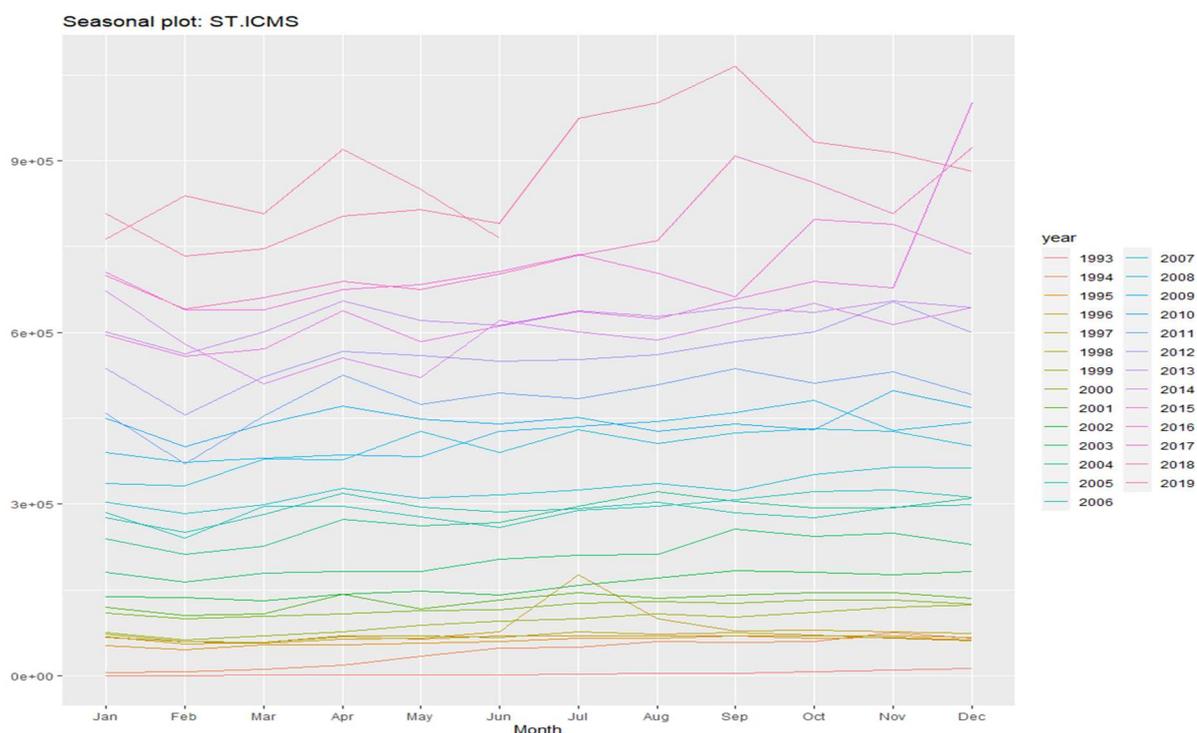
Mais testes terão que ser realizados para afirmar a presença ou não desse elemento sazonal.

Em relação ao elemento tendência, é bem evidente na série histórica, com uma elevação mais acentuada a partir de 2005. Apresenta um comportamento crescente ao longo do período.

O gráfico temporal ilustrado acima corrobora com a visão de Ehlers (2005) quando diz que as representações gráficas podem revelar padrões de comportamento tais como tendências, padrões cíclicos etc.

Para reforçar a presença ou não de sazonalidade, podemos verificar no Gráfico 2 a série histórica anual onde não notamos nenhum padrão evidente de sazonalidade, nem picos ou acentuações elevadas e permanentes em determinados períodos. Podemos ver, por exemplo, alguns picos isolados que não nos permite auferir com garantia a presença desse elemento.

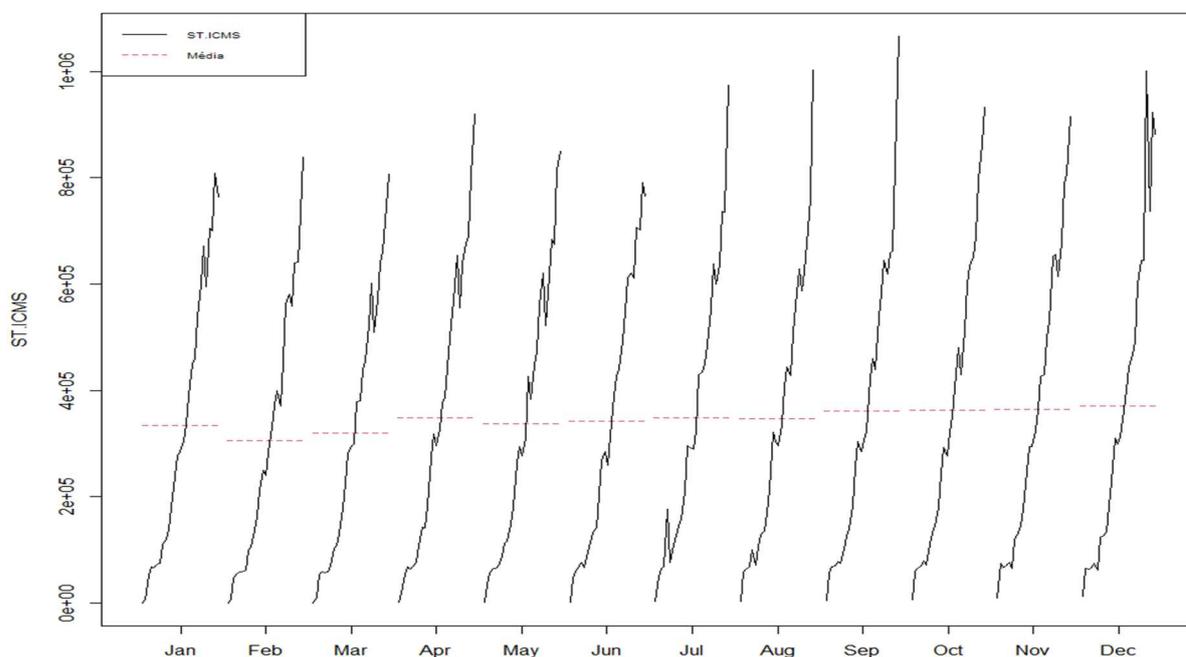
GRÁFICO 4 - SÉRIE HISTÓRICA ANUAL NO PERÍODO DE 1993 A 2018



FONTE: ELABORAÇÃO PRÓPRIA (2021)

Uma outra forma de visualização da média da arrecadação de receita, mensalmente, seria pelo Gráfico 5, em que apresenta a série histórica mensal, evidenciando a média, mês a mês e, mais uma vez, não há evidência robusta de presença de sazonalidade; os dados permanecem com média constante.

