



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:**
Limitações e possibilidades



ANÁLISE E PREVISÃO DO ICMS PARA O ESTADO DO RIO DE JANEIRO

ALEX DOS SANTOS VALLE - alexdsvalle@gmail.com
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO – PPGER - UFRRJ

FELIPE LEITE COELHO DA SILVA - felipeleite@ufrj.br
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO – PPGER - UFRRJ

ÁREA: 3. PESQUISA OPERACIONAL
SUBÁREA: 3.1 – MODELAGEM, SIMULAÇÃO E OTIMIZAÇÃO

RESUMO: O ICMS É O IMPOSTO COM MAIOR ARRECADAÇÃO DO ESTADO DO RIO DE JANEIRO, E A LEI DE RESPONSABILIDADE FISCAL EXIGE PREVISÃO A CADA EXERCÍCIO. ESTE TRABALHO TEM COMO OBJETIVO CONTRIBUIR COM A MELHORIA DOS MODELOS DE PREVISÃO DE ARRECADAÇÃO DE ICMS NO ESTADO. O ESTUDO COMPARA MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS PARA A ARRECADAÇÃO DE ICMS NO RIO DE JANEIRO DE 1999 ATÉ 2023. NESTE TRABALHO FORAM UTILIZANDOS OS MODELOS DE SUAVIZAÇÃO EXPONENCIAL, DE BOX-JENKINS E DEREDES NEURAI. O MODELO ARIMA SAZONAL DE BOX-JENKINS APRESENTOU A MELHOR CAPACIDADE PREDITIVA. PORTANTO, O MODELO ARIMA SAZONAL É O MAIS ADEQUADO PARA PREVISÕES FUTURAS E, ASSIM, AUXILIAR NO PLANEJAMENTO FISCAL DO ESTADO.

PALAVRAS-CHAVES: ICMS; SÉRIES TEMPORAIS; PREVISÃO

1. INTRODUÇÃO

Na última década, o Estado do Rio de Janeiro tem passado por um processo de deterioração de suas contas públicas. As consequências desse processo implicaram no não cumprimento de forma integral das políticas públicas planejadas, assim como, arrestos judiciais (Sobral, 2017). Nesse contexto, é implementado o Regime de Recuperação Fiscal, aprovada pela Lei Complementar Federal nº 159/2017, em que fornece aos Estados instrumentos de ajuste de suas contas, assim como, meios de se adequar à Lei de Responsabilidade Fiscal.

O caso mais grave em relação a Lei de Responsabilidade Fiscal ocorre quando a Receita Líquida Corrente anual é maior que a dívida líquida consolidada do exercício anterior, o total de suas despesas com pessoal, juros e amortização seja igual ou maior que 70% da receita líquida corrente e o valor das obrigações seja maior que a disponibilidade de caixa. Um Estado é apto a entrar no Regime de Recuperação Fiscal tendo atingido esses três critérios.

Sobral (2017) afirma que o processo de recuperação tem que ser feito de forma sustentada. Nesse sentido, uma política que apenas vise o corte de gastos poderá ter um efeito reverso do planejado pela Recuperação Fiscal. A arrecadação tem característica pró-cíclica, no qual momentos adversos irão impactar significativamente o quanto o Estado irá arrecadar de forma negativa. Logo, uma política que vise cortes poderá intensificar essa recessão.

O Imposto sobre a Circulação de Mercadorias e Serviços (ICMS) é o principal imposto de arrecadação estadual compondo as receitas tributárias da economia fluminense (SEFAZ, 2024). Ele é a principal fonte de recursos que faz parte da composição dos orçamentos públicos através da captação da produção e utilização de serviços. Esse imposto é previsto pelo inciso II, do artigo 155 da Constituição Federal e instituído pela Lei Complementar 87, de 13 de setembro de 1996, no qual tem suas definições gerais e como são suas aplicações (Brasil, 1988; 1996). Seus recursos não são repassados para União, sendo utilizados no próprio Estado e com transferências para os municípios (Soares et al. 2011).

