



Governo do Estado do Rio de Janeiro  
Secretaria de Estado de Fazenda  
Subsecretaria Adjunta de Política Fiscal

## NOTA TÉCNICA SUBPOF/SEFAZ-RJ Nº 07/2023

**ASSUNTO:** Metodologias e premissas das Receitas da LDO 2024.

Rio de Janeiro, 27 de março de 2023

### I - OBJETIVO

Apresentar metodologia e premissas utilizadas nas estimativas das receitas da UGE 9999 – Tesouro do Estado do Rio de Janeiro - referentes aos exercícios de 2024, 2025 e 2026.

### II - EMBASAMENTO LEGAL

Artigo 3º do Decreto nº 48.382 de 03 de março de 2023, que dispõe sobre a elaboração do Projeto de Lei das Diretrizes Orçamentárias para 2024 (PLDO 2024).

### III - INTRODUÇÃO

O desempenho da arrecadação tributária do Estado do Rio de Janeiro – ERJ, no período entre 2014 e 2020, pode ser descrito como baixo, em particular se tomarmos como base o período anterior à crise econômica instaurada no Brasil em 2014. A crise econômica que assolou todo país teve os efeitos percebidos, sobretudo, no Estado do Rio de Janeiro. Entre 2014 e 2017, o crescimento médio anual da arrecadação nominal alcançou 3,2%, muito aquém do registrado no período que antecedeu a recessão econômica.

O gráfico 1 abaixo mostra a evolução do ingresso das principais receitas públicas do ERJ entre 2019 e 2022. Após alguns anos de relativa estabilidade das receitas de imposto sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual, intermunicipal e de comunicação -ICMS e Fundo Estadual de Combate à Pobreza e às Desigualdades Sociais -FECF, em 2019 a arrecadação atingiu um patamar mais elevado, mas influenciado pela entrada de recursos extraordinários, como as receitas de REFIS e as relacionadas ao REPETRO. Em 2020, foi registrado novamente significativo valor de receitas extraordinárias, como a internalização do Convênio ICMS 51/2020, totalizando R\$ 2,6 bilhões em recursos não recorrentes. Este ingresso permitiu que, mesmo com o advento da pandemia de COVID-19, e consequente queda na arrecadação devido a redução da atividade econômica, o ERJ tivesse aumento de 5,0% em sua arrecadação de ICMS e FECF em 2020.

O ano de 2021 foi marcado por uma série de fatores favoráveis ao aumento da arrecadação tributária no Estado, que registrou alta nominal de 21,8% em relação ao ano anterior. Este aumento foi

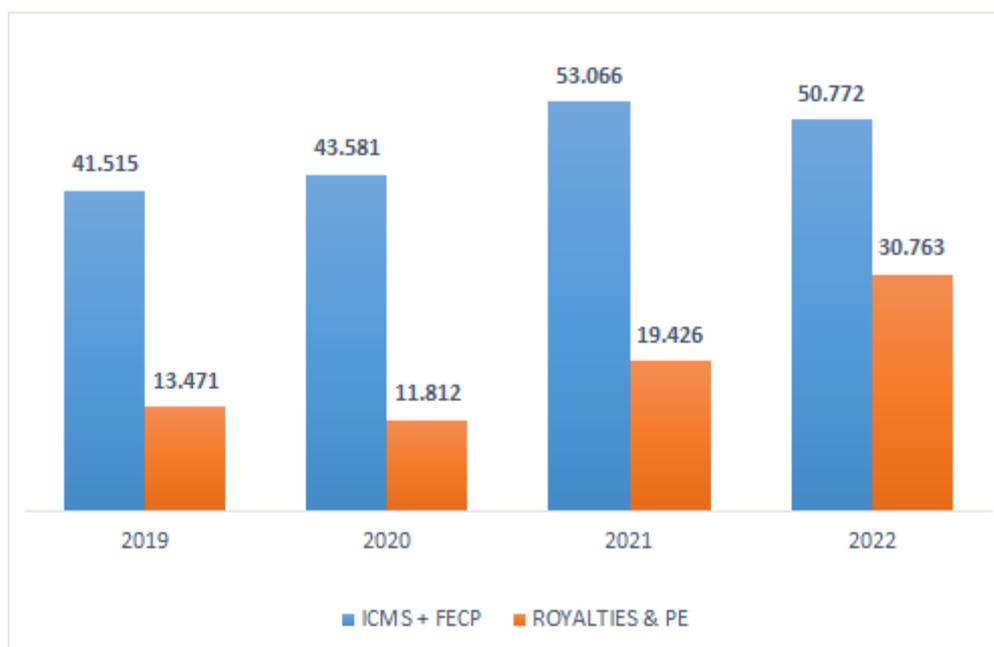
causado, principalmente, por três fatores: pela recuperação econômica em relação ao ano anterior, após a flexibilização das medidas restritivas e volta a normalidade com o gradual andamento das campanhas de vacinação; o aumento generalizado de preços, em especial e maior magnitude sobre produtos com alta incidência de ICMS, como petróleo e seus derivados, e energia elétrica; e o sucesso do Programa Especial de Parcelamento de Créditos Tributários (PEP-ICMS), que influenciou consideravelmente o ingresso de recursos relacionados ao ICMS em 2021.