GRÁFICO 5 - SÉRIE HISTÓRICA MENSAL



FONTE: ELABORAÇÃO PRÓPRIA (2021)

Após a verificação gráfica do comportamento da série temporal, no caso da arrecadação de ICMS no Estado de Mato Grosso no período de 1993 a 2019 (Junho), o passo seguinte é fazer o ajuste sazonal no modo automático, com o X13, que possui uma função específica com argumentos para desempenhar esse papel e os principais argumentos dessa função podem ser verificados na tabela abaixo (FERREIRA, GONDIN JR., MATTOS, 2015):

TABELA 2 - ARGUMENTOS DA FUNÇÃO SEAS() PARA AJUSTE AUTOMÁTICO

Argumento	Descrição
x	Série temporal de interesse
<u>arima.model</u>	Especifica o modelo SARIMA para a série de interesse
outlier	Define se o programa deve ou não detectar automaticamente variáveis de regressão
<u>regression.variables</u>	Permite especificar outliers e variáveis de calendário como Páscoa, <i>trading days</i> , ano bissexto dentre outras variáveis
<u>regression.aictest</u>	Define se o programa X13 deve ou não detectar, de forma automática, variáveis de regressão.
<u>transform.function</u>	Especifica o tipo de transformação que pode ser realizada na série de interesse, que pode ser: <i>log</i> (transformação logarítmica), <i>none</i> (nenhuma) ou <i>auto</i> (o próprio programa define se aplica-se ou não a transformação <i>log</i>).

FONTE: FERREIRA, GONDIN JR., MATTOS (2015, P.10)

No automático, o programa faz as seguintes avaliações: 1. Verifica os testes de sazonalidade QS; a hipótese nula do teste é de não haver sazonalidade; se o P-VALUE for igual a zero, então há indícios de sazonalidade; 2. Diagnóstico do pré-ajuste e Modelo ARIMA; 3. Faz a verificação se há indícios de sazonalidade ou efeitos de dias úteis graficamente; 4. Verifica a estabilidade do ajuste sazonal.

Para dessazonalizar a série temporal, o X13-ARIMA-SEATS faz o ajuste sazonal automático conforme se verifica na Figura 5. Podemos observar que o modelo ajustado não aponta, de imediato, algum efeito calendário (efeito Páscoa, por exemplo), porém, detectou *outliers level shift*, identificado com as iniciais LS na saída, nos meses: 1993: Abril, Junho, Agosto, Outubro; 1994: Fevereiro, Abril, Maio, Junho.

FIGURA 3 - AJUSTE SAZONAL AUTOMÁTICO

Call:
seas(x = ST.ICMS)

Coefficients:

AO1993. Jan	LS1993. Apr	LS1993. Jun	LS1993. Aug	LS1993. Oct
-0.3732	0.5116	0.4822	0.5182	0.3857
AO1993. Nov	AO1993. Dec	LS1994. Feb	LS1994. Apr	LS1994. May
0.3566	0.7303	0.4816	0.5627	0.5900
LS1994. Jun	AO1997. Jul	AO2015. Dec	MA-Nonseasonal-01	MA-Seasonal-12
0.3136	0.7715	0.3634	0.5052	0.8271

FONTE: ELABORAÇÃO PRÓPRIA (2021)

Outros *outliers* não esperados também foram detectados, como nos meses: Jan./1993, Nov./1993, Dez./1993, Jul./1997, Dez./2015. Esses *outliers* são do tipo aditivo.

Em relação aos outliers detectados, sejam do tipo LS (Level Shift) ou AO (*Additive Outlier*), é importante entender o significado de cada um. O outlier do tipo LS, segundo Figueiredo (2020), diz respeito à mudança de nível, ou seja, é um outlier decorrente de mudança no patamar conforme se verifica na Figura 6 a seguir que trata, por exemplo, da mudança abrupta da inflação em que explodiu com aumento em 100%aa:

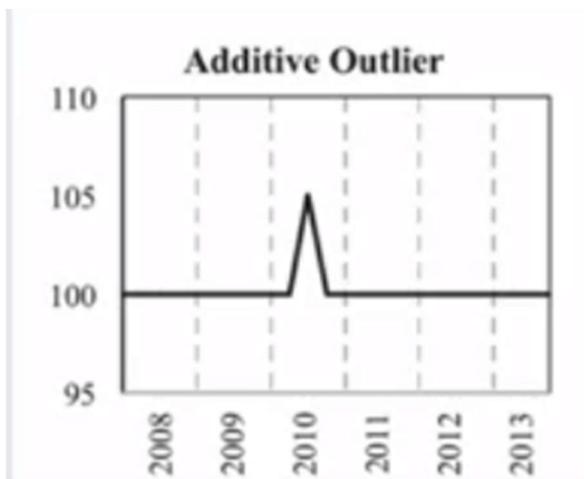
FIGURA 4 - OUTLIER DO TIPO LS



FONTE: FERREIRA, GONDIN JR., MATTOS (2015, P.11)

Por outro lado, o outlier do tipo AO (*Additive Outlier*) são outliers pontuais conforme se verifica na Figura 7 a seguir e que Figueiredo (2020) exemplifica, como exemplos desse tipo de outliers, o exemplo da poupança bloqueada no governo Collor:

FIGURA 5 - OUTLIER DO TIPO AO



FONTE: FERREIRA, GONDIN JR., MATTOS (2015, P.10)

Resultado da estimação ARIMA e os outliers que foram detectados, bem como a significância dos parâmetros:

FIGURA 6 - AVALIAÇÃO DO AJUSTE SAZONAL E SIGNIFICÂNCIA DOS PARÂMETROS

```

call:
seas(x = ST.ICMS)

Coefficients:
      Estimate std. Error z value Pr(>|z|)
AO1993. Jan   -0.37319   0.07631  -4.890 1.01e-06 ***
LS1993. Apr    0.51159   0.06868   7.449 9.42e-14 ***
LS1993. Jun    0.48225   0.06867   7.022 2.18e-12 ***
LS1993. Aug    0.51823   0.06777   7.647 2.06e-14 ***
LS1993. Oct    0.38567   0.06991   5.516 3.46e-08 ***
AO1993. Nov    0.35662   0.07096   5.026 5.01e-07 ***
AO1993. Dec    0.73035   0.07096  10.293 < 2e-16 ***
LS1994. Feb    0.48155   0.06991   6.888 5.67e-12 ***
LS1994. Apr    0.56274   0.07514   7.490 6.91e-14 ***
LS1994. May    0.58997   0.08110   7.274 3.49e-13 ***
LS1994. Jun    0.31364   0.07327   4.280 1.86e-05 ***
AO1997. Jul    0.77151   0.06164  12.517 < 2e-16 ***
AO2015. Dec    0.36337   0.06178   5.882 4.06e-09 ***
MA-Nonseasonal-01 0.50515   0.04861  10.392 < 2e-16 ***
MA-Seasonal-12  0.82711   0.03139  26.346 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

SEATS adj. ARIMA: (0 1 1)(0 1 1) Obs.: 318 Transform: log
AICC: 6910, BIC: 6967 QS (no seasonality in final):1.701
Box-Ljung (no autocorr.): 21.09 shapiro (normality): 0.9816 ***
Messages generated by x-13:
Notes:
- Unable to test AO1994.Apr due to regression matrix singularity.
- Unable to test AO1994.May due to regression matrix singularity.