A Lei de Responsabilidade Fiscal exige que os entes da Federação devam divulgar suas previsões orçamentárias, através do §1º artigo 4. Uma previsão acurada sobre os impostos permite um planejamento mais adequado de como os recursos serão alocados. Logo, o objetivo deste trabalho será realizar uma análise exploratória e comparar modelos de previsão para arrecadação do ICMS para o Estado do Rio de Janeiro, no período de janeiro de 1999 a dezembro de 2023.

O artigo possui cinco sessões em que a primeira é esta introdução, a segunda será apresentada a revisão de literatura sobre os métodos de previsões aplicados a impostos. A

terceira são os materiais e métodos de construção deste artigo. O quarto será apresentado os resultados e sua discussão e, por fim, a quinta sessão que se destina às considerações finais.

2. REVISÃO BIBLIOGRÁFICA

Nesta seção serão apresentados alguns trabalhos relacionados as receitas tributárias no Brasil. Existem diversos trabalhos tratando sobre previsões fiscais, dada a importância do tema. Durante a revisão é possível observar o processo de tentativa do melhor ajuste dos modelos para minimizar o desvio entre o previsto e o real, ou seja, um melhor poder de previsão.

Azevedo et al. (2019) buscaram realizar a previsão de ICMS de São Paulo (SP), Minas Gerais (MG), Rio de Janeiro (RJ), Rio Grande do Sul (RS), Paraná (PR) e a Bahia (BA) no período anual 1995 a 2011, através da estimação de um modelo de séries temporais ARIMA para verificar se o modelo apresenta resultados mais precisos do que os utilizados pela gestão dos Estados. Os autores compreenderam que o modelo apresenta uma melhor acurácia para todos os Estados analisados.

O ICMS do estado do Rio Grande do Sul foi previsto utilizando os modelos de Box-Jenkins com base nos dados mensais de 1997 a 2014, no qual foi verificado que o melhor modelo foi o $SARIMA(0,1,1)(0,1,1)_{12}$ (Scheffer et al. 2014). A mesma metodologia foi aplicada por Clemente e Clemente (2011) para a previsão fiscal de estado do Paraná. Os autores identificaram que o modelo $SARIMA(2,1,0)(0,1,1)_{12}$ apresentou a melhor capacidade preditiva. Chain et al. (2015) aplicaram a metodologia de Box-Jenkins para previsão do ICMS do estado de Minas Gerais. Devido aos eventos diferentes do padrão histórico da série, o modelo $SARIMA(1,1,1)(1,1,1)_{12}$ apresentou o melhor desempenho.

Carmo et al. (2019) utilizaram os modelos de redes neurais para previsão do ICMS do estado do Espírito Santo, através de dados mensais entre 2000 a 2018. Os resultados deste estudo apontaram que o método de rede neural apresentou resultados satisfatórios para previsão do ICMS.

Goncalves Júnior et al. (2021) utilizaram os modelos de amortecimento exponencial para a previsão de receitas tributárias dos estados do Rio de Janeiro, São Paulo, Minas Gerais e Espírito Santo. Exceto o estado do Espírito Santo, os demais estados da região sudeste apresentaram melhores resultados com o modelo Holt Winters.

No quesito internacional, Leal et al. (2007) fazem uma revisão de literatura sobre os modelos de previsão fiscal. O tema é abordado principalmente através do Tratado de Maastricht e o Pacto de Estabilidade e Crescimento que trouxe a questão orçamentária multilateral. Os

autores destacam que o processo decisório e as formas de mensuração são os principais desafios no processo de modulação da previsão. Dos modelos verificados, se destacam o uso da ARIMA, Vetores Autorregressivos, Equações Simultâneas e o Forecast Pooling, utilizando dados semestrais de 1981 a 2001, para variáveis fiscais e macroeconômicas para a Zona do Euro em 2002. Os resultados indicaram que determinados modelos obtiveram os melhores resultados de acordo com o país, pelo Erro Quadrado Médio de Previsão.

