



UNIVERSIDADE FEDERAL DE GOIÁS

FACULDADE DE ADMINISTRAÇÃO, CIÊNCIAS
CONTÁBEIS E ECONOMIA

Leandro Valerio Silva

Gráficos de controle para monitoramento da arrecadação de ICMS em Goiás

Goiânia

2017

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR
VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES
NA BIBLIOTECA DIGITAL DA UFG**

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: ☒ **Dissertação** ☐ **Tese**

2. Identificação da Tese ou Dissertação:

Nome completo do autor: Leandro Valerio Silva

Título do trabalho: Gráficos de controle para monitoramento da arrecadação de ICMS em Goiás

3. Informações de acesso ao documento:

Concorda com a liberação total do documento ☒ **SIM** ☐ **NÃO**¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.


Assinatura do autor

Ciente e de acordo:



Assinatura do orientador

Data: 22 / 09 / 2017

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Leandro Valerio Silva

Gráficos de controle para monitoramento da arrecadação de ICMS em Goiás

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Economia da Faculdade de Administração, Ciências Contábeis e Economia da Universidade Federal de Goiás, como requisito parcial para obtenção de título de Mestre em Economia.

Universidade Federal de Goiás – UFG

Faculdade de Administração, Ciências Contábeis e Economia

Orientador: Prof. Dr. Helton Saulo Bezerra dos Santos

Goiânia

2017

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Valerio Silva, Leandro

Gráficos de controle para monitoramento da arrecadação de ICMS
em Goiás [manuscrito] / Leandro Valerio Silva. - 2017.
67 f.

Orientador: Prof. Dr. Helton Saulo Bezerra dos Santos.

Dissertação (Mestrado) - Universidade Federal de Goiás,
Faculdade de Administração, Ciências Contábeis e Ciências
Econômicas (FACE), Programa de Pós-Graduação em Economia, Goiânia,
2017.

Bibliografia.

Inclui siglas, mapas, abreviaturas, gráfico, tabelas, lista de
figuras, lista de tabelas.

1. ICMS. 2. Gráficos de Controle. 3. SYMARMA. 4. Distribuições
Simétricas. 5. Séries Temporais. I. Bezerra dos Santos, Helton Saulo,
orient. II. Título.



ATA DE DEFESA PÚBLICA DE DISSERTAÇÃO

Aos vinte e cinco dias do mês de março de 2017, no horário de 10.00 horas às 11.16 horas, foi realizada, em sessão pública na sala 2110 da FACE, a defesa da dissertação Gratificação de controle p/ manutenção do custo do item em 60.000, de autoria do discente Leandro Valério Silva, do Programa de Pós-Graduação em Economia – PPE da Universidade Federal de Goiás. A Comissão Examinadora, constituída pelo Professor Helton Saulo Bezerra dos Santos, da Universidade Federal de Goiás (UFG)/PPE/(Membro Interno/Orientador), Professor Paulo Roberto Scalco, da Universidade Federal de Goiás (UFG)/PPE/(Membro Interno) e pelo Professor Jeremias da Silva Leão, da Universidade Federal do Amazonas (UFAM) (Membro Externo), emitiu o seguinte parecer/recomendações:

Resultado Final:

☒ Aprovado

☐ Reprovado

Recomendações:

Fazer as sugestões de banca.

Eu, Helton Saulo Bezerra dos Santos, orientador do discente, lavrei a presente Ata, que segue assinada por mim e pelos demais membros da Comissão Examinadora.

Helton Saulo Bezerra dos Santos

Prof. Dr. Helton Saulo Bezerra dos Santos (Orientador/Presidente/PPE/UFG)

Paulo Roberto Scalco

Prof. Dr. Paulo Roberto Scalco (Examinador Interno/UFG/PPE)

Prof. Dr. Jeremias da Silva Leão (Membro Externo/UFAM)

Goiânia, 25/03/2017.

Leandro Valerio Silva

Gráficos de controle para monitoramento da arrecadação de ICMS em Goiás

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Economia da Faculdade de Administração, Ciências Contábeis e Economia da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Mestre em Economia. Aprovado em 25 de março de 2017 pela banca examinadora composta pelos professores:

Prof. Dr. Helton Saulo Bezerra dos Santos
(orientador) - IME/UFG

Prof. Dr. Paulo Roberto Scalco - FACE/UFG

Prof. Dr. Jeremias da Silva Leão - DE/UFAM

Goiânia
2017

Resumo

O objetivo principal deste estudo é construir gráficos de controle para o monitoramento da arrecadação de ICMS em Goiás. Para tal, foram utilizados modelos autoregressivos de médias móveis simétricos (SYMARMA) com a finalidade de eliminar a autocorrelação presente na série temporal dos recolhimentos de ICMS. Construíram-se gráficos de controle do tipo Shewhart, CUSUM e EWMA, a partir dos resíduos gerados pelo modelo SYMARMA. Os resultados demonstraram que o gráfico de controle de Shewhart construído a partir dos resíduos do modelo SYMARMA com distribuição normal condicional apresentou-se mais de acordo com a realidade da arrecadação.

Palavras-chave: ICMS, Gráficos de Controle, SYMARMA, Distribuições Simétricas, Séries Temporais.

Abstract

The aim of this study is to use control charts to monitor the ICMS revenue in Goias, Brazil. The autocorrelation of the data was removed by using symmetric autoregressive moving average (SYMARMA) models . The Shewhart, CUSUM and EWMA control charts were constructed for residuals of the SYMARMA models. The results showed that the Shewhart control chart obtained from the SYMARMA model, based on a conditional normal distribution, presented the best result.

Keywords: ICMS, Control Chart, SYMARMA, Symmetric distributions, Time Series.

Lista de ilustrações

Figura 1 – Mapa dos municípios goianos segundo o ICMS arrecadado no ano de 2015.	20
Figura 2 – Distribuição Normal Padrão, com $\mu = 0$ e $\sigma = 1$	24
Figura 3 – Comparação entre as distribuições normal padrão e t -Student com 2 graus de liberdade.	25
Figura 4 – Série ICMS-GO.	44
Figura 5 – Histograma – ICMS-GO.	45
Figura 6 – boxplot – ICMS-GO.	45
Figura 7 – boxplot – ICMS-GO.	46
Figura 8 – boxplot – $\ln_{icms}$	46
Figura 9 – Correlograma da série $\ln_{icms}$	47
Figura 10 – Decomposição da série $\ln_{icms}$ em tendência temporal e sazonalidade.	48
Figura 11 – Série $\ln_{icms}$ após retirar a tendência determinística.	50
Figura 12 – Série $\ln_{icms}$ sem tendência determinística e desazonalizada.	51
Figura 13 – Correlograma da série após eliminar a tendência determinística e a sazonalidade.	52
Figura 14 – Gráficos QQplot dos resíduos - ARMA (a), t -ARMA (b) e Exp -ARMA (c).	56
Figura 15 – Gráficos de Shewhard - Série tratada pelo modelo ARMA (a) e série autocorrelacionada (b).	57
Figura 16 – Gráficos de Shewhard - Série tratada pelo modelo t -ARMA (a) e série tratada pelo modelo Exp -ARMA (b).	58
Figura 17 – Gráficos de Controle de CUSUM gerados a partir do modelo ARMA (a) e a partir da série autocorrelacionada (b)	59
Figura 18 – CUSUM - Série tratada pelo modelo t -ARMA (a) e série tratada pelo modelo Exp -ARMA (b).	59
Figura 19 – Gráficos de Controle EWMA gerados a partir do modelo ARMA (a) e a partir da série autocorrelacionada (b).	60

Figura 20 – EWMA - Série tratada pelo modelo t -ARMA (a) e série tratada pelo modelo Exp -ARMA (b).	61
--	----

Lista de tabelas

Tabela 1 – Composição da Arrecadação Tributária em Goiás no ano de 2015.	19
Tabela 2 – Participação da arrecadação de ICMS por municípios no ano de 2015.	20
Tabela 3 – Composição da arrecadação em Goiás por setores de atividade econômica no ano de 2015.	21
Tabela 4 – Composição da Arrecadação do ICMS em Goiás por modalidade de recolhimento no ano de 2015.	22
Tabela 5 – Distribuições simétricas de Cauchy, Laplace, logísticas tipo I e tipo II.	26
Tabela 6 – Distribuições Log-simétricas.	27
Tabela 7 – Expressões para $W_g(u_t)$ e $W'_g(u_t)$	37
Tabela 8 – Expressões para d_g e f_g	38
Tabela 9 – Estatísticas descritivas para as séries de ICMS e logaritmo do ICMS.	45
Tabela 10 – Estatísticas descritivas para as séries de ICMS e logaritmo do ICMS.	46
Tabela 11 – Resultado do teste ADF sobre a série $\ln_icms$	48
Tabela 12 – Extração da tendência determinística via MQO.	49
Tabela 13 – Resultado do teste ADF para série $\ln_icms_st$	49
Tabela 14 – Resultado da regressão por MQO para verificação da sazonalidade na série $\ln_icms$	51
Tabela 15 – Escolha dos graus de liberdade da distribuição t Student.	54
Tabela 16 – Escolha do parâmetro de curtose (k) da distribuição exponencial potência.	54
Tabela 17 – Resultados dos Modelos SYMARMA(1,0) estimados.	55
Tabela 18 – Diagnóstico dos resíduos.	55

Lista de abreviaturas e siglas

CEP	Controle Estatístico de Processos
GC	Gráfico de Controle
LC	Linha Central
LSC	Limite Superior de Controle
LIC	Limite Inferior de Controle
CUSUM	Cumulative Sum
EWMA	Exponentially Weighted Moving Average
MMEP	Médias Móveis Exponencialmente Ponderadas
TSP	Trend-Stationary Progress
DSP	Diference Stationry Progress
MQO	Mínimos Quadrados Ordinários
ADF	Teste de Dicky-Fuller Aumentado
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
BIC	Bayesian Information Criterion
MVC	Função de Máxima Verossimilhança Condicionada
EMVS	Estimador de Máxima Verossimilhança
RMSE	Raiz dos Erros Quadrados Médios
ICMS	Impostos sobre Circulação de Mercadorias e Serviços

IVC	Imposto sobre Vendas e Circulação
ICM	Impostos sobre Circulação de Mercadorias
IPVA	Impostos sobre Propriedade de Veículos Automotores
ITCD	Imposto sobre Transmissão Causa Mortis e Doações
SEFAZ	Secretaria da Fazenda do Estado de Goiás
BO	Business Object
IPCA	Índice de Preços ao Consumidor Amplo
ARMA	Modelo Autoregressivo e de Médias Móveis
ARIMA	Modelo Autoregressivo Integrado de Médias Móveis
SYMARMA	Modelo Autoregressivo de Médias Móveis Simétrico
t -ARMA	Modelo SYMARMA com distribuição t de student condicional
Exp -ARMA	Modelo SYMARMA com distribuição exponencial potência condicional

Sumário

1	INTRODUÇÃO	14
2	O ICMS	18
2.1	Considerações sobre o ICMS	18
2.2	ICMS em Goiás	19
3	DISTRIBUIÇÕES	23
3.1	Distribuições Simétricas	23
3.2	Distribuições Log-simétricas	26
4	MODELOS DE SÉRIES TEMPORAIS	28
4.1	Processos Estocásticos e Teste de Raiz Unitária	28
4.2	Modelo ARMA	31
4.3	Modelo SYMARMA	33
4.3.1	Algoritmo de Estimação	35
5	GRÁFICOS DE CONTROLE	39
5.1	Gráficos de Controle de Shewhart	40
5.2	Gráficos de Controle de CUSUM	41
5.3	Gráficos de Controle de EWMA	42
6	APLICAÇÃO	44
6.1	Dados	44
6.2	Tendência e Sazonalidade	47
6.3	Modelo SYMARMA	52
6.4	Gráficos de Controle	56
7	CONCLUSÕES	63
	REFERÊNCIAS	66

1 Introdução

A gestão eficiente dos recursos públicos é uma responsabilidade latente das democracias. Essa responsabilidade se revela na elaboração dos orçamentos públicos que por sua vez é um reflexo das ações discricionárias do governo no que se refere à suas receitas e seus gastos. Nesse sentido, várias técnicas de previsão e acompanhamento de arrecadação de receitas surgem como ferramentas importantes para auxiliar os gestores públicos na tomada de decisões.