```

FONTE: ELABORAÇÃO PRÓPRIA (2021)

Analisando a saída, em que evidencia o ajuste e o Modelo Arima utilizado, podemos notar que foi feita uma transformação logarítmica nos dados (tipo *log*). As variáveis de regressão, que são da etapa de pré-ajuste, foram todas significativas, ainda que com os *outliers* detectados.

FIGURA 7 - OUTPUT DO MODELO DE AJUSTE AUTOMÁTICO

Summary

AO1993.Jan	-0.37	0.1%	Adjustment	SEATS	QS	1.701
LS1993.Apr	0.51	0.1%	ARIMA	(0 1 1)(0 1 1)	H0: no seasonality in final series	
LS1993.Jun	0.48	0.1%	Obs.	318	Box-Ljung	21.09
LS1993.Aug	0.52	0.1%	Transform	log	H0: no residual autocorrelation	
LS1993.Oct	0.39	0.1%	AICc	6909.5	Shapiro	0.9816
AO1993.Nov	0.36	0.1%	BIC	6967.2	H0: normal distr. of residuals	
AO1993.Dec	0.73	0.1%				
LS1994.Feb	0.48	0.1%				
LS1994.Apr	0.56	0.1%				
LS1994.May	0.59	0.1%				
LS1994.Jun	0.31	0.1%				
AO1997.Jul	0.77	0.1%				
AO2015.Dec	0.36	0.1%				
MA-Nonseasonal-01	0.51	0.1%				
MA-Seasonal-12	0.83	0.1%				

FONTE: ELABORAÇÃO PRÓPRIA (2021)

Foi ajustado um modelo ARIMA(0 1 1)(0 1 1) e o parâmetro MA-SEASONAL-12 foi significativo ao considerar nível de significância 1%. O mesmo pode ser dito para os efeitos dos 13 outliers detectados, e, por serem significativos, é o suficiente para mantê-los no modelo. Note que o modelo ARIMA sofreu uma diferenciação para tornar a série estacionária.

Podemos observar que a hipótese de normalidade dos resíduos foi rejeitada com 95% de confiança e a transformação *log* foi aplicada na série de arrecadação de ICMS no período de 1993 a 2019.

Quanto aos critérios de informação AICc e BIC não será feita análise profunda pois não tem outros modelos para efeitos de comparabilidade, como, por exemplo, teste de efeito Páscoa, cuja saída apresentariam outros valores para o critério de informação e a partir daí poderíamos tomar esses critérios como referência para auferir alguma informação adicional.

O teste de Ljung-Box não apresentou autocorrelação nos dados, com um valor de 21.09. Teste de Shapiro mostrou-se significativo com 0.986.

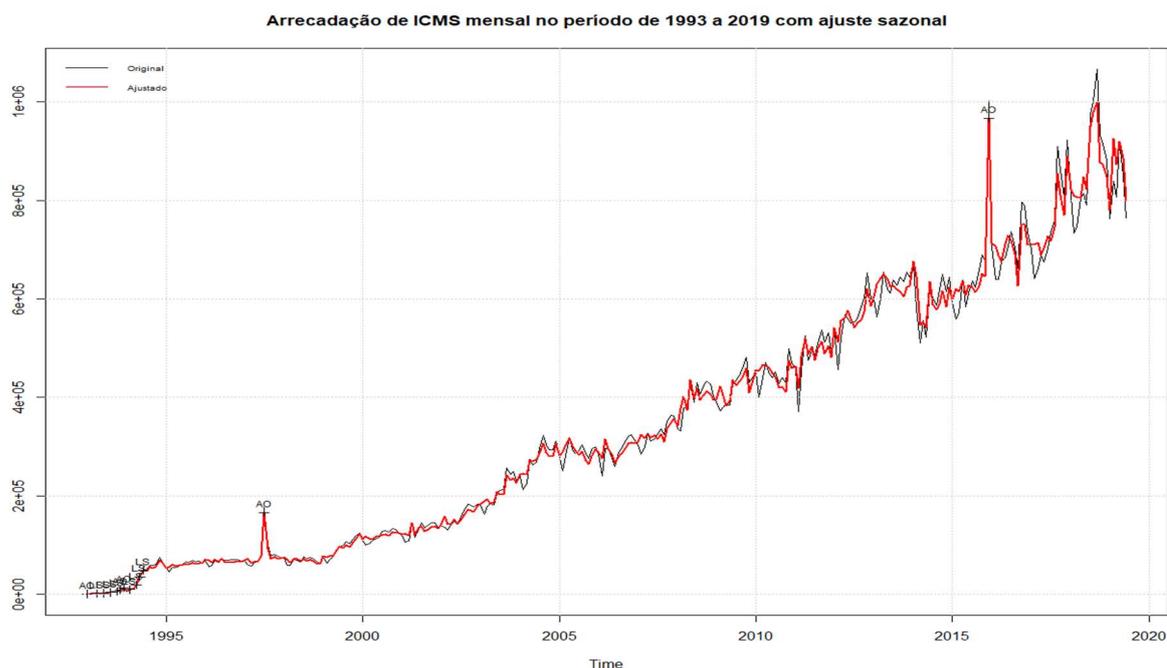
Os dois parâmetros, tanto o não-sazonal quanto o sazonal, do Modelo Arima foram significativos e nenhum deles precisa ser retirado. O modelo pode ser especificado com esses dois parâmetros.

5.1 DIAGNÓSTICO DE AVALIAÇÃO DO MODELO

Ferreira, Gondin e Mattos (2015b) recomendam que seja feita a avaliação da qualidade do ajuste sazonal regularmente e a ferramenta X13-ARIMA-SEATS disponibiliza esse instrumento por meio do teste estatístico QS e do gráfico *SI Ratio* para essa finalidade. Para os autores, o diagnóstico QS tem como objetivo a detecção de sazonalidade nos dados e onde se aplica aos dados originais, aos dados corrigidos por valores extremos, aos dados dessazonalizados, aos resíduos do modelo ARIMA (na fase de pré-ajuste) e no componente irregular. Em casos de séries temporais maiores que 7 anos, séries temporais longas portanto, o diagnóstico é aplicado, adicionalmente, aos últimos três anos. A hipótese nula desse teste é de que não existe sazonalidade na série temporal. O Diagnóstico QS identificou sazonalidade com um indicador de 1.701.

O teste de Ljung-Box verifica na série temporal verifica a existência de autocorrelação e o X13, segundo Ferreira, Gondin Jr. e Mattos (2015B, p.6), apresenta o resultado desse teste aplicado no modelo SARIMA estimado na defasagem 24. A hipótese nula desse teste é que os resíduos sigam uma distribuição normal. Na saída da Figura 5, o teste foi de 21.09, que sugere não haver evidências de autocorrelação residual até o *lag* 24.