Na Tabela 1 têm-se de forma resumida a abordagem dos trabalhos citados e de outros trabalhos analisados.

TABELA 1: Resumo dos trabalhos estudados

Referência	Modelo	Tipo de dados	Período	Estado
Azevedo et al. (2017)	ARIMA	Anual	1995-2011	SP, MG, RJ, RS, PR e BA.
Cruz (2007)	ARMA	Mensal	1996-2006	PI
Scheffer et al. (2014)	ARIMA e SARIMA	Semestral	1997-2014	RS
Chain et al. (2015)	ARIMA e SARIMA	Mensal	1998-2011	MG
Gonçalves Júnior et al. (2021)	Holt Winter	Mensal	2010-2017	RJ, SP, MG, ES
Carmo et al. (2019)	Rede Neural, Theta, Holt, ARIMA	Mensal	2000-2018	ES
Clemente e Clemente (2011)	ARIMA	Mensal	2000-2011	PR
Pessoa et al. (2011)	ARIMA e ARFIMA	Mensal	1998-2011	MG

Fonte: Elaboração própria.

3. MATERIAIS E MÉTODOS

Neste trabalho foram utilizados os dados mensais de arrecadação de ICMS para o Estado do Rio de Janeiro de janeiro de 1999 até dezembro de 2023, disponibilizados pela Secretaria de Fazenda do Estado do Rio de Janeiro (SEFAZ). A série temporal do ICMS foi dividida em dois conjuntos, sendo treino e teste. O conjunto de treino foi definido entre janeiro de 1999 até dezembro de 2022; e o conjunto de teste sendo de janeiro de 2023 até dezembro de 2023. Em seguida, foram ajustados os modelos de suavização exponencial, ARIMA sazonal, redes neurais

autorregressivas (NNAR) e o modelo ingênuo sazonal a série temporal do conjunto de treinamento.

Finalmente, através dos modelos ajustados foram realizadas as previsões para os meses de 2023. Para verificar acurácia dos modelos foram utilizadas as métricas do erro médio absoluto percentual (MAPE) e a raiz do erro quadrático médio (RMSE).

A estrutura do modelo ARIMA sazonal (SARIMA) de Box-Jenkins de ordem $(p,d,q) \times (P,D,Q)_s$ é dada por

$$\varphi(B)\Phi(B^s)\nabla^d\nabla_s^D Y_t = \theta(B)\Theta(B^s)a_t$$

em que $\varphi(B)$ é o operador autorregressivo de ordem p ; $\theta(B)$ é o operador de médias móveis de ordem q ; $\Phi(B^s)$ é o operador autorregressivo sazonal de ordem P ; $\Theta(B^s)$ é o operador de médias móveis sazonal de ordem Q ; ∇^d é o operador da diferença simples e; ∇_s^D é o operador da diferença sazonal; a_t é um ruído branco.

O modelo de suavização exponencial foi obtido a partir algoritmo ETS proposto por Hyndman et al. (2008).

O modelo de redes neurais autorregressivas, $NNAR(p, P, k)_m$, adotado neste trabalho leva em consideração uma rede feedforward com uma única camada oculta, p entradas, k nós na camada oculta, P defasagens sazonais e m períodos (HYNDMAN; ATHANASOPOULOS, 2018; VELOZ et al., 2016).

Os modelos ingênuos realizam a previsão para o instante seguinte através do valor imediatamente anterior, sem fazer nenhuma suposição sobre o comportamento da série. O método ingênuo sazonal repete as observações do último período sazonal para todos os próximos períodos.


As análises estatísticas foram desenvolvidas utilizando a linguagem de programação R (R CORE TEAM, 2022).