Na literatura, muito já se tem discutido a respeito das técnicas de previsão de receitas. Autores como Mendonça e Medrano (2011), Campos (2009), Benelli (2013), Silva (2014), entre outros, se empenham em desenvolver e comparar metodologias de previsão de arrecadação. Contudo, não se encontram muitos registros formais relacionado aos métodos de acompanhamento amíúde da arrecadação seja na esfera federal, estadual ou municipal. Ou seja, são escassos os relatos de como é feito o monitoramento dos recolhimentos e como são identificados as possíveis oscilações anormais desses recolhimentos.

As empresas privadas, principalmente as indústrias, vêm a quase um século desenvolvendo técnicas de gestão de qualidade. O controle estatístico de processos (CEP) é uma das principais ferramentas de um sistema de gerenciamento orientado para a qualidade.

A ideia por trás do conceito do CEP está ligada à variabilidade de um processo. Se há variabilidade, então aplicam-se ferramentas estatísticas que permitem traçar limites para essa variabilidade de modo a detectar o momento em que uma variação anormal ocorreu. Assim é possível identificar a causa da variação, buscando solucionar as possíveis falhas e trazer o processo de volta ao estado de controle.

Os gráficos de controle são as ferramentas mais importantes do CEP. Basicamente esses gráficos traçam os limites nos quais um determinado processo deve variar. O gráfico mais utilizado, conhecido como gráfico de Shewhart, baseia-se nas suposições de normalidade e independência dos dados amostrais. Contudo essas suposições nem sempre são válidas quando se trata de séries temporais. A presença de autocorrelação

afeta as estimativas de variabilidade do processo e consequentemente o uso de gráficos de controle construídos sob a hipótese de normalidade e independência dos dados. Daí é necessário a utilização de metodologias específicas de séries temporais para eliminar a autocorrelação presente nos dados em análise.

Mingoti e Fidelis (2001) demonstraram que a metodologia de geoestatística pode ser utilizada para a análise estatística de séries temporais e a estimação de sua variabilidade. Segundo as autoras, o monitoramento de processos através de gráficos de controle do tipo Shewhart pode ser feito via geoestatística. Isso permite um tratamento mais simples ao frequente problema de séries temporais autocorrelacionadas.

Ainda tratando de estimações através de geoestatística, Mingoti e Yassukawa (2006) mostram por meio de dados simulados que a metodologia de geoestatística é menos afetada quando se tem pequenas amostras comparado aos estimadores usuais da variância. Sendo assim uma alternativa para implantação de sistemas de controle de qualidade quando o número de observações é relativamente reduzido.

Lima (2005) utiliza a série temporal de fabricação de alumínio de uma determinada indústria para mostrar que o CEP, na presença de dados autocorrelacionados, causa um aumento significativo de alarmes falsos, levando a constantes interrompimentos de produção. O autor, então, submeteu os dados ao modelo Box-Jenkins de séries temporais para detectar a autocorrelação e utilizou os resíduos do modelo para a construção do gráfico de controle. O autor concluiu que o método reduziu satisfatoriamente a ocorrência de alarmes falsos no processo analisado.

Claro, Costa e Machado (2007) compararam os gráficos de controle de médias (Shewart) e de EWMA para medir a eficiência desses dispositivos. O resultado foi que ambas as ferramentas possuem "inegável valor" à melhoria de processos. Contudo o gráfico de médias possui uma capacidade limitada na detecção de pequenos e médios deslocamentos. Já o gráfico de EWMA se mostra como uma alternativa mais eficiente.

Mingoti e Yassukawa (2008) analisaram o impacto da autocorrelação no comportamento dos gráficos de controle tracionais como Shewhart, EWMA e CUSUM. Os resultados encontrados pelas autoras revela que os gráficos de CUSUM e EWMA não são adequados para processos autocorrelacionados devido a elevada quantidade de alarmes falsos. As autoras afirmam que os gráficos de Shewhart apresentaram os melhores

resultados quando as estimativas de variabilidade foram obtidas através de geostatística.

Tondolo (2016) analisou o problema de monitorar dados do tipo taxas e proporções autocorrelacionados. A autora gerou processos autorcorrelacionados via simulações de Monte Carlo, utilizando o modelo de séries temporais β ARMA para o ajuste dos dados e a consequente confecção dos gráficos de controle de Shewhard, CUSUM e EWMA com os resíduos dos modelos. O resultado apresentado pela autora revela que a metodologia β ARMA apresenta melhor poder de detecção em relação ao modelo ARIMA usual.

Tratando da arrecadação tributária do Estado do Piauí, Carvalho (2013) submeteu a série temporal de arrecadação média daquele Estado à modelagem ARIMA para retirar a tendência determinística e a autocorrelação presente nos dados. Em seguida o autor utilizou os resíduos do modelo para a construção dos gráficos de controle de Shewhart e de MMEP. Segundo o autor, ambos os gráficos apresentaram um resultado satisfatório, apontando inclusive um ponto fora de controle, sinalizando a necessidade de uma intervenção por parte do órgão arrecadador.

No que se refere à aplicação de metodologias específicas de séries temporais para eliminar a autocorrelação dos dados, o Modelo Autoregressivo Integrado de Média Móvel (ARIMA) desenvolvido por Box e Jenkins revela-se a mais utilizada na literatura.

Contudo, a ocorrência de observações extremas nos dados pode levar a resultados equivocados dos modelos tipo ARIMA. Procurando contornar tal limitação, Maior e Cysneiros (2016) propuseram um modelo que permite ajustar séries temporais com o uso de distribuições simétricas cujas caudas são mais pesadas que a distribuição normal. Assim, o Modelo Autoregressivo de Médias Móveis Simétricos (SYMARMA) desenvolvido pelos autores poderia cumprir o propósito de tratar a autocorrelação para a aplicação de gráficos de controle, ainda que nunca tenha sido utilizado para essa finalidade.

Assim, o objetivo principal deste estudo é aplicar o controle estatístico de processos à série temporal da arrecadação de ICMS recolhido no estado de Goiás e verificar a existência de pontos fora de controle estatístico. Para atingir esse objetivo, foi necessário realizar os objetivos secundários abaixo elencados:

- (i) Analisar o comportamento da série temporal do ICMS arrecadado em Goiás;

- (ii) Submeter a série em estudo à modelagem SYMARMA para tratamento da autocorrelação;
- (iii) Construir gráficos de controle de Shewhard, CUSUM e EWMA a partir dos resíduos obtidos pelo modelo SYMARMA.

Este estudo se divide em sete Capítulos, incluindo esta Introdução. No Capítulo 2 se explora o ICMS e as particularidades do ICMS Goiano. O Capítulo 3 apresenta as características das distuições simétricas e log-simétricas. O Capítulo 4 desenvolve os principais conceitos dos modelos de séries temporais, apresenta a modelagem ARMA para que se possa, enfim, definir o modelo SYMARMA. O Capítulo 5 introduz a metodologia dos gráficos de controle. Os resultados deste estudo são apresentados no Capítulo 6. E, por fim, o Capítulo 7 revela as principais conclusões deste estudo, bem como propõe estudos futuros.

2 O ICMS

2.1 Considerações sobre o ICMS

A reforma tributária dos anos sessenta alterou a sistemática da arrecadação dos impostos sobre as vendas até então em vigor. Segundo Giambiagi e Além (2008), a modernização do sistema priorizou a tributação sobre o valor agregado, em detrimento do antigo Imposto sobre Vendas e Consignações (IVC). Este último incidia de forma cumulativa, onerando as vendas. Dessa forma, criou-se o Imposto sobre circulação de mercadorias (ICM), acompanhando a tendência dos países europeus, sendo o Brasil o primeiro país a adotar esse sistema a nível estadual.

Inicialmente, a união definiu alíquotas uniformes para o ICM em todos os Estados da Federação. Posteriormente, o imposto foi largamente utilizado como política de fomento a setores específicos, de modo a impulsionar o desenvolvimento econômico. Assim, dentre as quatro categorias definidas pela reformulação do sistema tributário, o ICM ficou classificado na categoria de impostos sobre a produção e a circulação.

A Constituição de 1988 alterou novamente as regras de tributação. Houve a incorporação do ICM a outros cinco impostos, dando origem ao atual Imposto sobre a Circulação de Mercadorias e Serviços – ICMS. Porém, a maior modificação foi a concessão de autonomia aos Estados para a fixação das alíquotas internas de ICMS. Desse modo, cada ente federativo passou a legislar suas próprias regras de tributação do ICMS dentro de seus territórios.

Ainda segundo Giambiagi e Além (2008), a autonomia dos Estados em matéria de tributação do ICMS originou, ao longo dos anos, uma legislação confusa e intrincada, gerando dificuldades para empresas, contribuintes e até para os governos estaduais. Deve-se mencionar ainda o acirramento das guerras fiscais dentro do território nacional, o que levanta vários debates entre estudiosos sobre os reais benefícios ou perdas desse acirramento para a economia e a sociedade.

2.2 ICMS em Goiás

A arrecadação tributária em Goiás é composta pelo ICMS, Imposto sobre a Propriedade de Veículos Automotores (IPVA), Imposto sobre Transmissão Causa Mortis e Doações (ITCD), Fundo PROTEGE e "Outros Tributos". De acordo com dados da Secretaria da Fazenda do Estado de Goiás (SEFAZ), o ICMS representou 87,81% da arrecadação tributária total do Estado no ano de 2015. Os demais impostos e tributos arrecadados compuseram apenas 12,19% da arrecadação estadual, conforme Tabela 1. Esses dados evidenciam a relevância do ICMS para a geração de receitas em Goiás.

Tabela 1 – Composição da Arrecadação Tributária em Goiás no ano de 2015.

Participação (%)	
ICMS	87,81%
IPVA	6,92%
ITCD	1,91%
Fundo PROTEGE	1,54%
Outros tributos	1,83%

Fonte: SEFAZ

Elaboração Própria

De acordo com a Tabela 2, a arrecadação de 81,30% do ICMS esteve concentrada em apenas 5 municípios, no ano de 2015. Em Goiânia foi recolhida a maior quantia de ICMS do Estado, 43,05%. Considerando que os municípios de Senador Canedo e Aparecida de Goiânia fazem parte da região metropolitana da capital, a concentração total da grande Goiânia aumenta para 71,07% da arrecadação total. A Figura 3 permite visualizar a distribuição da arrecadação de ICMS em todo o Estado de Goiás.

Tabela 2 – Participação da arrecadação de ICMS por municípios no ano de 2015.

	Participação (%)
Goiânia	43,05%
Senador Canedo	22,83%
Anápolis	8,01%
Aparecida de Goiânia	5,20%
Rio Verde	2,21%
Demais municípios	18,70%

Fonte: SEFAZ

Elaboração Própria




Figura 1 – Mapa dos municípios goianos segundo o ICMS arrecadado no ano de 2015.

A arrecadação de ICMS no Estado é segmentada por setores de atividade econômica. Nesse sentido é possível identificar 5 setores principais de arrecadação. A Tabela 3 apresenta esses setores e suas respectivas participações na arrecadação de ICMS no ano de 2015.

Tabela 3 – Composição da arrecadação em Goiás por setores de atividade econômica no ano de 2015.

Setor de Atividade Econômica	Participação (%)
Comércio	24,52%
Combustíveis	25,76%
Indústria	18,80%
Energia Elétrica	15,56%
Comunicação	7,55%
(Produção Agropecuária, Prestação de Serviços, Extração Mineral, etc)	7,81%

Fonte: SEFAZ
Elaboração Própria

O setor de comércio abrange as atividade de comércio varejista e atacadista. Sua participação no total de ICMS arrecadado é de 24,52%. Como já se sabe, os municípios de Goiânia e Aparecida de Goiânia concentram a maior parte das empresas do setor de comércio.

O setor de combustível arrecada cerca de 25,76% do ICMS estadual. Grande parte desses recolhimentos são efetuados no município de Senador Canedo. Todavia, deve-se ressaltar que a SEFAZ considera como setor de combustíveis, o conjunto da arrecadação proveniente dos comércios atacadista e varejista de combustíveis e lubrificantes em todo o Estado.

Os setores de indústria, energia elétrica e comunicação possuem grande relevância para arrecadação de ICMS, com 18,80%, 15,56% e 7,55% dos recolhimentos totais, respectivamente. A maior parte desses recolhimentos são efetuados na capital, Goiânia.

Cerca de 7,81% da arrecadação estadual de ICMS é resultado das atividades de produção agrícola, prestação de serviços e extração mineral. Também se pode atribuir parte dessa arrecadação a setores não sujeitos a tributação regular de ICMS, como a construção civil, por exemplo.