GRÁFICO 6 - GRÁFICO DA SÉRIE AJUSTADA DE ICMS NO PERÍODO DE 1993 A 2019

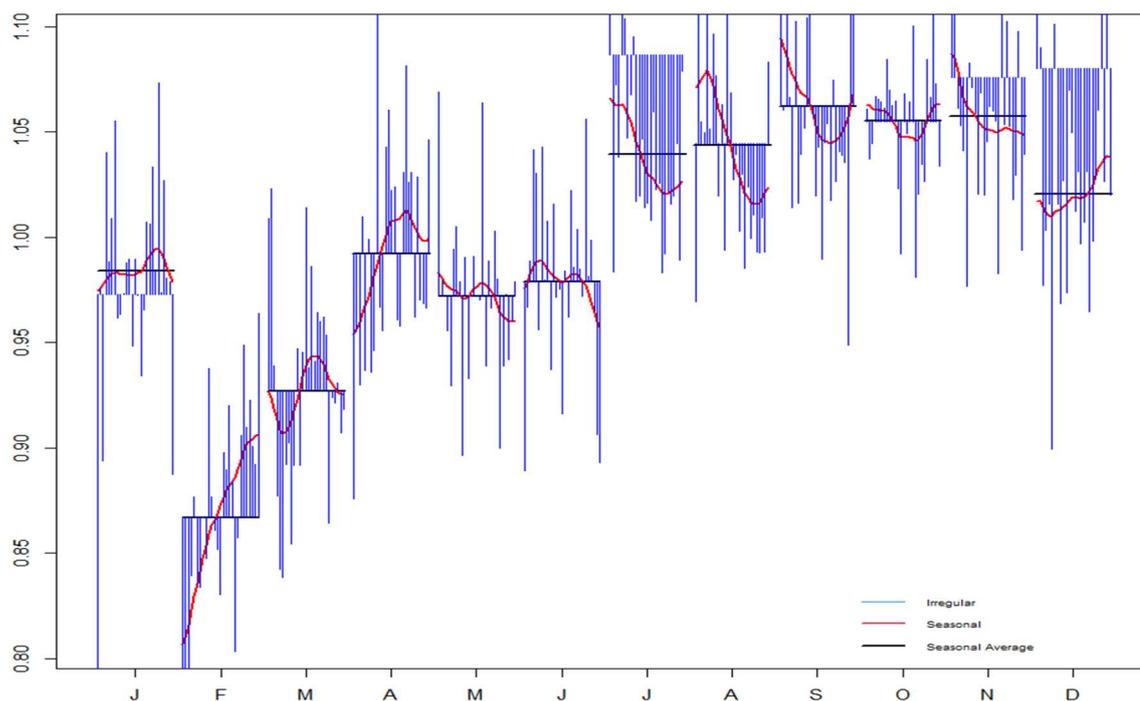


FONTE: ELABORAÇÃO PRÓPRIA (2021)

Em relação à série ajustada, podemos visualizar no Gráfico 4 em que demonstra a relação da série em nível e a série ajustada pelo X13ARIMA-SEATS, em vermelho. Note que o ajuste apresentou boa aderência com os dados originais, o que dá razoável segurança para realizar os testes de previsão do modelo.

Para verificar a relação os componentes sazonais, podemos ver no Gráfico 5, que trata da relação entre os componentes sazonais, podemos perceber que o componente sazonal acompanha a componente irregular e não há forte sobreposição entre as componentes.

GRÁFICO 7 - GRÁFICO DA COMPONENTE SAZONAL (SI RATIO)



FONTE: ELABORAÇÃO PRÓPRIA (2021)

Vamos, na sequência, verificar a acurácia do modelo com o código do RStudio que tem essa função, conforme se verifica na Figura 10 a seguir:

FIGURA 8 - ACURÁCIA DO MODELO PREVISTO EM RELAÇÃO AO MODELO ATUAL

```
> forecast::accuracy(predicted, actual)
      ME      RMSE      MAE      MPE      MAPE      ACF1 Theil's U
Test set -335.0127 21426.26 14447.23 -0.4589349 4.838954 0.5949284 0.4051625
```

FONTE: ELABORAÇÃO PRÓPRIA

Note que a variância de erro, MAPE, apresentou acurácia de 4,83%, sendo um bom indicador de ajuste do modelo, principalmente se considerarmos a margem de erro apurado na previsão de arrecadação de ICMS no Estado de Mato Grosso que apresentam erro que variam de 10 a 13%, considerando o Modelo Econométrico utilizado e o período de observação do presente trabalho.

Feitas as análises iniciais em relação aos dados em nível e dados ajustados, podemos partir para a previsão do modelo ajustado. Ao rodar a previsão com o X13ARIMA-SEATS, podemos verificar, isoladamente, apenas o modelo de previsão

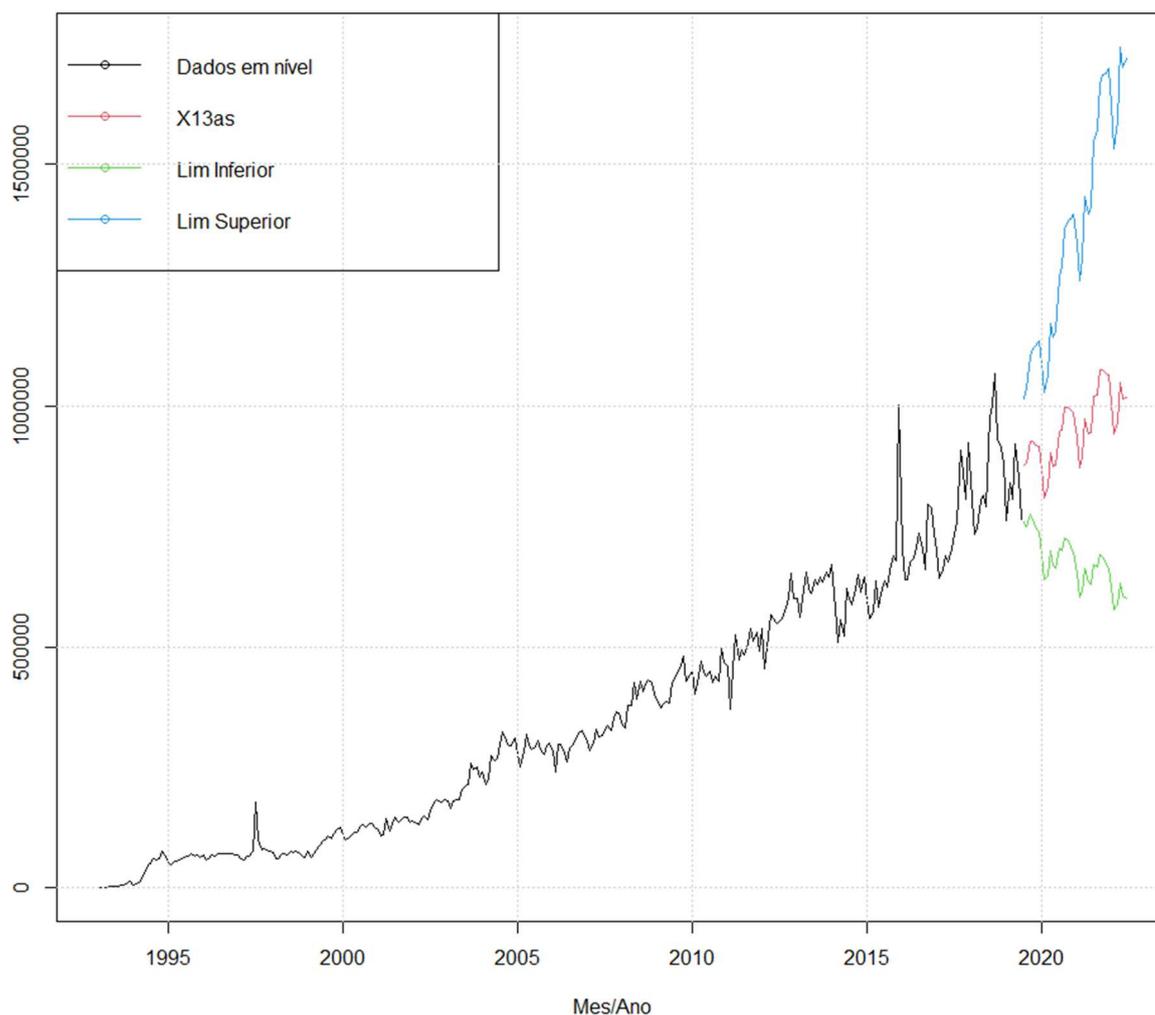
evidenciando a previsão (linha vermelha) e os limites superiores (linha azul) e inferiores (linha verde), conforme pode verificar no Gráfico 8:

GRÁFICO 8 - GRÁFICO DA PREVISÃO DO MODELO



FONTE: ELABORAÇÃO PRÓPRIA (2021)

GRÁFICO 9 - SÉRIE ORIGINAL DE ARRECAÇÃO DE ICMS E PREVISÃO DO AJUSTE



FONTE: ELABORAÇÃO PRÓPRIA (2021)

Segundo Ferreira, Gondin Jr. e Mattos (2015a, p.18) apontam que toda vez que novas informações são disponibilizadas, o ajuste sazonal dos dados deve ser refeito, pois pode ser que um novo dado pode alterar todos os valores da série temporal que foi ajustada previamente sem essa informação adicional. Segundo os autores, são quatro os métodos utilizados para revisão que são o método de revisão corrente, concomitante, concomitante parcial ou concomitante controlado.

No método corrente, há reidentificação do modelo ARIMA, filtros, *outliers* e variáveis de regressão e os seus respectivos parâmetros e fatores são reestimados para certo período previamente estabelecido. No segundo método, do tipo revisão concomitante, há também a reidentificação do modelo ARIMA, filtros, *outliers* e variáveis de regressão e os fatores e parâmetros são reestimados sempre que um novo dado encontra-se disponível. No terceiro método, o concomitante parcial, há uma

reidentificação anual do modelo ARIMA, filtros, *outliers* e variáveis de regressão e reestima-se os respectivos parâmetros e fatores. Assim, tão logo seja disponibilizado um novo dado, realiza-se o ajuste sazonal na série por inteiro, porém, mantendo-se as configurações do ano anterior. Por último, o método concomitante controlado, com o surgimento de um novo dado, realiza-se o ajuste corrente e o ajuste concomitante parcial e, na sequência, os seus resultados são comparados (FERREIRA, GONDIN JR.; MATTOS, 2015a).

6 CONCLUSÃO

Em um contexto de incertezas e também de crescente necessidade de uma eficaz alocação de recursos públicos para atendimento às demandas sociais, faz-se necessário melhorar continuamente o processo gestão das finanças públicas, particularmente, de receitas provenientes da arrecadação do ICMS no Estado de Mato Grosso.

Uma gestão eficiente baseada em um controle adequado tanto das receitas e das despesas direcionam o andamento das políticas públicas. Adicione-se à essa gestão a exigência legal quanto à elaboração do orçamento por meio da LRF – Lei de Responsabilidade Fiscal.

Dada a necessidade de entender a relação entre a variação da previsão de arrecadação de receitas do ICMS no Estado de Mato Grosso, que se utiliza de um modelo econométrico e a variação detectada com a utilização de um modelo mais recente, qual seja, o X13ARIMA-SEATS, podemos verificar a importância deste último para melhor acurácia na apresentação dos dados.

Este trabalho teve como objetivo inicial o desenvolvimento de uma análise crítica quanto ao modelo (econométrico) de previsão de ICMS utilizada no Estado de Mato Grosso que, conforme discutido na seção de análise, o modelo atualmente vigente apresenta, dentro do período delimitado de 1993 a 2019, uma taxa de erro que varia de 10 a 13%.

E em relação aos objetivos específicos delineados, foram feitas pesquisas em outros estudos semelhante em relação à modelagem de previsão em diversos entes federativos do Brasil com a utilização da Metodologia ARIMA (Box Jenkins) em sua maior parte e que apresentaram uma acurácia que variaram de 0,9% a 5%. É bom salientar que as acurácias são variáveis em função dos dados envolvidos nas séries. Uma comparação mais acertada possível seria a utilização do mesmo período e mesmas variáveis para se ter maior probabilidade de proximidade entre os resultados e acurácias. Em relação ao segundo objetivo específico, que sugeriu a comparação da projeção realizada pelo Estado de Mato Grosso com a utilização da metodologia de Box Jenkins e outros Estados brasileiros, em Mato Grosso, o resultado apurado foi de 4,83% de acurácia, constando dentro, portanto, das variações percebidas por outros modelos pesquisados. O terceiro objetivo específico esperado foi a análise da

previsão do ICMS por meio de um modelo de forma comparativa ao modelo utilizado atualmente pela Secretaria de Fazenda do Estado de Mato Grosso (SEFAZ-MT) e teve o X13-ARIMA-SEATS como modelo paralelo ao modelo econométrico utilizado no Estado de Mato Grosso e, em relação às acurácias, o modelo proposto apresentou uma acurácia de 4,83% em relação à média da acurácia atual, que tem variações entre 10 a 13%.

Ficou evidente que, pela própria natureza dos dados, a série temporal de arrecadação do ICMS no Estado de MT no período de 1993 a 2019, apresentou elevação, ou seja, uma tendência de crescimento, esta que precisou de revisões com ferramentas clássicas da teoria de séries temporais, como tendências, padrões cíclicos etc., para que a previsão gerada não fosse comprometida.

Foi observado também que, mesmo com crescimento ao longo do tempo, a série não apresentou sazonalidades evidentes quando foi verificado mês a mês, ou seja, não teve algum mês específico que tinha sazonalidade em relação à Páscoa, Natal e outras possíveis variáveis que podiam, tradicionalmente, guardar relação com a sazonalidade.