4. RESULTADOS E DISCUSSÃO

4.1 Análise Exploratória

Na figura 1 é apresentada a evolução da arrecadação do ICMS no ERJ. É possível notar que além da trajetória ascendente, ocorre um processo de sazonalidade ao longo do tempo (FIGURA 1 (a)). A figura 1 (b) mostra a trajetória anual da arrecadação do ICMS através do gráfico de boxplot. Pode-se observar nesta figura variabilidade para o ano de 2020.

FIGURA 1: Arrecadação e tendência ao longo do tempo




Fonte: Elaboração própria a partir dos dados da SEFAZ (2024).

Ribeiro et al. (2020) analisaram quais as elasticidades dos setores têm maior impacto na arrecadação do ICMS do ERJ. Foi concluído que o setor terciário tem a maior elasticidade em relação aos demais, seguido pelo setor secundário, de petróleo e energia. Com isso, é possível notar as variabilidades da arrecadação ao longo do tempo por conta de grandes eventos e a pandemia da COVID-19. Esse movimento do setor terciário, reflete na sazonalidade encontrada na arrecadação (Figura 2), por conta dos períodos do ano que o comércio está aquecido. Esse argumento foi reforçado por Matos et al. (2017) indicando que a área de serviços tem apresentado uma maior importância ao longo dos anos.

Barcelos e Santos (2018) afirmam que outro ponto que afetou a arrecadação no período tratado foram as “guerras fiscais” que ocorrem a partir de 2004. Esse termo foi cunhado para estabelecer o momento em que os Estados passaram a diminuir sua alíquota para atrair as empresas de outras regiões. Em 2005, foi criada a Lei Nº 4533/2055, conhecida como “lei Rosinha” que reduziu a alíquota de 15% para 2% caso se instalassem em determinados municípios do ERJ, principalmente no Noroeste Fluminense esvaziado pelos vizinhos, dado os incentivos fiscais na época. Se observado o ano de 2005 na figura 1, é possível notar que apesar do aumento da arrecadação em relação ao ano anterior, permanece os valores em torno da mediana similares ao ano anterior. Essa lei foi revogada em 2010 pela Lei Nº5636/2010, conhecida como “Lei Cabral”. Ao observar esse período, nota-se o salto da arrecadação do ano

de 2009 para 2010. O aumento exponencial de arrecadação em 2013 é atribuído principalmente a performance do setor de petróleo e gás, devido a performance da Petrobrás (SEFAZ, 2024).


FIGURA 2: Distribuição da arrecadação do ICMS concatenada em meses.



Fonte: Elaboração própria a partir dos dados da SEFAZ (2024).

Para melhor verificar esse processo de tendência e sazonalidade pode se utilizar o método de decomposição STL (*Seasonal and Trend Decomposition using Loess*). O método separa a série temporal em componentes com tendência, sazonalidade e resíduo. A figura 3 mostra a decomposição STL. O componente de tendência mostra a evolução da arrecadação ao longo dos anos confirmando que a arrecadação vai aumentando ao longo do tempo. A série possui uma sazonalidade bem clara que fica destacado quando se é decomposto pelo gráfico da figura 3. O gráfico do erro demonstra fatores da economia fluminense que afetaram sua arrecadação, pode se notar que a década de 2010 possui uma instabilidade maior que a década anterior devido a crise fiscal característica da economia fluminense e que ela foi afetada profundamente pela pandemia da covid-19.


FIGURA 3 - Decomposição da série temporal em STL da arrecadação de ICMS



Fonte: Elaboração própria a partir dos dados da SEFAZ (2024).

A figura 4 mostra a autocorrelação da arrecadação de ICMS durante o período tratado e nela podemos ratificar como que determinadas políticas públicas terão seu impacto ao longo do tempo, transmitindo tendência e sazonalidade como já foi tratada acima. Os anos que possuem correção alta, são períodos que ocorreram grandes eventos no Estado, como jogos Pan Americanos e Olimpíadas, alteração de políticas tributárias e aumento da performance da Petrobrás devido ao pré-sal.