No caso específico da produção primária, sabe-se que o Estado de Goiás se destaca a nível nacional nesse segmento. Contudo, grande parte dessa produção é voltada para a exportação, o que a torna isenta da tributação de ICMS. Daí se percebe a pequena participação da produção primária sobre a arrecadação total estadual.

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

Nesse sentido, a arrecadação estadual de ICMS é dividida em três grupos: Espontâneo, Dívida Ativa e Ação Fiscal. Esses grupos se diferenciam pela forma com que os recolhimentos são realizados. A arrecadação espontânea corresponde aos impostos apurados e recolhidos pelo próprio contribuinte junto à SEFAZ no prazo legal estabelecido. A Dívida Ativa é relativa aos recolhimentos não realizados pelo contribuinte dentro do exercício ou prazo a que se referem e que são pagos ao Estado em algum momento posterior. Já os recolhimentos da Ação Fiscal são o resultado do trabalho de fiscalização e combate à sonegação.

Conforme os dados da Tabela 4, O ICMS espontâneo (ICMS-GO) corresponde à maior parcela da arrecadação total de ICMS. No ano de 2015 essa modalidade de arrecadação correspondeu a 97,40 % do ICMS total arrecadado. O ICMS espontâneo representa a real disposição do contribuinte em realizar seus recolhimentos e assim, responde com mais precisão as oscilações da atividade econômica. Deve-se ressaltar ainda que o ICMS espontâneo representa um fonte de recursos mais confiável para a elaboração dos orçamentos governamentais (SILVA, 2014). Por essa razão, esse estudo se baseou na análise da série temporal de ICMS espontâneo.

Tabela 4 – Composição da Arrecadação do ICMS em Goiás por modalidade de recolhimento no ano de 2015.

Participação (%)	
Ação Fiscal	1,68%
Dívida Ativa	0,92%
Espontâneo	97,40%
Fonte: SEFAZ	
Elaboração Própria	

3 Distribuições

3.1 Distribuições Simétricas

Formalmente, uma variável aleatória Y com suporte em $\mathbb{R}$, com parâmetro de localização $\mu \in \mathbb{R}$ e de escala $\varphi > 0$, tem distribuição simétrica se sua função densidade de probabilidade (FDP) é da seguinte forma:

$$f(y; \mu, \varphi) = \frac{1}{\sqrt{\varphi}} g \left[\left(\frac{y - \mu}{\sqrt{\varphi}} \right)^2 \right], y \in \mathbb{R}, \quad (3.1)$$

para alguma função $g(\cdot)$ denominada função geradora de densidade, com $g(u) > 0$, para $u > 0$ e $\int_0^\infty u^{-1/2} g(u) du = 1$; (CYSNEIROS; PAULA; GALEA, 2005). Essa condição é necessária e suficiente para que $f(y; \mu, \varphi)$ seja uma FDP. Denota-se $Y \sim S(\mu, \varphi)$ como variável aleatória simétrica.

A distribuição normal é a mais conhecida das distribuições simétricas. Sua função de densidade pode ser escrita como:

$$f(y; \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{1}{2} \left(\frac{y - \mu}{\sigma} \right)^2 \right], -\infty < y < \infty, \quad (3.2)$$

Então Y tem uma distribuição normal denotada por $Y \sim N(\mu, \sigma)$ onde μ é a média e σ é o desvio padrão.

A grande utilização da distribuição normal decorre principalmente do Teorema Central do Limite que estabelece que sob condições de regularidade, à medida que o número de observações de uma determinada variável aleatória tende ao infinito, sua distribuição torna-se aproximadamente normal. A Figura 1 apresenta a densidade de uma variável aleatória com distribuição normal.




Figura 2 – Distribuição Normal Padrão, com $\mu = 0$ e $\sigma = 1$.

A distribuição t de Student é muito utilizada quando se pretende modelar dados que possuem valores extremos, uma vez que é composta por caudas mais pesadas que a distribuição normal.

Formalmente, uma variável aleatória $Y \sim t(\mu, \varphi, v)$ tem distribuição t de Student com v graus de liberdade se sua função de densidade é assim expressa:

$$f(y; \mu, \sigma, v) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi}\Gamma\left(\frac{n}{2}\right)} \left[1 + \frac{\left(\frac{y-\mu}{\sigma}\right)^2}{v}\right]^{-\frac{n+1}{2}}, v > 0, \quad (3.3)$$

em que $\Gamma(a) = \int_0^\infty u^{a-1}e^{-u}du$ é a função gama.

A distribuição t de Student tende para a distribuição normal com média μ e σ quando $v \rightarrow \infty$. A Figura 3 compara a distribuição normal padrão com uma distribuição t com $v = 2$.




Figura 3 – Comparação entre as distribuições normal padrão e t -Student com 2 graus de liberdade.

Também é importante destacar, no contexto das distribuições simétricas, a distribuição exponencial potência. Diz-se que uma variável aleatória $Y \sim S(\mu, \varphi)$ tem distribuição exponencial potência se sua função geradora de densidade $g(\cdot)$ é dada por:

$$g(u) = C(k) \exp \left\{ -\frac{1}{2} u^{\frac{1}{1+k}} \right\}, \quad -1 < k \leq 1, u > 0, \quad (3.4)$$

em que $C(k)^{-1} = \Gamma \left(1 + \frac{1+k}{2} \right) 2^{1+\frac{1+k}{2}}$ e denota-se por $Y \sim EP(\mu, \varphi, k)$.

Segundo Cysneiros, Paula e Galea (2005), o parâmetro k pode ser visto como um parâmetro de curtose, ou de não normalidade, uma vez que quando $k = 0$, têm-se uma distribuição normal.

As distribuições simétricas de Cauchy, Laplace ou exponencial dupla e logística tipo I e II também são muito utilizadas na literatura e suas funções de densidades são apresentadas na Tabela 5.

Tabela 5 – Distribuições simétricas de Cauchy, Laplace, logísticas tipo I e tipo II.

Distribuição	Função de densidade	
Cauchy	$f(y, \mu, \sigma) = \left\{ \pi \sigma \left[1 + \left(\frac{y-\mu}{\sigma} \right)^2 \right] \right\}^{-1}$ em que μ é um parâmetro de locação e $\sigma > 0$	$-\infty < y < \infty$
Laplace	$f(y; \mu, \sigma) = \frac{1}{2\sigma} \exp \left\{ - \left \frac{y-\mu}{\sigma} \right \right\}$ em que μ é um parâmetro de locação e $\sigma > 0$	$-\infty < y < \infty$
Logística tipo I	$f(y; \mu, \sigma) = \frac{ce^{-(y-\mu)^2/\sigma^2}}{\sigma^2(1+e^{-(y-\mu)^2/\sigma^2})^2}$ em que $c \approx 1,484300027$ é uma constante normalizadora	$-\infty < y < \infty$
Logística tipo II	$f(y; \mu, \sigma) = \frac{1}{\sigma} \frac{e^{-(y-\mu)/\sigma}}{[1+e^{-(y-\mu)/\sigma}]^2}$	$-\infty < y < \infty$
Elaboração própria		

3.2 Distribuições Log-simétricas

Em diversas áreas do conhecimento é muito comum a existência de dados em que a variável de interesse é contínua, estritamente positiva, assimétrica e com forte presença de observações extremas. A distribuição log-simétrica torna-se, então, largamente utilizada para descrever o comportamento de dados com tais características (VANEGAS; PAULA, 2016). Segundo Puig (2008), a distribuição log-simétrica possui duas interessantes propriedades para descrever dados positivos, "closure under change of scale and closure under reciprocals".

Formalmente, seja Y uma variável contínua, cuja distribuição pertence à classe simétrica, com parâmetro de locação $-\infty < \mu < \infty$, parâmetro de dispersão $\sigma > 0$ e função geradora de densidade $g(\cdot)$.

A variável Y é denotada aqui como $Y \sim S(\mu, \sigma, g(\cdot))$ e sua função de densidade de probabilidade é dada por $f_y(y) = \frac{g\left[\frac{(y-\mu)^2}{\sigma}\right]}{\sqrt{\sigma}}$ para $-\infty < \mu < \infty$, tal que $g(u) > 0$ e $\int_0^\infty u^{-1/2} g(u) du = 1$.

Então, fazendo $T = \exp(Y)$, obtem-se uma nova variável aleatória cuja classe de distribuição é chamada de log-simétrica, denotada por $T \sim L-S(\eta, \sigma, g(\cdot))$, com suporte

no intervalo $(0, \infty)$, em que $\eta = \exp(\mu)$ é o parâmetro de escala, θ é o parâmetro de poder e a função de densidade de T é dada por:

$$f_T(t) = \frac{g(\tilde{t}^2)}{t\sqrt{\theta}}, t > 0, \quad (3.5)$$

em que $\tilde{t} = \log \left[\left(\frac{t}{\eta} \right)^{\frac{1}{\sqrt{\theta}}} \right]$. A função geradora de densidade $g(\cdot)$ pode envolver um argumento extra, denotado como ϵ , que comumente é assumido como conhecido.

A Tabela 6 abaixo apresenta algumas importantes distribuições log-simétricas.

Tabela 6 – Distribuições Log-simétricas.

Distribuição	Função de densidade	
Log-Normal (η, θ)	$g(u)\alpha \exp \left[-\frac{1}{2}u \right]$	$v(t) = 1$
Log-Student (η, θ, ξ)	$g(u)\alpha \left[1 + \frac{u}{\xi} \right]^{-\frac{\xi+1}{2}}$ $\xi > 0$	$v(t) = \frac{\xi+1}{\xi+t^2}$
Log-exponencial potência (η, θ, ξ)	$g(u)\alpha \left[-\frac{1}{2}u^{-\frac{1}{1+\xi}} \right]$ $-1 < \xi \leq 1$	$v(t) = \frac{ t ^{-\frac{2\xi}{\xi+1}}}{1+\xi}$
Elaboração própria		

Considerando os casos especiais em que se tem uma distribuição log-normal ($\xi = 0$) e uma distribuição log-laplace ($\xi = 1$). Se $\xi = 1$, então a distribuição de $Y = \log(T)$ é exponencial.

4 Modelos de Séries Temporais

Neste capítulo apresenta-se o conceito de séries temporais e as modelagens Box-Jenkins (ARMA) e SYMARMA. A breve descrição do modelo ARMA, neste estudo, tem a finalidade de facilitar a formalização do modelo SYMARMA, tendo em vista, como se verá mais adiante, que há larga semelhança entre ambos os modelos.

A detecção dos elementos presentes nas séries temporais são de fundamental importância para determinar as especificações dos modelos a serem estimados. Tanto o modelo ARMA como o modelo SYMARMA possuem a mesma metodologia de especificação. Por essa razão, as mesmas técnicas apresentadas para o modelo ARMA também equivalem ao modelo SYMARMA. Antes porém, busca-se evidenciar os processos estocásticos e a metodologia do teste de raiz unitária, fundamental para adentrar à modelagem propostas neste estudo.

4.1 Processos Estocásticos e Teste de Raiz Unitária

Uma série temporal é constituída por uma sequência de observações ao longo de um determinado período. Cada observação realizada em uma sequência assume um valor no tempo. Quando essas observações tem a probabilidade de assumir qualquer valor, diz se que a série temporal é um processo aleatório, ou estocástico. Em suma, "um processo estocástico é um conjunto de variáveis aleatórias ordenadas no tempo" (GUJARATI; PORTER, 2011, p.734).

Os processos estocásticos podem ser estacionários ou não estacionários. Um processo é estacionário quando sua média e variância são constantes ao longo do tempo. Também é condição necessária de estacionariedade que a covariância entre dois períodos (ou autocovariância) dependa apenas da defasagem entre os períodos. Esse processo também é conhecido como processo estocástico fracamente estacionário.

Assim, para que uma série y_t seja estacionária, as seguintes propriedades devem ser satisfeitas:

Média: $E(y_t) = \mu$

Variância: $Var(y_t) = E(y_t - \mu)^2 = \sigma^2$

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

Uma série temporal que viola uma, ou todas as propriedades acima é chamada de série temporal não estacionária. Processos estocásticos não estacionários – também conhecidos como passeio aleatório – ocorrem frequentemente em séries econômicas. A estimação de modelos de séries temporais que envolvam esse tipo de série requer diagnósticos e metodologias próprias, não se podendo estima-las trivialmente (BUENO, 2011, p.109).