Em relação à metodologia, os dados, de fonte secundária, foram coletados em órgãos como BACEN – Banco Central e também no sítio da Secretaria de Fazenda do Estado de Mato Grosso, que contém uma seção própria de receitas públicas com demonstração das séries históricas do ICMS em valores nominais e corrigidos. Os dados foram deflacionados utilizando-se o índice IPCA e foi feita a dessazonalização da série utilizando-se de ferramentas específicas do X13-ARIMA-SEATS que, aplicado à série em nível, detectou alguns pontos de sazonalidade, seja do tipo LS ou AO, que, basicamente, alteraram a estrutura da série, seja aumentando, diminuindo ou mudando o comportamento da série em algum momento específico. Uma nota quanto à ferramenta X13-ARIMA-SEATS: foi formulada para operar dentro do ambiente RStudio.

A série deste trabalho foi tratada e foram feitos ajustes, como, por exemplo, no modelo ARIMA, que sofreu uma diferenciação no componente de integração, bem como os dados foram logaritimizados e as variáveis foram significativas a ponto de não serem necessários remoção do modelo. O modelo ajustado automaticamente pela ferramenta X13ARIMA-SEATS apresentou boa aderência com os dados em nível e foi válida para fazer as previsões necessárias e com acurácia de 4,83%.

Importante frisar o contraste de acurácia observada pela metodologia de previsão de arrecadação de ICMS com o modelo econométrico utilizado atualmente no Estado de Mato Grosso, que aponta uma acurácia de 10 a 13% e a acurácia observada na utilização do Modelo X13ARIMA-SEATS que reportou uma acurácia de 4,83% e que leva à necessidade de adequar as metodologias atualmente utilizadas por metodologias mais robustas no que diz respeito à previsão de arrecadação de ICMS.

Um outro aspecto importante a ser evidenciado trata-se da importância da política de revisão quando da inclusão de novos dados no modelo, pois a alteração da série, seja na inclusão ou remoção, pode alterar os resultados e métricas de saídas, bem como a acurácia para fins de previsão. Essa política deve ser sistematicamente revisitada para avaliar os resultados e modelos que poderão ser utilizados.

Como resultados da pesquisa, podemos destacar os principais, a começar pela evidenciação da tendência crescente das receitas no período de 1993 a 2019. Não foi percebida, em uma primeira análise gráfica, a presença marcante de sazonalidade. O modelo ajustado automaticamente pelo X13-ARIMA-SEATS apontou para um modelo ARIMA(0 1 1)(0 1 1), fazendo-se necessária uma diferenciação para que a série se tornasse estacionária. A série foi logaritmizada para permitir melhor performance nos resultados. Os parâmetros do modelo foram significativos e não precisaram ser retirados. A hipótese de normalidade da série foi rejeitada com 95% de confiança.

Das questões levantadas preliminarmente na parte introdutória deste trabalho, em relação a: quais os modelos existentes? Dos modelos pesquisados para construção da base bibliográfica, os mais recorrentes foram a Metodologia ARIMA (Box-Jenkins) e Modelo Econométrico Causal Dinâmico. O modelo sugerido neste trabalho é o ARIMA, porém, com utilização da ferramenta de análise X13-ARIMA-SEATS que apresentou bons resultados frente aos modelos pesquisados; outra questão foi: qual é o modelo que pode apresentar maior acurácia para a realidade do Estado de Mato Grosso? Dos modelos verificados, bem como dos resultados apurados, em Mato Grosso, a utilização do X13-ARIMA-SEATS, com uma acurácia de 4,83%, e considerando que o ajuste foi feito automaticamente, sem o ajuste manual do pesquisador para fazer verificações como inclusão e exclusão de variáveis, verificação de ajustes calendários e outros, o modelo respondeu satisfatoriamente à proposição inicial, que concorre com o resultado dos demais modelos pesquisados.

Uma primeira contribuição deste trabalho está relacionada ao fato de dar um suporte aos gestores públicos no processo de tomada de decisões em relação às alocações orçamentárias: quanto maior o poder de previsibilidade quanto à arrecadação de receitas, no caso, ICMS, melhor poderá ser a formulação de políticas sociais. Uma segunda contribuição diz respeito ao atendimento no arcabouço legal, notadamente o atendimento à exigência da Lei de Responsabilidade Fiscal em relação à previsão de receitas constante no Art. 12 da referida Lei.

Limitações foram encontradas na construção do presente trabalho em relação à análise dos dados: foi trabalhado o ajuste automático do modelo X13-ARIMA-SEATS e não houve aprofundamento em relação à utilização de efeitos calendários, como, por exemplo, feriados nacionais ou outro feriado móvel específico do Estado do Mato Grosso. Ajustes manuais poderiam refletir na acurácia apresentada apontando um melhoramento no resultado.

Como sugestão de trabalhos futuros, recomenda-se aprimorar a ferramenta com utilização do calendário brasileiro, com ajuste manual, e comparação entre os modelos de ajuste automático e manual e verificar a acurácia apresentada. A ferramenta X13ARIMA-SEATS permite também a utilização de séries multivariadas, em que podem ser inseridas, por exemplo, outros tipos de tributos para fazer novas análises de previsão.

7 REFERÊNCIAS

AZEVEDO, Ricardo Rocha; SILVA, José Marcos da; GATSIOS, Rafael Confetti. **Análise Crítica dos Modelos de Previsão de Série Temporal com Base no ICMS Estadual**. Revista Gestão, Finanças e Contabilidade, UNEB. v.7, n. 1, p. 164-184, jan./abr. Salvador: 2017.

CASTANHO, Bernardino Josafat da Silva. **Modelos para previsão de receitas tributárias: o ICMS do Estado do Espírito Santo**. Dissertação de Mestrado. Universidade Federal do Espírito Santo: Vitória, 2011. < Disponível em: <http://repositorio.ufes.br/handle/10/5981> >. Acessado em: 12 set. 2017.

CHAIN, Caixo Peixoto. COSTA, Daniel Fonseca. SANT'ANA, Naiara Lete dos. BENEDICTO, Gideon Carvalo de. **Contribuição da Modelagem de Valores Atípicos na Previsão da Arrecadação do ICMS do Estado de Minas Gerais**. Exacta, vol. 13,n. 2, pp. 239-249. Universidade Nove de Julho, São Paulo: 2015. Disponível em: < <https://www.redalyc.org/html/810/81043159010/> > Acessado em: 13 jan. 2018.

CLEMENTE, Ademir. CLEMENTE, Leonel Toshio. **Aplicação da Metodologia Box-Jenkins para previsão do ICMS do estado do Paraná de agosto de 2011 a julho de 2012**. Revista Economia & Tecnologia. Ano 07. Vol. 27. Out./Dez. 2011. Disponível em: < <https://revistas.ufpr.br/ret/article/view/25910> > Acessado em: 13/01/2017

EHLERS, Ricardo S. **Análise de Séries Temporais**. Departamento de Estatística. UFPR. Curitiba: 2005. Disponível em: < <http://www.each.usp.br/rvicente/AnaliseDeSeriesTemporais.pdf> > Acessado em: 09/01/2019.