FIGURA 4 - Correlação entre os anos da série



Fonte: Elaboração própria a partir dos dados da SEFAZ (2024)

4.2 Modelos De Previsão

A tabela 3 apresenta as métricas de comparação entre os modelos de previsão aplicados propostos nesse trabalho. Ao avaliar as métricas, o modelo ARIMA sazonal possui a melhor performance quando avaliado o MAPE e RMSE da série Teste. Matos et al. (2017), afirmam que o ERJ apresenta métricas de erro de previsão maior do que ocorre em outros Estados.


A série de Treino, os melhores resultados ficam com o modelo de suavização exponencial (MAPE) e rede neural (RMSE). A Figura 5 ilustra o ajuste ao longo da série e demonstra o quão distante é o modelo Ingênuo Sazonal e quão próximo estão os demais modelos.

TABELA 3 - Acurácia dos modelos

Modelo	ME		MAPE (%)		RMSE	
	Treino	Teste	Treino	Teste	Treino	Teste
Ingênuo Sazonal	133,60	-81,13	10,47	10,30	310,66	422,16
ARIMA	-0,06	15,91	6,35	5,17	204,96	232,06
Suavização Exponencial	11,34	-104,21	5,66	5,67	191,70	238,11
NNAR	-0,05	71,14	5,88	7,22	185,81	320,77

Fonte: Elaboração própria a partir dos dados da SEFAZ (2024).

FIGURA 5 - Comparação entre os modelos de previsão e os dados reais.



Fonte: Elaboração própria a partir dos dados da SEFAZ (2024).


Na tabela 4 temos os valores previstos de cada modelos para o ano de 2023. Os modelos possuem uma dificuldade em captar as sazonalidades apontadas na figura 2, como pode ser observado pelas diferenças nos meses de janeiro, fevereiro, outubro e dezembro. O modelo ARIMA é o que possui as menores diferenças apontado pelo erro.

TABELA 4 - Previsão mensal para o ano de 2023

	2023	Suavização Exponencial		Ingênuo Sazonal		ARIMA		Rede Neural	
		Previsão	Erro	Previsão	Erro	Previsão	Erro	Previsão	Erro
Janeiro	3.696.813	4.136.276	-439.463	4.271.780	-574.967	3.622.747	74.066	3.270.868	425.945
Fevereiro	3.162.944	3.603.488	-440.544	3.560.807	-397.863	3.510.285	-347.341	3.472.536	-309.592
Março	3.454.230	3.555.985	-101.755	3.291.941	162.289	3.492.928	-38.698	3.380.302	73.928
Abril	3.831.171	3.621.509	209.662	4.061.596	-230.425	3.671.449	159.722	3.576.049	255.122
Mai	3.240.412	3.542.839	-302.427	3.687.723	-447.311	3.550.137	-309.725	3.659.940	-419.528
Junho	3.604.080	3.510.097	93.983	4.030.345	-426.265	3.689.833	-85.753	3.713.230	-109.150
Julho	3.473.281	3.579.376	-106.095	3.508.191	-34.910	3.556.415	-83.134	3.722.683	-249.402
Agosto	3.471.218	3.588.921	-117.703	3.334.692	136.526	3.496.812	-25.594	3.678.804	-207.586
Setembro	3.588.625	3.719.912	-131.287	4.197.399	-608.774	3.718.731	-130.106	3.818.829	-230.204
Outubro	4.009.857	3.737.614	272.243	3.329.205	680.652	3.510.985	498.872	3.704.009	305.848
Novembro	3.771.010	3.816.857	-45.847	3.529.163	241.847	3.562.351	208.659	3.729.725	41.285
Dezembro	3.788.191	3.929.446	-141.255	3.262.555	525.636	3.518.204	269.987	3.675.198	112.993

Fonte: Elaboração própria a partir dos dados da SEFAZ (2024).