Há outra característica importante presente em séries temporais que deve ser considerada, a tendência. Segundo Gujarati e Porter (2011) a tendência pode ser determinística ou estocástica.

A tendência determinística (TSP – Trend-Stationary Progress) ocorre quando a série temporal é uma função do tempo. A equação abaixo representa uma série temporal TSP:

$$y_t = \beta_1 + \beta_2 t + u_t, \quad (4.1)$$

Assim, os valores assumidos por y_t na equação (4.1) variam ao longo do tempo em torno de uma tendência temporal t . Para tornar uma série TSP em estacionária, basta que se estime uma regressão por Mínimos Quadrados Ordinários (MQO) tendo a tendência temporal como variável explicativa. Dessa forma, a série de resíduos u_t será a própria série y_t sem tendência determinística.

A tendência estocástica (DSP – Difference Stationary Progress) ocorre quando a série não é previsível. Ou seja, a série possui deslocamentos aleatórios ao longo de sua trajetória, fazendo com que sua média e variância variem constantemente. Para que uma série DSP se torne estacionária, deve-se diferencia-la, como no procedimento abaixo:

$$y_t = \beta_1 + y_{t-1} + u_t$$

$$y_t - y_{t-1} = \beta_1 + u_t$$

$$\Delta y_t = \beta_1 + u_t$$

Pode ocorrer a situação em que uma série temporal contenha elementos determinísticos e estocásticos, como na equação (4.2). Nesse caso deve-se aplicar os procedimentos de extração de tendência determinística via MQO e diferenciação dos resíduos.

$$y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t, \quad (4.2)$$

Séries temporais não estacionárias que necessitem ser diferenciadas para se tornarem estacionárias são conhecidas na literatura especializada como processos estocásticos de raiz unitária. Todo procedimento que envolve modelagem de séries temporais devem ser precedidos de algum tipo de teste que identifique a presença de raiz unitária nas séries. O teste mais utilizado pela literatura é o teste de Dickey-Fuller aumentado (ADF). (DICKEY; FULLER, 1981).

O procedimento desenvolvido por Dickey e Fuller consiste em incluir na equação (4.3) defasagens suficientes de y_t de tal modo que o termo de erro se torne não correlacionado serialmente. Isso é necessário para que se obtenha um coeficiente não viesado de δ , pois o teste ADF testa a hipótese nula de que esse coeficiente seja igual a zero, contra a hipótese alternativa de ser diferente de zero. Caso o coeficiente seja diferente de zero, admite-se que a série possui raiz unitária e deve ser diferenciada para tornar-se estacionária. A cada diferenciação, executa-se o teste ADF novamente sobre a série resultante, até que a tendência estocástica seja totalmente eliminada.

$$\Delta y_t = \beta_1 + \beta_2 t + \delta y_{t-1} + \sum_{i=1}^n \eta_i \Delta y_{t-i} + \epsilon_t, \quad (4.3)$$

Ainda não há na literatura um teste de raiz unitária capaz de detectar a presença de tendência determinística. O procedimento que se utiliza com frequência pelos autores consiste em verificar a significância de t na equação (4.3) apontada pelo teste ADF. A partir da significância daquele coeficiente pode-se procurar mais indícios da presença da tendência determinística por meio de regressões por MQO. Muitas vezes o teste ADF pode apresentar viés na direção de não rejeição da hipótese nula na presença de tendência determinística ou de mudanças estruturais na série.

Assim, o teste ADF deve ser executado em três etapas. A primeira etapa corresponde ao teste ADF irrestrito, onde a constante e a tendência temporal estão incluída no teste. Essa etapa corresponde à estimação da equação (4.3).

Se na primeira etapa, o teste ADF apontar para um parâmetro de tendência determinística não significativo, pode-se iniciar a segunda etapa. Nesse estágio, o teste ADF inclui apenas a constante, conforme evidencia a equação (4.4).

$$\Delta y_t = \beta_1 + \delta y_{t-1} + \sum_{i=1}^n \eta_i \Delta y_{t-i} + \epsilon_t, \quad (4.4)$$

A equação (4.5) representa a terceira etapa do teste ADF. Aqui, o teste é realizado sem os parâmetros de constante e tendência determinística. Esse caso é denominado de passeio aleatório puro.

$$\Delta y_t = \delta y_{t-1} + \sum_{i=1}^n \eta_i \Delta y_{t-i} + \epsilon_t, \quad (4.5)$$

4.2 Modelo ARMA

A metodologia ARMA é utilizada somente em séries temporais estacionárias. Para séries temporais que seguem um processo de raiz unitária, aplica-se um modelo ARMA sobre "n" diferenças de uma série original não estacionária. O modelo ARMA(p, q) aplicado a uma série temporal estacionária pode ser descrito pela seguinte equação:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{i=0}^q \theta_i \epsilon_{t-i}, \quad (4.6)$$

onde, c é uma constante, $\phi_1 \dots \phi_p$ são os coeficientes da parte autoregressiva (ordem p), $\theta_0 = 1$, $\theta_1 \dots \theta_q$ são os coeficientes da parte média móvel (ordem q) e $\epsilon_t \dots \epsilon_{t-q}$ são os componetens aleatórios do modelo.

Definindo $\phi(L) = 1 - \phi_1 L - \dots - \phi_p L^p$ e $\theta(L) = 1 - \theta_1 L - \dots - \theta_q L^q$, onde L é o operador de defasagem, têm-se a equação (3.8) de forma mais compacta:

$$\phi(L)y_t = \theta(L)\epsilon_t, \quad (4.7)$$

Segundo Bueno (2011), todas as raízes dos polinômios $\phi(L)$ e $\theta(L)$ devem estar fora do circulo unitário para que o modelo seja fracamente estacionário e invertível. Caso as duas condições não sejam satisfeitas "a série não poderia ser estimada recursivamente, usando-se observações passadas" (BUENO, 2011, p.37).

Na primeira etapa, deve-se identificar as ordens p e q do modelo. A análise visual do gráfico das funções de autocorrelação (FAC) e autocorrelação parcial (FACP) é o procedimento principal dessa etapa.

Na segunda etapa procede-se a estimação de cada um dos possíveis modelos identificados a partir da análise da FAC e da FACP. É importante ressaltar que a quantidade de defasagens p e q do modelo é ponderada pela perda de graus de liberdade. Assim, por meio do princípio da parcimônia, deve-se privilegiar modelos que gerem os menores critérios de informação Akaike (AIC), Schuartz (BIC) e Hannan-Quinn (HQC) conjuntamente.

A terceira etapa compreende o diagnóstico dos resíduos gerados pelos modelo. A modelagem correta implica, necessariamente, a obtenção de resíduos sem memória ou ruído branco. Em outras palavras, os resíduos devem ser não autocorrelacionados.

Bueno (2011) recomenda que se faça a análise visual dos gráficos das FAC e FACP dos resíduos em conjunto com o teste de Ljung-box sobre os mesmo. Espera-se que nesse procedimento não se rejeite a hipótese nula de que os resíduos não são autocorrelacionados.

Por fim, deve-se utilizar o teste Arch proposto por Engle (1982) para identificar sinais de heterocedasticidade nos resíduos do modelo. A não rejeição da hipótese nula do teste Arch implica que os resíduos são homocedásticos.

É comum que séries temporais de arrecadação tributária apresente comportamentos cíclicos, com forte padrão sazonal. Segundo Enders (1995), a sazonalidade é um componente importante e não pode ser desprezado. De acordo com o autor, há dois tipos de sazonalidade. O primeiro tipo é a sazonalidade aditiva. Nesse caso verifica-se o padrão sazonal em uma ou mais defasagens específicas. A dificuldade em identificar o modelo correto decorre da interação com os componentes não sazonais.

O outro tipo é a sazonalidade multiplicativa. Nesse caso verifica-se padrões sazonais nas defasagens em períodos de tempo uniformes (anual, semestral, trimestral, etc). Bueno (2011) define um modelo $ARMA(p, q)(P, Q)s$, em que p e q são as ordens autoregressivas e de médias móveis não sazonais, P e Q são os números dos coeficientes sazonais autoregressivos e de médias móveis, respectivamente, e s é o período sazonal.

Assim, um modelo $\text{ARMA}(2, 1)(1, 2)_{12}$ poderia ser definido da seguinte forma:

$$(1 - \phi_1 L - \phi_2 L^2)(1 - \phi_{12} L^{12})y_t = (1 - \theta L)(1 - \theta_{12} L^{12} - \theta_{24} L^{24})\epsilon_t, \quad (4.8)$$

No modelo acima representado pela equação (4.8), a sazonalidade é corrigida simultaneamente na estimação. A esse tipo de modelo dá-se o nome de modelagem SARIMA (Sazonal Autoregressive Integrated Moving Average). Contudo, há outros métodos menos elaborados para tratar a sazonalidade. Gujarati e Porter (2011) sugerem que se utilize o métodos das variáveis binárias para verificar se há presença de sazonalidade numa determinada série temporal. O autor orienta para que se adicione dummies temporais aos dados e estime-se uma regressão por MQO excluindo um período para ser tomado como referencia. Caso algum coeficiente seja significativo, confirma-se a presença de sazonalidade na série.

A estimação de coeficientes ARMA (ou ARIMA - caso haja necessidade de diferenciar a série original) com a utilização de variáveis dummies constituem os modelos ARMA/ARIMA com intervenção – também chamados de ARMAX/ARIMAX. Esses modelos podem se aplicar bem às séries temporais e frequentemente levam a bons resultados.

4.3 Modelo SYMARMA

O Modelo Autoregressivo de Médias Móveis Simétricos (SYMARMA) foi proposto por Maior e Cysneiros (2016) com o objetivo de ajustar séries temporais à classe de distribuições simétricas. A fundamentação do modelo permite acomodar observações atípicas com o uso de distribuições simétricas com caudas mais pesadas que a distribuição normal, como a distribuição t de Student, por exemplo. Assim, as estimativas fornecidas pelo modelo tendem a ser mais estáveis.

Maior e Cysneiros (2016) formalizam o modelo SYMARMA da seguinte forma:

Seja Y_t uma variável aleatória que segue uma distribuição simétrica de modo que a densidade condicional de y_t dado o conjunto de informações passadas $\delta_{t-1} = (y_{t-1}, \dots, y_1, \mu_{t-1}, \dots, \mu_1)$ é dada por:

$$f(y_t|\delta_{t-1}) = \frac{1}{\sqrt{\varphi}} g\left\{\frac{(y_t - \mu_t)^2}{\varphi}\right\}, y_t \in \mathbb{R}, \mu_t \in \mathbb{R}, \varphi > 0, \quad (4.9)$$

onde μ é o parâmetro de localização, φ é o parâmetro de escala, $g(\cdot \cdot \cdot)$ é a função geradora de densidades, com $g(u) > 0$ para $u > 0$, tal que $\int_0^\infty u^{-1/2} g(u) du = 1$.

A média e a variância de $y_t | \delta_{t-1}$ são expressas respectivamente por:

$$E(y_t | \delta_{t-1}) = \mu_t, \quad (4.10)$$

$$\text{VAR}(y_t | \delta_{t-1}) = \xi \varphi, \quad (4.11)$$

Em que $\xi > 0$ é uma constante dada por $\xi = -2\rho'(0)$, sendo $\rho(\cdot)$ a função característica de $y_t | \delta_{t-1}$ e $\rho'(0) = d\rho(u)/du|_{u=0}$. (Maior e Cysneiros (2016), Fang, Kotz e Ng (1990))

Considere $\gamma_t = y_t - x'_t \beta$ um modelo ARMA em que $x'_t = (x_{t1}, x_{t2}, \dots, x_{tk})$ é o vetor de valores de k variáveis explicativas e $\beta = (\beta_1, \beta_2, \dots, \beta_k)'$ um vetor de parâmetros desconhecidos. A componente γ também pode ser definida como:

$$\gamma_t = c + \sum_{i=1}^p \phi_i \gamma_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t, \quad (4.12)$$

Tomando $j > 0$ pode-se definir a esperança condicional de γ dado δ_{t-1} como:

$$E(\gamma | \delta_{t-1}) = c + \sum_{i=1}^p \phi_i \{y_{t-i} - x'_{t-i} \beta\} + \sum_{j=1}^q \theta_j \epsilon_{t-j}, \quad (4.13)$$

Seja a média μ_t do modelo SYMARMA dado por:

$$\mu_t = x'_t \beta + \tau_t, \quad (4.14)$$

onde τ_t é uma componente adicional com termos autoregressivos e de média móveis incluídos aditivamente.