Por outro lado, em 2022, a partir de julho/agosto, a arrecadação de ICMS sofreu um impacto negativo advindo da aprovação da Lei Complementar 194/2022, que definiu os combustíveis, a energia elétrica, as comunicações e o transporte coletivo como bens essenciais e, portanto, reduzindo as alíquotas para o teto entre 17% e 18%. A queda nominal verificada no gráfico em 2022 só não foi maior em virtude dos impactos estarem restritos ao 2º semestre de 2022, além do crescimento econômico verificado em outros setores não atingidos pela referida Lei.

Portanto, o comportamento das receitas de ICMS e FECP nos últimos anos está, em grande parte, relacionado a questões não recorrentes, como os efeitos temporários e específicos do aumento de preços em segmentos importantes de arrecadação e o REFIS. No entanto, se grande parte do ganho está relacionada a questões conjunturais/específicas, as perdas decorrentes da LC nº 194/2022 são estruturais, isto é, diminuem significativamente o potencial arrecadatório dos estados a partir das reduções de alíquotas em segmentos importantes para a arrecadação.

As receitas de Royalties e Participações Especiais-R&PE, a partir de 2021, registraram bom desempenho com a recuperação do preço internacional do petróleo e a mudança de patamar do câmbio. Ressalta-se que, em 2021, a produção permaneceu estável em relação ao ano anterior, mas o preço em reais (Brent x câmbio), impulsionado pela variação positiva das duas variáveis, fez a arrecadação de R&PE chegar a quase R\$ 20 bilhões. No caso de 2022, registra-se ainda um aumento da produção de óleo e gás no ERJ, além de um preço internacional que atingiu o valor médio de US\$ 100. Mantido o câmbio no mesmo patamar de 2021, tem-se uma arrecadação recorde de R&PE. No entanto, registra-se que o comportamento positivo das três variáveis que explicam o ingresso dessas receitas é bastante incomum quando analisadas conjuntamente, motivo que requer cautela em relação ao ingresso dessas receitas já em 2023.

Gráfico 1 - Arrecadação de ICMS+ FECP e R&PE - R\$ (em milhões):



O gráfico acima demonstra, de forma simplificada, um dos principais desafios para o Estado, em especial no curto prazo: a volatilidade de suas receitas conjunturais associada ao novo patamar (inferior) de suas receitas estruturais. A volatilidade da receita de R&PE é um dos fatores de risco para a manutenção do equilíbrio fiscal do Estado, visto que fatores externos, como o preço do Brent, não estão

sob controle do poder público estadual e influenciam diretamente este resultado. Em relação as receitas estruturais, medidas como o PEP-ICMS (REFIS) possuem efeitos no curto prazo, mas não geram mudanças estruturais para o aumento da arrecadação tributária no longo prazo. Na mesma direção, os ganhos relacionados ao aumento temporário da inflação também não se sustentam de forma permanente.

Em um cenário de manutenção da LC nº 194/2022 e preço internacional do petróleo com viés de queda, o ano de 2023 apresenta diversos desafios para o ERJ - exigindo, portanto, cautela na formação do cenário fiscal, pelo lado das receitas, para os próximos exercícios.

## **IV - METODOLOGIA EMPREGADA**

### **IV.I - Estratégia Metodológica Adotada na Previsão das Receitas Tributárias**

Para realizar a projeção das receitas tributárias concernente ao período de 2024 a 2026, foram utilizados dois modelos de previsão: o Modelo ARIMA com variável exógena e o Modelo Híbrido. Para o ano de 2023, vale a metodologia empregada na 2ª Revisão de Receita, conforme processo SEI-040076/000005/2023. Desse modo, descreve-se a metodologia de forma mais detalhada para prever o ICMS, IPVA e o ITD para os exercícios seguintes no Anexo I.

A previsão de ICMS, para o ano de 2024 a 2026, foi aplicado um modelo SARIMA, que utiliza uma matriz de regressores externos, com o mesmo número de observações que a série univariada objeto de previsão. Para tal, foram utilizados como variáveis externas o Índice de Atividade Econômica (IBC-BR) e a taxa de câmbio real.