FIGURA 6 - Previsão média para cada modelo



Fonte: Elaboração própria a partir dos dados da SEFAZ (2024)

5. CONSIDERAÇÕES FINAIS

O presente artigo apresenta uma análise e previsão da arrecadação de ICMS para o Estado do Rio de Janeiro no período de janeiro de 1999 até dezembro de 2023. Foram utilizados os modelos de suavização exponencial, ARIMA sazonal, redes neurais autorregressivas e o ingênuo sazonal. A série temporal de ICMS evoluiu ao longo dos anos, destacando a importância dos setores econômicos e eventos específicos que impactaram a arrecadação.

Os resultados indicam que o modelo ARIMA sazonal teve a melhor performance em termos de MAPE e RMSE na série teste, enquanto os modelos de suavização exponencial e de redes neurais autorregressiva mostraram bons resultados na série de treino. A análise também

revela a dificuldade dos modelos em capturar todas as sazonalidades específicas em meses como janeiro, fevereiro, outubro e dezembro.

Através da decomposição STL, foi possível confirmar a tendência ascendente e a sazonalidade clara na arrecadação de ICMS, além de identificar períodos de instabilidade devido a fatores econômicos e eventos como o da COVID-19.

A análise de impactos de políticas públicas emergentes oferece insights valiosos para a gestão fiscal do Estado, pois permitem oferecer uma ferramenta que pode auxiliar na melhor arrecadação de recursos públicos. A aplicação de diferentes modelos de previsão e a comparação detalhada entre eles proporcionam uma visão abrangente de melhores práticas de previsões fiscais.

Para futuras pesquisas, sugere-se explorar outros modelos, como o MLP e alternativas híbridas que possam captar variáveis exógenas que possam influenciar a arrecadação de ICMS.

6. REFERÊNCIAS

AZEVEDO, R. R. D.; SILVA, J. M. D.; GATSIOS, R. C. **Análise crítica dos modelos de previsão de série temporal com base no ICMS Estadual**. Revista de Gestão, Finanças e Contabilidade, Salvador, v. 7, n. 1, p. 98-115, 2017. Disponível em: <https://www.revistas.uneb.br/index.php/financ/article/view/2563>.

BARCELOS, Daniel Ribeiro; SANTOS, Leandro Bruno. **Política de isenção fiscal e dinâmica econômica no Estado do Rio de Janeiro nos anos 2010**. Revista Cerrados, [s. l.], v. 16, n. 02, p. 189-212, 2018. DOI: 10.22238/rc2448269220181602189212. Disponível em: <https://www.periodicos.unimontes.br/index.php/cerrados/article/view/1261>.

BRASIL. **Lei complementar n. 87, de 13 de setembro de 1996**. Dispõe sobre o imposto dos Estados e do Distrito Federal sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação, e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, DF, 16 set. 1996. Seção 1, p. 18261.

CARMO, M. D.; BOLDT, F.; KOMATI, K. **Previsão de receitas de ICMS do Estado do Espírito Santo através de seleção de características em cascata e técnicas de aprendizado de máquina**. In: Anais do Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 16, Salvador. Sociedade Brasileira de Computação, 2019. p. 118-129. ISBN 2763-9061. Disponível em: <https://doi.org/10.5753/eniac.2019.9277>.

CHAIN, C. P. et al. **Contribuição da modelagem de valores atípicos na previsão da arrecadação do ICMS do Estado de Minas Gerais**. Exacta, São Paulo, v. 13, n. 2, p. 239-249, 2015. Disponível em: <http://www.redalyc.org/articulo.oa?id=81043159010>.