De (4.10) e (4.14) têm-se:

$$E(y_t | \delta_{t-1}) = x'_t \beta + \tau_t,$$

logo

$$\tau_t = E(y_t | \delta_{t-1}) - x'_t \beta,$$

Tomando

$$E(\gamma|\delta_{t-1}) = E(y_t - x'_t\beta|\delta_{t-1})$$

$$E(\gamma|\delta_{t-1}) = E(y_t|\delta_{t-1}) - x'_t\beta$$

$$E(\gamma|\delta_{t-1}) = \tau_t$$

Reescrevendo (4.14)

$$\tau_t = c + \sum_{i=1}^p \phi_i \{y_{t-1} - x'_{t-1}\beta\} + \sum_{j=1}^q \theta_j \epsilon_{t-j}, \quad (4.15)$$

Portanto

$$\mu_t = c + x'_t\beta + \sum_{i=1}^p \phi_i \{y_{t-1} - x'_{t-1}\beta\} + \sum_{j=1}^q \theta_j \epsilon_{t-j}, \quad (4.16)$$

Assim, a componente dinâmica dada em (4.16) e a componente aleatória dada em (4.10) definem o modelo SYMARMA.

Segundo Maior e Cysneiros (2016), na ausência de variáveis exógenas e considerando que $y_t|\delta_{t-1}$ tem uma distribuição normal, o modelo ARMA é um caso particular do modelo SYMARMA.

Para elucidar a afirmação dos autores, seja o modelo dado por:

$$y_t = \alpha + \sum_{i=1}^p \phi y_{t-i} + \sum_{j=1}^q \theta \epsilon_{t-j} + \epsilon_t,$$

com $\epsilon_t \sim N(0, \sigma^2)$ para $t = 1, 2, \dots, T$, sendo não-correlacionados. Desse modo, a função de densidade condicional para y_t é dada pela seguinte equação,

$$f(y_t|\delta_{t-1}) = \frac{1}{\sqrt{2\pi}\varphi} \exp\left\{-\frac{(y_t - \mu_t)^2}{2\varphi}\right\},$$

Portanto, $y_t|\delta_{t-1} \sim N(\mu_t, \varphi)$ com $\mu_t = \alpha + \sum_{i=1}^p \phi y_{t-i} + \sum_{j=1}^q \theta \epsilon_{t-j}$

4.3.1 Algoritmo de Estimação

Os parâmetros do modelo SYMARMA pode ser obtidos através do método da máxima verossimilhança condicionada na primeiras m observações, onde $m =$

$\max\{p, q\}$ (MAIOR; CYSNEIROS, 2016). Assim, a função de máxima verossimilhança condicionada (MVC) é dada pela seguinte equação:

$$L(\iota, \varphi) = \prod_{t=m+1}^n f(y_t | \delta_{t-1}, \mu_t, \varphi), \quad (4.17)$$

onde $\iota = (\beta^T, \phi^T, \theta^T)^T$.

Expressa-se, então, o logarítmo da função MVC como:

$$l(\iota, \varphi) = \sum_{t=m+1}^n f(y_t | \delta_{t-1}, \mu_t, \varphi) = \sum_{t=m+1}^n -\frac{1}{2} \log(\varphi) + \log\{g(u_t)\}, \quad (4.18)$$

onde $u_t = \frac{(y_t - \mu_t)^2}{\varphi}$ e μ_t como definida em (4.16).

Assumindo que a função $g(\cdot)$ é contínua e diferenciável, pode-se obter o vetor score (U) a partir da primeira derivada de l (equação 4.18), em relação aos parâmetros desconhecidos. Calculando a segunda derivada obtém-se a matriz de informação condicional de Fisher (K). Desse modo, as funções scores para os vetores ι e φ são respectivamente dados por:

$$U_\iota(\iota, \varphi) = \varphi^{-1} O^T D(y - \mu)$$

e

$$U_\varphi(\iota, \varphi) = \frac{1}{2\varphi} [-(n - m) + \varphi^{-1} (y - \mu)^T D(y - \mu)],$$

onde $y = (y_{m+1}, \dots, y_n)^T$, $\mu = (\mu_{m+1}, \dots, \mu_n)^T$, $D = \text{diag}\{v_{m+1}, \dots, v_n\}$ com $v_t = v(u_t) = -2W_g(u_t)$ e $W_g(u_t) = \frac{\partial \log(g(u_t))}{\partial u_t}$.

Tem-se também $O = (C, A, B)$ como uma matriz $(n - m) \times (p + q + k + 1)$, tal que:

$$A = \begin{bmatrix} y_m - x_m^T \beta & \cdots & y_{m+1-p} - x_{m+1-p}^T \beta \\ y_{m+1} - x_{m+1}^T \beta & \cdots & y_{m+2-p} - x_{m+2-p}^T \beta \\ \vdots & \ddots & \vdots \\ y_{n-1} - x_{n-1}^T \beta & \cdots & y_{n-p} - x_{n-p}^T \beta \end{bmatrix}_{(n-m) \times p}$$

$$B = \begin{bmatrix} y_m - \mu_m & \cdots & y_{m+1-q} - \mu_{m+1-q} \\ y_{m+1} - \mu_{m+1} & \cdots & y_{m+2-q} - \mu_{m+2-q} \\ \vdots & \ddots & \vdots \\ y_{n-1} - \mu_{n-1} & \cdots & y_{n-q} - \mu_{n-q} \end{bmatrix}_{(n-m) \times q}$$

$$C = \begin{bmatrix} 1 - \sum_{i=1}^p \phi_i & \cdots & x_{(m+1)k} - \sum_{i=1}^p \phi_i x_{(m+1-i)k} \\ 1 - \sum_{i=1}^p \phi_i & \cdots & x_{(m+2)k} - \sum_{i=1}^p \phi_i x_{(m+2-i)k} \\ \vdots & \ddots & \vdots \\ 1 - \sum_{i=1}^p \phi_i & \cdots & x_{(n)k} - \sum_{i=1}^p \phi_i x_{(n-i)k} \end{bmatrix}_{(n-m) \times (k+1)}$$

As expressões $W_g(u_t)$ e $W'_g(u_t)$ para algumas distribuições simétricas podem ser representadas como na Tabela 7 abaixo, conforme Cysneiros, Paula e Galea (2005).

Tabela 7 – Expressões para $W_g(u_t)$ e $W'_g(u_t)$.

Distribuição	$W_g(u_t)$	$W'_g(u_t)$
Normal	$-\frac{1}{2}$	0
t Student	$-\frac{(v+1)}{2(v+u)}$	$\frac{(v+1)}{2(v+u)^2}$
Exponencial potência	$-\frac{1}{2(1+k)u^{\frac{k}{k+1}}}$	$\frac{k}{2(1+k)^2 u^{\frac{2k+1}{k+1}}}$
Elaboração própria		

O estimador de máxima verossimilhança (EMVS) $\hat{\iota}$ do vetor de parâmetros ι é obtido quando se iguala $U(\iota)$ a zero. Com exceção de $U(\varphi)$, o sistema de equações não tem uma solução explícita, devendo-se, então buscar outro processo iterativo para a estimação dos parâmetros. Maior e Cysneiros (2016) utilizam o método do Scoring de Fisher para o processo de estimação dos parâmetros do modelo SYMARMA. A partir desse método obtém-se a seguinte equação:

$$\iota^{(i+1)} = \iota^{(i)} + (K^{(i)})^{-1} U^{(i)}, i = 1, 2, \dots \quad (4.19)$$

onde K é a matriz de informação de Fisher condicional esperada para (ι, φ) e K^{-1} é a matriz inversa de K . A matriz de informação de Fisher condicional esperada é

expressa por $K_{\iota\iota} = 4d_{\iota}\varphi^{-1}O^TO$ e $K_{\varphi\varphi} = \frac{n-m}{4\varphi^2}(4f_g - 1)$ com $d_g = E[W_g^2(u_t)u_t|\delta_{t-1}]$ e $f_g = E[W_g^2(u_t)u_t^2|\delta_{t-1}]$.

A Tabela 8 abaixo apresenta os valores para d_g e f_g para algumas distribuições simétricas. (CYSNEIROS; PAULA; GALEA, 2005).

Tabela 8 – Expressões para d_g e f_g

Distribuição	d_g	f_g
Normal	$\frac{1}{4}$	$\frac{3}{4}$
t Student	$\frac{(v+1)}{4(v+3)}$	$\frac{3(v+1)}{4(v+3)}$
Exponencial potência	$\frac{\Gamma[(3-k)/2]}{4(2^{k-1})(1+k)^2\Gamma[(k+1)/2]}$	$\frac{(k+3)}{4(k+1)}$
Elaboração própria		

5 Gráficos de Controle

O Controle Estatístico de Processos (CEP) é uma ferramenta de fundamental importância quando se busca melhorar o desempenho de um processo. Os gráficos de controle (GC) se destacam como uma das ferramentas mais importantes do CEP. Basicamente, o GC cumpre o propósito de monitorar um processo para controlar e reduzir sua variabilidade. Nesse sentido, o GC tem grande importância na detecção de variações anormais, permitindo a interferência imediata dos agentes para correção dos problemas e, conseqüente, a redução da variabilidade.

Montgomery (2009) afirma que a variabilidade de um determinado processo pode ocorrer por causas aleatórias ou por causas atribuíveis. As causas aleatórias de variação são parte inerente de um processo. Ou seja, é uma variabilidade natural e inevitável. Processos em que se verifica apenas esse tipo de variabilidade é considerado sob controle estatístico.

A variabilidade por causas atribuíveis ocorre quando há um deslocamento muito grande em comparação ao padrão de variabilidade natural ou aleatório. Um processo é considerado fora de controle estatístico na presença de causas atribuíveis. Daí a importância dos GCs, pois permitem detectar rapidamente a ocorrência de causas atribuíveis, bem como estimar os parâmetros de um processo.

Basicamente o GC é composto por uma Linha Central (LC) que representa o valor médio da característica de qualidade que equivale ao estado de controle, e duas linhas horizontais. A linha acima da LC é chamada de Limite Superior de Controle (LSC). Já a abaixo da LC encontra-se o Limite Inferior de Controle (LIC). Diz-se que os pontos entre os limites estão sob controle estatístico. A ocorrência de pontos fora dos referidos limites pode caracterizar que o processo está fora de controle.

Basicamente o GC é semelhante a um teste de hipótese, onde

$$\begin{cases} H_0 : \text{processo sob controle estatístico} \\ H_a : \text{processo fora de controle estatístico} \end{cases} \quad (5.1)$$

Daí, para a construção do GC assume-se que as observações consecutivas do

processo, ou seja, a série temporal seja independente e identicamente distribuída (*i.i.d.*), o que frequentemente não se observa na prática. (CLARO; COSTA; MACHADO, 2007).

É muito comum em séries temporais a existência de autocorrelação, bem como a presença de tendência determinística e estocástica. Também não se pode deixar de mencionar a sazonalidade. Esses elementos afetam a confiabilidade dos GCs, uma vez que podem causar pontos fora de controle quando na verdade não estão (alarmes falsos), e também podem acabar por não detectar causas especiais que de fato existem. (TONDOLO, 2016)

Uma estratégia constantemente indicada consiste em aplicar metodologias de previsão, tal qual modelos ARIMA, para tratar as séries temporais e utilizar os resíduos (*i.i.d.*) (MONTGOMERY, 2009). Assim, os resíduos são utilizados para a detecção de causas especiais. (TONDOLO, 2016)

Este estudo analisará a série temporal de ICMS sob a perspectiva dos três gráficos de controle mais debatidos na literatura: Os gráficos de controle de Shewhart, CUSUM e EWMA.

5.1 Gráficos de Controle de Shewhart

O primeiro GC e mais utilizado na literatura foi proposto em 1932 por Walter S. Shewhart. Seu conceito fundamental assume que:

$$y_t = \mu + \epsilon_t, \quad t = 1, \dots, n$$

onde y_t é uma observação obtida de um processo em controle, μ é a média do processo, supostamente fixa e constante, ϵ_t é o termo de erro, ie. $\epsilon_t \sim N(0, \sigma^2)$ e n é o tamanho amostral.

Uma vez que a série temporal monitorada neste estudo apresenta uma única observação para cada período do tempo, o GC de Shewhart utilizado será um gráfico de controle individual.