FAVA, Vera Lúcia. **Análise de Séries de Tempo**. In: VASCONCELLOS, Marco Antônio.; ALVES, Denisard (Ed.). Manual de Econometria. São Paulo: Atlas, 2000. Cap. 9, p. 199-203.

_____. **Metodologia de Box-Jenkins para Modelos Univariados**. In: VASCONCELLOS, Marco Antônio.; ALVES, Denisard (Ed.). Manual de Econometria. São Paulo: Atlas, 2000. Cap. 10, p. 205-231.

FERREIRA, Pedro Costa; GONDIN JR., José Lisboa; MATTOS, Daiane Marcolino de. **Métodos de Ajuste Sazonal para séries de Business Tendency**: um estudo de caso para a Sondagem da Indústria utilizando o método X13-ARIMA-SEATS. Nota Técnica. FGV, IBRE: 2015A.

_____. **X13-ARIMA-SEATS com R**: um estudo de caso para a Produção Industrial Brasileira. 2015B.

FIGUEIREDO, Adriano Marcos Rodrigues. **Séries Temporais com R**: Análise do consumo Morettin com X13ARIMA-SEATS. Campo Grande-MS,Brasil: RStudio/Rpubs, 2020. Disponível em:

<<https://adrianofigueiredo.netlify.app/post/series-temporais-com-r-analise-do-consumo-de-morettin-e-toloi-com-x13arima-seats/>>. Acesso em: 01 mar.2021.

_____. **Séries Temporais com R: Análise ARIMA do Consumo do Varejo em MS com X13ARIMA-SEATS**. Campo Grande-MS, Brasil: RStudio/Rpubs, 2020. Disponível em: <https://adrianofigueiredo.netlify.app/post/series-temporais-consumo-varejo-ms-x13arima-seats/> Acesso em: 01 mar.2021.

GUJARATI, Damodar N. **Econometria Básica**. 5 ed. Porto Alegre: McGrawHill, 2011.

LAGEMANN, Eugênio. **Tributação Ótima**. Ensaios FEE, Porto Alegre, v. 25, n. 2, p. 403-426, out. 2004. Disponível em: <<https://revistas.fee.tche.br/index.php/ensaios/article/view/2064>>. Acesso em: 15 jan. 2019.

LIEBEL, M. J. **Previsão de Receitas Tributárias – O Caso do ICMS no Estado do Paraná**. [s.l.] Universidade Federal do Rio Grande do Sul, 2004.

MORE: **Mecanismo online para referências**, versão 2.0. Florianópolis: UFSC Rexlab, 2013. Disponível em: <<http://novo.more.ufsc.br/inicio>>. Acesso em: 16 jan. 2019.

MORETTIN, Pedro A. **Econometria Financeira: um curso em Séries Temporais Financeiras**. Departamento de Estatística – Instituto de Matemática e Estatística. USP. São Paulo: 2006.

PESSOA, Filipe de Moraes Cangussu; CORONEL, Daniel Arruda. **Previsão de arrecadação de ICMS para o Estado de Minas Gerais: uma comparação entre Modelos ARIMA e ARFIMA**. Encontro de Administração Pública e Governo – ANPAD. Salvador: 2012. Disponível em: <http://www.anpad.org.br/admin/pdf/2012_EnAPG79.pdf> Acesso em: 13/01/2017.

QUEIROS, Emerson Oliveira de. **Modelo de Previsão para receita tributária estadual: aplicação da Metodologia Box-Jenkins**. Dissertação. Mestrado em Economia Política. Pontifícia Católica de São Paulo – PUC-SP: São Paulo, 2012. Disponível em: <<https://tede2.pucsp.br/handle/handle/9196>> Acesso em: 21 mar. 2017.

ROSSI, José W. **Econometria e Séries Temporais com aplicações a dados da economia brasileira**. 2014. Disponível em: <[https://passeidireto.minhabiblioteca.com.br/books/978-85-216-2685-5/epubcfi/6/46\[:vnd.vst.idref=chapter09\]!/4/12@0:100](https://passeidireto.minhabiblioteca.com.br/books/978-85-216-2685-5/epubcfi/6/46[:vnd.vst.idref=chapter09]!/4/12@0:100)>. Acesso em: 10 jan. 2019.

SAMPAIO, Maria da Conceição. **Tributação do consumo no Brasil: aspectos teóricos e aplicados**. In: ARVATE, Paulo Roberto. **Economia do Setor Público no Brasil**. Rio de Janeiro: Elsevier, 2004. Cap. 11, pp. 188-205. 13ª Reimp.

SANTOS, Cristiane Márcia dos; LIMA, João Eustáquio de. **Análise de previsões da arrecadação do ICMS no Estado de Minas Gerais**. Revista de Economia e Administração, v.5, n.4, 413-423-p, out./dez./2006. Disponível em: <

<http://www.spell.org.br/documentos/ver/25886/analise-de-previsoes-da-arrecadacao-do-icms-no-estado-de-minas-gerais> > Acessado em: 03 jan. 2019.

SIQUEIRA, Marcelo Lettieri; RAMOS, Francisco S. Incidência Tributária. *In*: ARVATE, Paulo Roberto. **Economia do Setor Público no Brasil**. Rio de Janeiro: Elsevier, 2004. p. 155-172.

SIQUEIRA, Rozane Bezerra de; NOGUEIRA, José Ricardo; BARBOSA, Ana Luiza Neves de Holanda. **Teoria da Tributação Ótima**. *In*: ARVATE: Paulo Roberto. **Economia do Setor Público no Brasil**. Rio de Janeiro: Elsevier, 2004. Cap. 10. P. 173-187.

VASCONCELLOS, Marco Antônio S. ALVES, Denisard. (editores). **Manual de Econometria**: nível intermediário. São Paulo: Atlas, 2000

8 APÊNDICES

APÊNDICE A – Valor do ICMS (deflacionado) no período de janeiro de 1993 a junho de 2019