CLEMENTE, A. E.; CLEMENTE, L. T. **Aplicação da metodologia box-jenkins para previsão do ICMS do estado do Paraná de agosto de 2011 a julho de 2012**. Revista

Economia & Tecnologia, Curitiba, v. 7, n. 4, 2011. ISSN 2238-1988. Disponível em: <https://revistas.ufpr.br/ret/article/view/25910>.

GONÇALVES JÚNIOR, G. A.; FEHR, L. C. F. A.; RODRIGUES, R. S. **Previsão do ICMS nos estados da região sudeste: Utilização do modelo sazonal simples e holt-winter**. Revista Brasileira de Administração Científica, São Paulo, v. 12, n. 4, p. 432-440, 2021. Disponível em: <http://doi.org/10.6008/CBPC2179-684X.2021.004.0030>.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. Melbourne: OTexts, 2018.

HYNDMAN, R.; KOEHLER, A.; ORD, K.; SNYDER, R. **Forecasting with exponential smoothing: The state space approach**. 2008.

LEAL, T. et al. **Fiscal forecasting: Lessons from the literature and challenges**. Working Paper Series, European Central Bank, Frankfurt am Main, Germany, n. 843, 2007. Disponível em: <https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp843.pdf>.

MATOS, Vinícius da Silva; CRUZ, Yuri Fernandes da; CRUZ, Claudia Ferreira; BUFONI, André Luiz. Análise da eficácia dos processos relacionados à arrecadação do ICMS no Estado do Rio de Janeiro. In: **VIII Congresso Brasileiro de Administração e Contabilidade - AdCont 2017**, 19-21 out. 2017, Rio de Janeiro, RJ. Rio de Janeiro: AdCont, 2017.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna: R Foundation for Statistical Computing, 2022. Disponível em: <https://www.R-project.org/>.

REPÚBLICA FEDERATIVA DO BRASIL. **Constituição (1988)**. Senado Federal. Disponível em: https://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm.

RIBEIRO, Alessandra Oliveira et al. **Arrecadação de ICMS do Estado do Rio de Janeiro: A elasticidade dos setores econômicos e seu uso na melhora da situação fiscal e financeira do Estado**. Brazilian Journal of Development, v. 6, n. 4, p. 36352-36358, 2020. DOI: 10.34117/bjdv6n4-241. Recebido em: 10 mar. 2020.

SCHEFFER, D.; SOUZA, A. M.; ZANINI, R. R. **Utilização de modelos ARIMA para previsão da arrecadação de ICMS do estado do Rio Grande do Sul**. In: Anais do XVII Simpósio de Pesquisa Operacional e Logística da Marinha (SPOLM), São Paulo: Blucher, 2014. p. 734-745. ISBN 2175-6295.

SECRETARIA DA FAZENDA DO ESTADO DO RIO DE JANEIRO. **Site da secretaria da fazenda do estado do rio de janeiro**. Disponível em: <http://www.fazenda.rj.gov.br>. Acesso em: 10 jun. 2024.

SOARES, M.; GOMES, E. D. C. O.; TOLEDO FILHO, J. R. D. **A repartição tributária dos recursos do ICMS nos municípios da região metropolitana de Curitiba**. Revista de Administração Pública, Rio de Janeiro, v. 45, n. 2, p. 459-481, 2011. Disponível em: <https://doi.org/10.1590/S0034-76122011000200008>.

SOBRAL, B. L. B. **A crise no Estado do Rio de Janeiro entendida não apenas como uma questão financeira / the rio de janeiro state' crisis understood not only as a financial**

issue. Geo UERJ, Rio de Janeiro, n. 31, p. 34-63, 2017. Disponível em: <https://www.e-publicacoes.uerj.br/geouerj/article/view/32056>.

VELOZ, A.; SALAS, R.; ALLENDE-CID, H.; ALLENDE, H.; MORAGA, C. **Identification of lags in nonlinear autoregressive time series using a flexible fuzzy model.** Neural Process. Lett., v. 43, p. 641–666, 2016.