Assumindo que w seja um estatística amostral e que μ_w e σ_w sejam a média e o desvio padrão de w , respectivamente, têm-se que a linha central e os limites superior e

inferior são dados por:

$$LSC = \mu_w + k\sigma_w,$$

$$LC = \mu_w,$$

$$LIC = \mu_w - k\sigma_w,$$

onde k é a distância dos limites em relação à linha central, expressa em unidade de desvio padrão. Geralmente utiliza-se $k = 3$. Assim, a probabilidade de ocorrência de pontos sob controle fora dos limites é de 27%. (MINGOTI; FIDELIS, 2001)

O GC de Shewhart, em relação à sua estrutura é classificado como sem memória, pois ignora as informações das observações passadas. Por essa razão a sua utilização é mais apropriada para detectar grandes desvios em relação à média do processos. (MINGOTI; YASSUKAWA, 2008)

5.2 Gráficos de Controle de CUSUM

O GC de CUSUM (Cumulative Sum) é indicado quando pequenas mudanças são importantes (MONTGOMERY, 2009). O GC de CUSUM incorpora toda a informação das observações passadas. Assim, é fundamentado em somas cumulativas dos desvios das observações em relação a um valor alvo, geralmente a média do processo.

Basicamente, os desvios acima do alvo são acumulados na estatística C^+ , enquanto se acumulam os desvios abaixo do alvo na estatística C^- . (CANO; MOGUERZA; CORCOBA, 2009)

As estatísticas C^+ e C^- são chamadas CUSUMs unilaterais superior e inferior, respectivamente, e são determinadas por:

$$C_t^+ = \max[0, y_t - (\mu_w + k) + C_{t-1}^+]$$

$$C_t^- = \max[0, (\mu_w - k) - y_t + C_{t-1}^-]$$

onde, os valores iniciais de $C_0^+ = C_0^- = 0$, $t = 1, \dots, n$ é o tamanho da amostra e k é o valor de referência representando o desvio da média que se pretende detectar.

O processo é considerado fora de controle quando uma das estatísticas C_t^+ ou C_t^- excedem o intervalo de decisão H . Montgomery (2009) afirma que a escolha dos

parâmetros k e H são fundamentais para determinar o desempenho do GC CUSUM. O autor recomenda que os valores de k e H seja definidos em 0,5 e 5 desvios padrões, respectivamente.

Logo, os limites para o GC de CUSUM são assim estabelecidos:

$$LSC = H,$$

$$LIC = -H.$$

5.3 Gráficos de Controle de EWMA

Também utilizado para detectar pequenas mudanças, o GC de EWMA (Exponentially Weighted Moving Average) é uma alternativa ao GC de Shewhart. Sua fundamentação baseia-se no peso das observações decaindo à medida que ficam mais antigas.

O GC de EWMA é definido por:

$$z_t = \lambda y_t + (1 - \lambda)z_{t-1},$$

onde $0 < \lambda \leq 1$ é uma constante.

Considerando $z_0 = \mu_w$ e y_t são os valores observados, definem-se os limites como:

$$\begin{aligned} LSC &= \mu_w + L\sigma_w \sqrt{\frac{\lambda^{1-(1-\lambda)^{2t}}}{2-\lambda}}, \\ LC &= \mu_w, \\ LIC &= \mu_w - L\sigma_w \sqrt{\frac{\lambda^{1-(1-\lambda)^{2t}}}{2-\lambda}}, \end{aligned}$$

em que L é a largura dos limites de controle expresso em unidade de desvio padrão.

Para grandes valores de t , os limites superior e inferior de controle assintóticos dos gráficos podem ser reescritos como:

$$\begin{aligned} LSC &= \mu_w + L\sigma_w \sqrt{\frac{\lambda}{2-\lambda}}, \\ LIC &= \mu_w - L\sigma_w \sqrt{\frac{\lambda}{2-\lambda}}, \end{aligned}$$

Montgomery (2009) recomenda, como regra empírica, utilizar valores menores de λ para detectar pequenas mudanças. A utilização de $L = 3$ é recomendada para valores maiores de λ . Contudo para valores menores de λ , recomenda-se reduzir a largura dos limites.

Assim como nos demais GCs, pontos acima ou abaixo dos limites caracterizam processo fora de controle.

Mingoti e Yassukawa (2008) afirmam que o GC de EWMA é mais robusto em relação à não-normalidade da distribuição do processo Y_t .

6 Aplicação

Tendo apresentado as características principais do ICMS recolhido em Goiás, este capítulo irá descrever a série de ICMS espontâneo recolhido no Estado (ICMS-GO). Em seguida os dados serão submetidos aos modelos propostos para detecção e eliminação da autocorrelação. Por fim, serão construídos os gráficos de controle, objetos deste estudo.

6.1 Dados

Os dados da arrecadação goiana foram obtidos no sistema informatizado de relatórios gerenciais de arrecadação – Business Object (BO) – da Secretaria da Fazenda do estado de Goiás (SEFAZ). Foram utilizados dados mensais de janeiro de 2008 à maio de 2016, totalizando 101 observações. A série temporal do ICMS-GO foi atualizada a valores constantes de maio de 2016 pelo Índice de Preços ao Consumidor Amplo – IPCA. Utilizou-se o software R versão 3.3.1 para tratamento da série em estudo e aplicação das metodologias propostas. Na Figura 4 é possível visualizar o comportamento da série ao longo do horizonte temporal em análise.




Figura 4 – Série ICMS-GO.

Uma sucinta análise descritiva é apresentada na Tabela 9. Observa-se que a medida de variabilidade apontada pelo coeficiente de variação de 15,58% é relativamente

alta, dada a magnitude dos dados. As medida de assimetria indicam que a série possui uma curva mais aberta que a da distribuição normal (curtose = 2,180012) e a assimetria é de apenas 0,056 aproximadamente, o que indica uma assimetria à direita.

Tabela 9 – Estatísticas descritivas para as séries de ICMS e logarítmo do ICMS.

Estatísticas	ICMS-GO
Média	$1,071 \times 10^9$
Mediana	$1,081 \times 10^9$
Moda	não existe
Desvio Padrão	$1,67 \times 10^8$
Coefficiente de Variação	15,58%
Assimetria	0,05637471
Curtose	2,180012
Máximo	$1,493 \times 10^9$
Mínimo	$7,808 \times 10^8$
n	101
Elaboração Própria	

Para confirmar as características apresentadas na Tabela 9, as Figuras 5 e 6 apresentam o histograma e o boxplot da série do ICMS-GO, respectivamente.




Figura 5 – Histograma – ICMS-GO.




Figura 6 – boxplot – ICMS-GO.

Para reduzir a variância dos dados e obter um melhor ajuste dos modelos, foi feita

a transformação logarítmica da série, gerando então a série do logarítmo do ICMS-GO ($\ln_icms$). Os dados apresentados na Tabela 10, abaixo, evidenciam que houve uma redução significativa do coeficiente de variação da série $\ln_icms$ em relação à série original. Comparando os bloxplot das séries ICMS-GO e $\ln_icms$, nas Figuras 7 e 8, respectivamente, percebe-se que não houve grandes mudanças com relação à assimetria dos dados.

Tabela 10 – Estatísticas descritivas para as séries de ICMS e logarítmo do ICMS.

Estatísticas	ICMS-GO	$\ln_icms$
Média	$1,071 \times 10^9$	20,78
Mediana	$1,081 \times 10^9$	20,80
Moda	não existe	não existe
Desvio Padrão	$1,67 \times 10^8$	0,1582
Coeficiente de Variação	15,58%	0,76%
Assimetria	0,05637471	2,0580
Curtose	2,180012	21,12
Máximo	$1,493 \times 10^9$	21,12
Mínimo	$7,808 \times 10^8$	20,48
n	101	101
Elaboração Própria		




Figura 7 – boxplot – ICMS-GO.




Figura 8 – boxplot – $\ln_icms$.

A análise do correlograma da série $\ln_icms$ na Figura 9, evidencia também a presença de autocorrelação nos dados. Assim como a tendência e a sazonalidade, a autocorrelação induz a resultados distorcidos se não forem devidamente tratados. As próximas seções apresentam os procedimentos para detectar e eliminar tais componentes.




Figura 9 – Correlograma da série $\ln_icms$.

6.2 Tendência e Sazonalidade

Trabalhos econométricos envolvendo séries temporais devem primordialmente serem precedidos da identificação dos elementos contidos nas séries analisadas. A presença desses elementos distorcem os resultados dos modelos se não forem corretamente identificados e tratados. Na Figura 10 é possível verificar, por meio da decomposição da série $\ln_icms$, a existência de tendência temporal e sazonalidade. A presença de tendência estocástica deve ser verificada por meio de teste específico.




Figura 10 – Decomposição da série *ln_icms* em tendência temporal e sazonalidade.

O teste ADF é o mais recomendado para a identificação de tendência estocástica (raiz unitária). Esse teste também pode apontar indícios de tendência determinística nas séries em estudo.

De acordo com a Tabela 11, o teste ADF irrestrito apontou para a presença de tendência determinística significativa 5% na série *ln_icms*.

Tabela 11 – Resultado do teste ADF sobre a série *ln_icms*.

		c/ cte e tend	c/ cte e s/ tend	s/ cte e s/ tend
ln_icms	Constante	6.4333***	2.3923**	
	Tendência	0.0011**		
	P-valor do teste	0.0002	0.0005	0.0054

* Significativo a 10%

** significativo a 5%

*** significativo a 1%

Elaboração Própria

Para confirmar a presença de tendência determinística, foi estimada uma regressão por MQO tendo a tendência temporal (t e t^2) como variáveis explicativas. O resultado da

regressão é apresentado na Tabela 12. Como pode ser observado, os parâmetros estimados foram altamente significativos. Assim, tendo sido modelada a tendência temporal, foram extraídos os resíduos da regressão, originando a série *ln_icms_st*. O termo "st" significa "sem tendência determinística".

Tabela 12 – Extração da tendência determinística via MQO.

	Constante	<i>t</i>	<i>t</i> ²	<i>R</i> ²
<i>ln_icms</i>	-3.075x10 ⁰⁴ ***	3.053x10 ⁰¹ ***	-7.574x10 ⁻⁰³ ***	0.7496

* Significativo a 10%

** significativo a 5%

*** significativo a 1%

Elaboração Própria

Após a retirada da tendência determinística presente na série *ln_icms*, a série resultante foi novamente submetida ao teste ADF. De acordo com os resultados apresentados na Tabela 13, confirma-se que a tendência determinística foi realmente extraída. Também se observa que a constante não foi significativa. O resultado da etapa do teste ADF sem constante e sem tendência permite concluir que a série é estacionária em torno de uma tendência temporal determinística, podendo ser classificadas como série TSP.

Tabela 13 – Resultado do teste ADF para série *ln_icms_st*.

		c/ cte e tend	c/ cte e s/ tend	s/ cte e s/ tend
<i>ln_icms_st</i>	Constante	1.415x10 ⁻⁰³	-0.0006	
	Tendência	-3.979x10 ⁻⁰⁵		
	P-valor do teste	2.279x10 ⁻⁰⁵	6.398x10 ⁻⁰⁶	1.495x10 ⁻⁰⁷

* Significativo a 10%

** significativo a 5%

*** significativo a 1%

Elaboração Própria

Na Figura 11 é possível visualizar a série temporal estacionária. Por meio da análise visual, também é possível indentificar um comportamento sazonal. Esse comportamento é perfeitamente natural em séries relacionadas à atividade econômica. Sabe-se que em determinadas épocas, como períodos de safras agrícolas e fins de ano, a um

incremento de atividade voltadas ao consumo que expandem a atividade econômica, demandando mais mão de obra e impulsionando a arrecadação.




Figura 11 – Série $\ln_icms$ após retirar a tendência determinística.

Para verificar a presença de sazonalidade na série $\ln_icms_st$, foi estimada uma regressão por MQO utilizando dummies temporais. A dummy referente ao mês de dezembro foi retirada do modelo para servir como referência, conforme recomenda Gujarati e Porter (2011). Os resultados das regressões apresentados na Tabela 14 confirmaram empiricamente a presença de sazonalidade.

Tabela 14 – Resultado da regressão por MQO para verificação da sazonalidade na série $\ln_{icms}$.