	ICMS	1996.02	56078,35	1999.05	87675,82	2002.08	170530,1
Data	Corrigido	1996.03	58871,23	1999.06	95625,89	2002.09	182931,8
1993.01	444,5874	1996.04	68151,97	1999.07	99546,23	2002.10	180211,6
1993.02	503,4827	1996.05	64630,82	1999.08	107384,4	2002.11	176748,3
1993.03	709,674	1996.06	70080,84	1999.09	102663,8	2002.12	182534,9
1993.04	1063,001	1996.07	69028,52	1999.10	111582	2003.01	180172
1993.05	1341,982	1996.08	69048,53	1999.11	118782,2	2003.02	163362,8
1993.06	1871,347	1996.09	70063,01	1999.12	124289	2003.03	179003,2
1993.07	2547,298	1996.10	70337,27	2000.01	109598,5	2003.04	182568,1
1993.08	3676,825	1996.11	69777,44	2000.02	99091,52	2003.05	181966,8
1993.09	4749,665	1996.12	67062,58	2000.03	103142,9	2003.06	204017,5
1993.10	6299,517	1997.01	66808,8	2000.04	108491,6	2003.07	210753,3
1993.11	9360,192	1997.02	59503,57	2000.05	113456,2	2003.08	212768,3
1993.12	12927,99	1997.03	57120,8	2000.06	115145,4	2003.09	256650,4
1994.01	6072,52	1997.04	64351,81	2000.07	127121,8	2003.10	243919,6
1994.02	7548,609	1997.05	65959,48	2000.08	129409,1	2003.11	248532,2
1994.03	10981,39	1997.06	76239,91	2000.09	126051,7	2003.12	229745
1994.04	18474,66	1997.07	176457,1	2000.10	132904,3	2004.01	238502,3
1994.05	34694,81	1997.08	99787,05	2000.11	132207,3	2004.02	212425,2
1994.06	47604,31	1997.09	77746,67	2000.12	125515,6	2004.03	226449,4
1994.07	49741,71	1997.10	79904,05	2001.01	119143,4	2004.04	273509,8
1994.08	59001,71	1997.11	76925,22	2001.02	105371,8	2004.05	262161,5
1994.09	58125,52	1997.12	74244,8	2001.03	107954,7	2004.06	268250,6
1994.10	59438,19	1998.01	72791,51	2001.04	142516,2	2004.07	296241,9
1994.11	74628,5	1998.02	59134,61	2001.05	116296,1	2004.08	321945,7
1994.12	64822,56	1998.03	58525,38	2001.06	132148,2	2004.09	304106,1
1995.01	52024,52	1998.04	69707,28	2001.07	145021,1	2004.10	293302,8
1995.02	45873,69	1998.05	69336,66	2001.08	135292,4	2004.11	293828,2
1995.03	54522,18	1998.06	66378,42	2001.09	140533,6	2004.12	310775,9
1995.04	54346,35	1998.07	76338,65	2001.10	144826,7	2005.01	276501,1
1995.05	57423,08	1998.08	72235,3	2001.11	144932,8	2005.02	250344,7
1995.06	59290,97	1998.09	75068,56	2001.12	134515,1	2005.03	281667,3
1995.07	65119,48	1998.10	71565,64	2002.01	138551,8	2005.04	318280,2
1995.08	64775,03	1998.11	65179,47	2002.02	136381,5	2005.05	295111,4
1995.09	69170,94	1998.12	61382,73	2002.03	130481	2005.06	285596,5
1995.10	65411,11	1999.01	75593,18	2002.04	142290	2005.07	292191,6
1995.11	67192,51	1999.02	62533,41	2002.05	147408,5	2005.08	303378
1995.12	63097,2	1999.03	69792,05	2002.06	141496,9	2005.09	285318,3
1996.01	68706,68	1999.04	77052,45	2002.07	157513,8	2005.10	276341,5

2005.11	294238,4	2009.04	386179,4	2012.09	583688,2	2016.02	639274,5
2005.12	299622,7	2009.05	383615	2012.10	600743,2	2016.03	639268,3
2006.01	284431,7	2009.06	427193,7	2012.11	653170,2	2016.04	675653,6
2006.02	240305,4	2009.07	435101,4	2012.12	599708,2	2016.05	684036,7
2006.03	295933,9	2009.08	444006,9	2013.01	600335,7	2016.06	706696,3
2006.04	296745,7	2009.09	459673,3	2013.02	563187,4	2016.07	736310,5
2006.05	277719,6	2009.10	481350,5	2013.03	601582	2016.08	703930,3
2006.06	259073,5	2009.11	429285,5	2013.04	654642,7	2016.09	661635,3
2006.07	288937,5	2009.12	443448,7	2013.05	621090,2	2016.10	797241
2006.08	296837,6	2010.01	450372,7	2013.06	611840,4	2016.11	789295
2006.09	307380	2010.02	400176,8	2013.07	638730,6	2016.12	736335,6
2006.10	321218,3	2010.03	439912,4	2013.08	628326,7	2017.01	699914,3
2006.11	324133,7	2010.04	470696,2	2013.09	644089,4	2017.02	641478,6
2006.12	312311,4	2010.05	447951,9	2013.10	635407,5	2017.03	661366,4
2007.01	303664,7	2010.06	440642,8	2013.11	654888,4	2017.04	688693
2007.02	283797	2010.07	451073	2013.12	644139,7	2017.05	675126,6
2007.03	298889,4	2010.08	427565,5	2014.01	672196,3	2017.06	702326
2007.04	327703,8	2010.09	439910,8	2014.02	580097	2017.07	734744,8
2007.05	311100,8	2010.10	429383,3	2014.03	510027,9	2017.08	760501,7
2007.06	315790,9	2010.11	498745,7	2014.04	556095,6	2017.09	909106,5
2007.07	324269,4	2010.12	468628	2014.05	521828,7	2017.10	861811
2007.08	336230,1	2011.01	459179,1	2014.06	621256,9	2017.11	807250,7
2007.09	323872,7	2011.02	370282,8	2014.07	600753	2017.12	922783,1
2007.10	351101,2	2011.03	454649	2014.08	587370,6	2018.01	807797,5
2007.11	364292,8	2011.04	525620,4	2014.09	618365,2	2018.02	733331,5
2007.12	362562,1	2011.05	474570,7	2014.10	650406,1	2018.03	746835,6
2008.01	336516	2011.06	493988,4	2014.11	614114,1	2018.04	803731,8
2008.02	331059,5	2011.07	484729	2014.12	643970	2018.05	814132,1
2008.03	378363,9	2011.08	508452,6	2015.01	594699,9	2018.06	790428,1
2008.04	377720	2011.09	537342,2	2015.02	558853,8	2018.07	974557,3
2008.05	426902,3	2011.10	511706,2	2015.03	571469,1	2018.08	1001905
2008.06	389760,8	2011.11	530622,4	2015.04	638511,5	2018.09	1066151
2008.07	429838,7	2011.12	491968,3	2015.05	583620,1	2018.10	932453,8
2008.08	406315,5	2012.01	537581,8	2015.06	611567,7	2018.11	914411,5
2008.09	423679,6	2012.02	455415,2	2015.07	637213,8	2018.12	880974,3
2008.10	432080,7	2012.03	522234,3	2015.08	623692,5	2019.01	763184,3
2008.11	427039,6	2012.04	567442,5	2015.09	658430,6	2019.02	839361,2
2008.12	401696,6	2012.05	559722,6	2015.10	689564,3	2019.03	807426,6
2009.01	389810,9	2012.06	549772,7	2015.11	678250	2019.04	919794
2009.02	372796,1	2012.07	553097,1	2015.12	1001285	2019.05	850406,9
2009.03	380117,7	2012.08	560461,8	2016.01	705289,5	2019.06	764910