Coeficientes		
Constante	$-2,75 \times 10^{07}$	***
t	$2,73 \times 10^{04}$	***
t^2	-6,762	***
$dsazonal.L$	108,7	***
$dsazonal.Q$	3,537	
$dsazonal.C$	-77,36	***
$dsazonal4$	61,79	**
$dsazonal5$	-30,09	
$dsazonal6$	29,97	
$dsazonal7$	-17,59	
$dsazonal8$	-17,29	$R^2 = 0.8324$
$dsazonal9$	-5,674	
$dsazonal10$	-0,6741	
$dsazonal11$	9,38	


* Significativo a 10%

** significativo a 5%

*** significativo a 1%

Elaboração Própria

Após a modelagem simultânea da tendência determinística e da sazonalidade evidenciada na Tabela 14, extraiu-se os resíduos da regressão, originando a série $\ln_{icms}$ sem tendência e desazonalizada ($\ln_{icms_st_des}$), conforme Figura 12. Assim, a série $\ln_{icms_st_des}$ será submetida à modelagem SYMARMA.

Figura 12 – Série $\ln_{icms}$ sem tendência determinística e desazonalizada.

6.3 Modelo SYMARMA

O modelo SYMARMA é um modelo dinâmico para séries temporais com distribuição simétrica condicional. Conforme foi demonstrado no Capítulo 4, o modelo ARMA é um caso particular do modelo SYMARMA, uma vez que o modelo ARMA corresponde a um modelo SYMARMA com distribuição normal condicional. Assim, a estimação do modelo SYMARMA segue a mesma metodologia Box-Jenkins, ou ARMA.

Desse modo, o primeiro passo para a estimação do modelo SYMARMA a partir da série estacionária é identificar as ordens p e q do modelo, utilizando o correlograma, conforme recomenda Enders (1995).

A Figura 13 apresenta o correlograma da série *ln_icms_st_des*. É possível verificar claramente um pico na primeira defasagem da FACP, que determina a ordem p do modelo. Já com relação a ordem q , a análise da FAC pode gerar dúvidas se há um pico na primeira defasagem, ou se na verdade se trata de um decaimento exponencial.




Figura 13 – Correlograma da série após eliminar a tendencia determinística e a sazonalidade.

Sendo assim, foram estimados modelos SYMARMA com um componente autoregressivo e um componente de média móvel - SYMARMA(1,1). Do mesmo modo, foi estimado um modelo com somente um componente autoregressivo - SYMARMA(1,0). Os resultados do modelo SYMARMA(1,1) não apresentaram coeficientes significativos, enquanto no modelo SYMARMA(1,0), o coeficiente foi significativo, assim como as demais etapas do processo apresentaram resultados satisfatórios, conforme se verificará mais adiante. Logo, o modelo SYMARMA(1,1) foi descartado e seus resultados não serão apresentados.

Neste estudo a estimação do modelo SYMARMA será realizada utilizando três famílias de distribuições condicionais diferentes – a distribuição normal, a distribuição t de student, e a distribuição exponencial potencia.

A estimação do modelo SYMARMA com distribuição condicional normal corresponde ao modelo ARMA tradicional, por essa razão esse modelo será denominado, simplesmente, modelo ARMA. A escolha da distribuição condicional t de student é devida às caudas mais pesadas dessa distribuição em relação à distribuição normal, pois permite acomodar melhor distribuições atípicas. Esse modelo será denominado, neste estudo, modelo t -ARMA. O modelo SYMARMA com distribuição condicional exponencial potencia será denominado por modelo *Exp*-ARMA, e sua estimação terá como finalidade apenas comparar os resultados das três distribuições entre si, sem maiores considerações neste estudo.

A distribuição t de student e a distribuição exponencial potencia possuem parâmetros específicos que devem ser definidos previamente. Torna-se necessário determinar os graus de liberdade (v) da distribuição t de student, assim como o parâmetro de curtose (k) da distribuição exponencial potencia.

Para a escolha dos parâmetros v e k das distribuições t de student e exponencial potencia, respectivamente, utilizou-se o critério de informação BIC (Bayesian Information Criterion), dado por

$$BIC = -2 \log(L) + b \log(n),$$

em que L é o valor da função de Verossimilhança, b é o número de parâmetros a serem estimados e n é o número de observações. O BIC é um critério consistente, uma vez que fornece estimativas dos parâmetros que convergem em probabilidade para os seus

verdadeiros valores à medida que a amostra tende ao infinito (MAIOR, 2012). Assim, o modelo que descreve com melhor precisão a dinâmicas dos dados é aquele que apresenta o menor BIC.

De acordo com os resultados apresentados na Tabela 15, a distribuição t de student com 4 graus de liberdade apresentou o menor valor do critério de informação BIC. Da mesma forma, o parâmetro de curtose igual a 0,2 para a distribuição exponencial foi o que apresentou, também o menor BIC, conforme Tabela 16.

Tabela 15 – Escolha dos graus de liberdade da distribuição t Student.

Graus de liberdade (v)	ℓ	BIC
1	128,4839	-250,9548
2	138,8178	-269,6183
4	142,6086	-273,1913
5	143,0706	-272,1218
6	143,2892	-270,5438

onde $\ell = \log L$

Elaboração Própria

Tabela 16 – Escolha do parâmetro de curtose (k) da distribuição exponencial potência.

k	ℓ	BIC
0,1	143,0930	-282,1774
0,2	143,2473	-282,4860
0,3	143,2122	-282,4158
0,4	143,0251	-282,0416
0,6	142,3075	-280,6064
0,9	140,6851	-277,6316

onde $\ell = \log L$

Elaboração Própria

Tendo definido os parâmetros necessários, forma estimados os modelos SY-MARMA(1,0) segundo as distribuições condicionais normal, t de student e exponencial potência. Os resultados são apresentados na Tabela 17

Tabela 17 – Resultados dos Modelos SYMARMA(1,0) estimados.

Distribuição Condicional	Constante	ϕ_1	ℓ	RMSE	BIC
Normal	$-4,47 \times 10^4$ (0,0105)	0,4476 (0,0905)	142,7042	6,06	-281,3998
Student ($\nu=4$)	$-7,79 \times 10^3$ (0,4310)	0,4310 (0,0852)	142,6086	4,00	-273,1913
Exponencial Potência ($k = 0,2$)	$-2,93 \times 10^3$ (0,0102)	0,4427 (0,0888)	143,2473	5,37	-282,4860

Elaboração Própria

É possível verificar nos resultados apresentados acima que o modelo *Exp*-ARMA apresenta o menor valor do critério BIC, enquanto o modelo *t*-ARMA apresenta o maior valor desse critério. Em compensação o último obteve os menores erros quadrados médios (RMSE). O modelo ARMA apresentou o maior valor de RMSE e um valor de BIC intermediário entre os outros dois modelos. Nos três modelos os coeficientes de seus componentes autoregressivos foram significativos e somente a constante do modelo *t*-ARMA não foi significativa.

No que se refere ao diagnóstico dos resíduos, a Tabela 18 sintetiza o resultado dos testes de autocorrelação e heterocedasticidade. O p-valor de cada modelo obtido no teste Box-Ljung permite não rejeitar a hipótese de que os resíduos não são serialmente correlacionados a 1% de significância. Esse resultado satisfaz a condição de que os resíduos não possuem memória. O teste de heterocedasticidade ARCH LM permite afirmar que os resíduos dos modelos são homocedáticos, conforme o p-valor do teste. A Figura 14 apresenta o gráfico QQplot dos resíduos dos modelos ARMA (a), *t*-ARMA (b) e *Exp*-ARMA (c).

Tabela 18 – Diagnóstico dos resíduos.

Teste	ARMA	<i>t</i> -ARMA	<i>Exp</i> -ARMA
Box-Ljung	0,2104	0,1131	0,1459
ARCH LM	0,7762	0,3937	0,904

Elaboração Própria




Figura 14 – Gráficos QQplot dos resíduos - ARMA (a), t -ARMA (b) e ExP -ARMA (c).


Os resultados obtidos a partir da modelagem SYMARMA foram satisfatórios e sugerem que não há mais correlação nos dados. Desse modo, os resíduos gerados serão utilizados para a construção dos gráficos de controle.

6.4 Gráficos de Controle

Esta seção apresenta os gráficos de controle construídos a partir dos resíduos obtidos pelo modelo SYMARMA segundo as três famílias de distribuições simétricas condicionais: normal, t de student e exponencial potencia. Há duas análises importantes a serem realizadas a partir desses resultados. A primeira está nas distorções que a autocorrelação causa sobre os gráficos de controle. Para elucidar essa questão, foi feita uma comparação entre os gráficos de controle construídos a partir da série autocorrelacionada e a série tratada pela modelagem SYMARMA. A outra importante análise a ser feita é com relação ao desempenho do modelo SYMARMA à série de ICMS. Para tal, é relevante comparar os gráficos de controle obtidos a partir dos resíduos do modelo SYMARMA condicional às três famílias de distribuições analisadas.

Primeiramente confeccionou-se os gráficos de controle do tipo Shewhard. A Figura 15 abaixo compara a série tratada pelo modelo ARMA (a) e a série autocorrelacionada (b). Importante ressaltar que a tendência determinística e a sazonalidade foram extraídas

de todas as séries.



(a) Sheward - Modelo ARMA

(b) Sheward - série autocorrelacionada

Figura 15 – Gráficos de Sheward - Série tratada pelo modelo ARMA (a) e série autocorrelacionada (b).

A Figura 16 apresenta os gráficos de controle de Sheward gerados a partir dos resíduos dos modelos t -ARMA (a) e Exp -ARMA (b). Percebe-se que ambos os gráficos de controle são aparentemente iguais. Houve somente um ponto fora de controle estatístico, acima do LSC. Sendo que esse ponto é o mesmo nos dois gráficos.

Importante destacar que enquanto o gráfico de controle obtido pelo modelo ARMA apresenta dois pontos fora de controle estatístico, os gráficos de controle gerados pelos modelos t -ARMA e Exp -ARMA apresentam somente um ponto. Isso possivelmente pode ter relação com o melhor ajuste dos modelos SYMARMA, cujas distribuições condicionais possuem caldas mais pesadas que a distribuição normal, às observações atípicas do ICMS goiano.




Figura 16 – Gráficos de Shewhard - Série tratada pelo modelo t -ARMA (a) e série tratada pelo modelo ExP -ARMA (b).

O gráfico de controle CUSUM construído a partir dos dados tratados pelo modelo ARMA apresenta um processo totalmente sob controle estatístico (Figura 17 (a)). Quando não tratado os dados, o gráfico de CUSUM apresenta uma grande quantidade de pontos fora de controle estatístico (Figura 17 (b)). Muito sensível a pequenas variações, o gráfico de CUSUM acaba por gerar uma série de alarmes falsos ao ser submetidos a dados autocorrelacionados. No caso da arrecadação tributária, isso poderia levar a uma excesso de esforços desnecessários para correção do processo.




Figura 17 – Gráficos de Controle de CUSUM gerados a partir do modelo ARMA (a) e a partir da série autocorrelacionada (b)

Comparando os gráficos de controle CUSUM contruídos a partir dos modelos t -ARMA e Exp -ARMA na Figura 18 ((a) e (b), respectivamente), verifica-se processos absolutamente sob controle estatístico em ambos os casos.





Figura 18 – CUSUM - Série tratada pelo modelo t -ARMA (a) e série tratada pelo modelo Exp -ARMA (b).

Na Figura 19 (a), é possível verificar o gráfico de controle EWMA originado a partir da série tratada pelo modelo ARMA. Nesse gráfico de controle somente um ponto pode ser caracterizado como fora de controle estatístico. Por outro lado, o gráfico de controle contruído sob a mesma metodologia a partir dos dados autocorrelacionados exibe vários pontos fora de controle, como pode ser observado na Figura 19 (b).



(a) EWMA - ARMA

(b) EWMA - Série autocorrelacionada

Figura 19 – Gráficos de Controle EWMA gerados a partir do modelo ARMA (a) e a partir da série autocorrelacionada (b).

Segundo Mingoti e Yassukawa (2008) a metodologia EWMA é uma média ponderada das observações passadas e a atual e isso por si só representa um tratamento para a autocorrelação. Daí, segundo as autoras, o gráfico de controle EWMA pode ser utilizado com dados autocorrelacionados, dispensando o uso de metodologias para tratamento dos dados. Contudo, se analisar conjuntamente todos os gráficos de controle construídos neste estudo sob diversas metodologias, é possível verificar uma pequena quantidade de pontos fora de controle para a série de ICMS. Daí, sob esse ponto de vista, o gráfico de cotrole EWMA da Figura 19 (b) parece contrariar a afirmação das autoras.

O gráfico de controle EWMA originado a partir dos modelos t -ARMA e Exp -ARMA apontam para processos perfeitamente estáveis. Como pode ser verificado na Figura 20 (a), o modelo t -ARMA e Figura 20 (b), o modelo Exp -ARMA, não há qualquer ponto fora de controle estatístico. Esse resultado contrasta com o gráfico de controle exposto na Figura 18 (a) gerado a partir do modelo ARMA, onde se verifica um ponto fora de controle.


(a) EWMA - t -ARMA(b) EWMA - Exp -ARMA

Figura 20 – EWMA - Série tratada pelo modelo t -ARMA (a) e série tratada pelo modelo Exp -ARMA (b).

Os resultados apresentados neste capítulo revelam importantes características da série de arrecadação tributária de ICMS em Goiás. A identificação dos elementos presente na série em estudo levou a correta especificação dos modelos para tratamento da autocorrelação. A partir desses modelos foi possível construir gráficos de controle para monitoramento da arrecadação.

Essa série de gráficos de controle contruídos neste estudo, salvo algumas exceções, demonstram um processo de arrecadação relativamente estável com pouca necessidade de intervenção. De um modelo geral, a modelagem SYMARMA revelou-se bem ajustada para esse tipo de dados quando se analisa os gráficos de controle gerados a

partir dessa metodologia. No caso dos resíduos dos modelos t -ARMA e ExP -ARMA, verificou-se gráficos de controle muito semelhantes.

7 Conclusões

O objetivo principal deste estudo é propor o Controle Estatístico de Processos (CEP) para monitorar arrecadação tributária de ICMS do Estado de Goiás. Utilizando cartas de controle, o CEP se traduz em uma ferramenta importante para detecção de comportamentos anormais em um dado processo. Aplicado à arrecadação de ICMS, essa ferramenta pode fornecer aos gestores públicos uma sinalização no sentido de intervir para evitar variações prejudiciais aos cofres públicos.

No intuito de alcançar o objetivo proposto, a série mensal de ICMS recolhido em Goiás foi submetida a um rigoroso processo estatístico para detecção de elementos capazes de distorcer os resultados. Em séries temporais ligadas a processos econômicos, tal como arrecadação de impostos, é comum a ocorrência de tendências temporal e estocástica. No caso específico do ICMS tem-se ainda a preocupação com a sazonalidade, tendo em vista que os picos de consumo de bens e serviços afetam diretamente a arrecadação do imposto.

A autocorrelação presente em dados de séries temporais representa um elemento extremamente distorcivo para qualquer metodologia que se deseja aplicar. Para a construção de gráficos de controle para monitoramento de processos deve-se primordialmente identificar e tratar a série submetida a essa metodologia. Caso contrário, pode-se incorrer em resultados incorretos e diagnósticos falhos que demandarão esforços custosos e desnecessários.

O processo estatístico ao qual foi submetida a série de ICMS goiano indicou um processo estacionário em torno de uma tendência temporal determinística. Os dados também apresentaram um forte padrão sazonal. Esses componentes foram retirados da série por meio de regressões de mínimos quadrados ordinários (MQO).

A autocorrelação foi removida da série de ICMS por meio da modelagem SYMARMA. A suposição de normalidade dos dados exigida pelos modelos ARMA tradicionais pode, em muitos dos casos, ser violada e não levar aos resultados almejados. Por essa razão optou-se por utilizar um modelo que acomodasse melhor observações atípicas por meio de uma distribuição com caudas mais pesadas que a distribuição normal.

Por essa razão, neste estudo, a autocorrelação presente nos dados foi tratada utilizando o Modelo SYMARMA, proposto por Maior e Cysneiros (2016). Tal modelo permite o ajuste de séries temporais pertencentes à classe de distribuições simétricas. Nesse sentido, a série temporal de ICMS foi submetida à modelagem SYMARMA com distribuição condicional normal, t de Student e exponencial. Os resultados do modelo SYMARMA(1,0) condicional às três famílias de distribuições simétricas demonstraram ter eliminado a autocorrelação existente na série.

A comparação entre os gráficos de controle construídos neste estudo apresentou resultados divergentes quando se analisou os gráficos de Shewhart. A divergência apresentada está na posição em que ocorreram pontos fora de controle. O gráfico de Shewhart confeccionado a partir dos resíduos do modelo ARMA apresentou os pontos 80 e 97 fora de controle. Se se considerar os modelos t -ARMA e ExP -ARMA, apenas o ponto 60 apresentou-se como fora de controle.

Analisando os gráficos de controle de CUSUM e EWMA confeccionados a partir da série tratada pelos modelos SYMARMA, em nenhum deles houve pontos fora de controle abaixo do limite inferior de controle. Em se tratando de arrecadação tributária, pontos acima do limite superior de controle não representam preocupação para os agentes públicos. Há um consenso de que é vantajoso para o Estado que a arrecadação tributária atinja níveis cada vez mais elevados. Sob esse ponto de vista, segundo a modelagem SYMARMA, a arrecadação tributária de ICMS em Goiás apresenta um processo estável e sob controle.

Segundo o modelo ARMA, houve somente um ponto abaixo do limite inferior de controle no gráfico de Shewhart. Tal ponto corresponde ao período de janeiro de 2016. É notório que todo país passa por uma séria crise econômica que afeta o consumo de bens e serviço, consequentemente afeta o ICMS arrecadado. O mês de janeiro também é marcado por uma redução nos gastos da população em decorrência do tradicional aumento do consumo no mês anterior. Se considerarmos que a sazonalidade foi expurgada da série antes da autocorrelação ser retirada, o ponto fora de controle apontado é realmente preocupante para a arrecadação.

Ainda assim é importante levar em consideração que o modelo t -ARMA possui uma melhor metodologia para acomodar observações extremas. Por esse ponto de vista,

a observação considerada fora de controle a partir do modelo ARMA poderia ser apenas um alarme falso, visto que nos modelos t -ARMA e $ExpP$ -ARMA esse mesmo ponto está perfeitamente sob controle. Seria necessário novos estudos a partir de abordagens diferentes para que se possa determinar a acurácia dos modelos com relação à série de ICMS arrecadado em Goiás.

Os resultados revelados por meio da comparação entre as séries autocorrelacionadas e sem autocorrelação deixa claro a importância dos procedimentos para tratar a autocorrelação. Os três tipos de gráficos construídos a partir de dados autocorrelacionados apresentaram uma série de pontos fora de controle estatístico. Há autores que argumentam a favor de não tratar a autocorrelação quando se utiliza gráficos de controle que levam em conta observações passadas, tal como o do tipo EWMA. Contudo, no caso do ICMS, a autocorrelação gerou um gráfico de controle EWMA extremamente distorcido.

Se se considerar conjuntamente todos os resultados, é possível concluir que a série de arrecadação tributária de ICMS em Goiás apresenta um processo relativamente estável. Ocorreu somente um ponto fora de controle que demanda preocupação por parte dos gestores públicos. Contudo ainda há que se desenvolver melhor a metodologia SYMARMA para dar mais clareza a aquele resultado.

Para estudos futuros aponta-se uma maior aprofundamento na utilização da metodologia SYMARMA, a fim de se criar uma regra de decisão mais confiável sobre qual distribuição condicional seria adequada à série de arrecadação de ICMS em Goiás. Estudos de previsão de valores futuros poderia atender a essa finalidade.

Referências

- BENELLI, F. C. *Previsão de Receita Tributária por Base de Incidência*. 126 f. Tese (Dissertação de Mestrado) — Universidade Federal de Brasília, Brasília, 2013. 14
- BUENO, R. L. S. *Econometria de Séries Temporais*. São Paulo: Cengage Learning, 2011. 29, 31, 32
- CAMPOS, C. V. C. *Previsão de Arrecadação de Receitas Federais: Aplicações de Modelos de Séries Temporais para o Estado de São Paulo*. 133 f. Tese (Dissertação de Mestrado) — Universidade Federal de Ribeirão Preto, Ribeirão Preto, 2009. 14
- CANO, E. L.; MOGUERZA, J. M.; CORCOBA, M. P. *Quality Control with R*. New York: [s.n.], 2009. 41
- CARVALHO, G. J. *Utilização de modelo de previsão e de gráficos de controle combinados Shewhart-MMEP para a Arrecadação Média de tributos da Secretaria da Fazenda do Estado do Piauí - SEFAZ PI*. Tese (Monografia Submetida ao Curso de Estatística) — Universidade de Brasília, Brasília, 2013. 16
- CLARO, F. A. E.; COSTA, A. F. B.; MACHADO, M. A. G. Gráficos de controle de ewma e de x para monitoramento de processos autocorrelacionados. *Revista Produção Online*, v. 17, n. 3, p. 536–546, 2007. 15, 40
- CYSNEIROS, F. J. A.; PAULA, G. A.; GALEA, M. Modelos simétricos aplicados. *ABE, XI Escola de Modelos de Regressão, São Paulo*, 2005. 23, 25, 37, 38
- DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a unit rootl. *Econometrica: Journal of the Econometric Society*, JSTOR, 1981. 30
- ENDERS, W. *Applied Econometric Time Series*. New York: John Wiley & Sons, 1995. 32, 52
- ENGLE, R. F. Autoregressive conditional hetroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica: Journal of the Econometric Society*, JSTOR, 1982. 32
- FANG, K. T.; KOTZ, S.; NG, K. W. *Symmetric Multivariate and Related Distributions*. London, UK: Chapman and Hall, 1990. 34
- GIAMBIAGI, F.; ALÉM, A. C. *Finanças Públicas*. Rio de Janeiro: Elsevier, 2008. 18

GUJARATI, D. N.; PORTER, D. C. *Econometria Básica*. São Paulo: Bookman, 2011. 28, 29, 33, 50

LIMA, M. W. P. *Modelos de Previsão Aplicados no controle estatístico de processos na presença de dados autocorrelacionados*. 144 f. Tese (Dissertação de Mestrado) — Universidade Estadual de Campinas, Campinas, 2005. 15

MAIOR, V. Q. S. *SYMARMA: Um modelo dinâmico para dados temporais sob distribuição simétrica condicional*. 101 f. Tese (Dissertação de Mestrado) — Universidade Federal do Pernambuco, Recife, 2012. 54

MAIOR, V. Q. S.; CYSNEIROS, F. J. A. Symarma: a new dynamic model for temporal data on conditional symmetric distribution. *Statistical Papers*, Springer, 2016. 16, 33, 34, 35, 36, 37, 64

MENDONÇA, J. M.; MEDRANO, L. A. Um modelo econométrico para a previsão de impostos no brasil. *IPEA*, Brasília, 2011. Texto para Discussão. 14

MINGOTI, S. A.; FIDELIS, M. T. Aplicando a geoestatística no controle estatístico de processos. *Revista Produto e Produção*, Porto Alegre, v. 5, n. 2, p. 55–70, 2001. 15, 41

MINGOTI, S. A.; YASSUKAWA, F. R. S. Um estudo do comportamento dos gráficos de controle construídos via metodologia de geoestatística. In: *SIMPEP*, 2006, Baurú. *Anais...* Baurú, 2006. 15

MINGOTI, S. A.; YASSUKAWA, F. R. S. Uma comparação de gráficos de controle para a média de processos autocorrelacionados. *Revista Eletrônica Sistemas e Gestão*, v. 3, n. 1, p. 55–73, 2008. 15, 41, 43, 60

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. Wiley: [s.n.], 2009. 39, 40, 41, 43

PUIG, P. A note on the harmonic law: a two-parameter family of distributions for ratios. *Statistics & Probability Letters*, Elsevier, v. 78, n. 3, p. 320–326, 2008. 26

SILVA, L. V. *Proposta de um Modelo de Previsão de Arrecadação Tributária de ICMS no Estado de Goiás*. Tese (Monografia Submetida ao Curso de Ciências Econômicas) — Universidade Federal de Goiás, Goiânia, 2014. 14, 22

TONDOLO, C. M. *Gráficos de controle para dados do tipo taxas e proporções autocorrelacionados*. 75 f. Tese (Dissertação de Mestrado) — Universidade Federal de Santa Maria, Santa Maria, 2016. 16, 40

VANEGAS, L. H.; PAULA, G. A. Log-symmetric distributions: statistical properties and parameter estimation. *Brazilian Journal of Probability and Statistics*, Brazilian Statistical Association, v. 30, n. 2, p. 196–220, 2016. 26