Para realizar a previsão do Imposto sobre a Propriedade de Veículos Automotores (IPVA) e do Imposto de Transmissão Causa Mortis e Doação (ITD), para os anos de 2024 a 2026, foi aplicado um modelo Híbrido que combina alguns modelos, inclusive o ARIMA. Na previsão da receita de IPVA, foi ainda utilizado como variável externa o Índice de Atividade Econômica (IBC-BR); no ITD, foi apenas o Híbrido univariado (sem variáveis explicativas ou independentes).

### **IV.I.2. Previsão das Receitas Tributárias**

#### **IV.I.2.1. ICMS**

O ICMS é a principal fonte de Receita do Estado do Rio de Janeiro. A arrecadação depende do nível da atividade econômica e está, por conseguinte, relacionada à produção de bens e serviços no contexto nacional e regional. O imposto foi estimado inicialmente em R\$ 44,15 bilhões para 2024. Para os anos de 2025 e 2026, a arrecadação de ICMS foi estimada em R\$ 45,17 bilhões e R\$ 47,18 bilhões, respectivamente. Cabe salientar que foram deduzidos da previsão de ICMS os impactos advindos de benefícios fiscais em fase de aprovação (portanto ainda não tem impacto sobre a arrecadação realizada, exigindo a dedução), conforme Nota Técnica SUBPOF/SEFAZ-RJ Nº 43/2022, estimados na ordem de R\$ 364 milhões em 2024, R\$ 375 milhões em 2025 e R\$ 375 milhões em 2026. Portanto, o valor final de previsão de ICMS em 2024, 2025 e 2026, será de R\$ 43,79 bilhões, 44,80 bilhões e R\$ 46,80 bilhões, respectivamente.

As previsões para a arrecadação de ICMS foram realizadas a partir do modelo descrito na seção anterior. Cabe ressaltar que as previsões desse tributo não consideraram as receitas extraordinárias<sup>[1]</sup>, visto que as mesmas não são de caráter permanente e, portanto, poderiam superestimar as previsões realizadas.

#### IV.I.2.2. FECP

O FECP é um adicional de 2% ao ICMS cobrado por força de lei. O tributo foi prorrogado pela Lei nº 8643/2019 até 31 de dezembro de 2023., mas foi mantida a sua estimativa de arrecadação dada a recorrência de sua prorrogação.

Para o ano de 2024, estima-se a arrecadação de R\$ 5,42 bilhões, e para os anos seguintes, R\$ 5,54 bilhões e R\$ 5,79 bilhões, respectivamente. O FECP tem a mesma base de cálculo do ICMS, diferindo em alguns pontos. Desta forma, optou-se por simplificar a previsão do FECP e utilizar a previsão já obtida do ICMS como base geradora do comportamento do FECP - isto é, foi aplicado o mesmo fator de crescimento observado no ICMS.

#### IV.I.2.3. IPVA

O IPVA é um tributo de competência estadual, cujo fato gerador é a propriedade de veículos automotores. O referido imposto é lançado anualmente, devendo ser recolhido, no Estado do Rio de Janeiro, nas datas estabelecidas em calendário publicado pela SEFAZ.

Estimou-se a arrecadação com base em modelos estatísticos reconhecidos. Para 2024 projeta-se a Receita de R\$ 4,02 bilhões; já em 2025 e 2026 prevê-se R\$ 4,17 bilhões e R\$ 4,32 bilhões, respectivamente. As previsões para o IPVA foram realizadas com base no modelo híbrido com Índice de Atividade Econômica do Banco Central do Brasil (IBC-BR), apresentado na seção anterior, e detalhado no Anexo I.

#### IV.I.2.4. ITD

O ITCMD incide sobre a transmissão de qualquer direito, bem imóvel ou bem móvel havido por sucessão legítima ou testamentária e por doação, ou seja, de natureza não onerosa.

Para os anos de 2024, 2025 e 2026 foi projetada arrecadação de R\$ 1,70 bilhão, R\$ 1,80 bilhão e R\$ 1,91 bilhão, respectivamente. As previsões de ITD foram realizadas com base no modelo híbrido apresentado na seção anterior e detalhado no Anexo I.

#### IV.I.2.5. IRRF

Diferentemente dos outros tributos, cuja arrecadação está mais próxima do comportamento de atividade econômica, o IRRF está mais associado ao retrospecto da folha de pagamentos do ERJ, isto é, é diretamente proporcional ao comportamento da despesa de pessoal.

Para os anos de 2024, 2025 e 2026 foi projetada arrecadação de R\$ 7,20 bilhões, R\$ 7,60 bilhões e R\$ 8,02 bilhões, respectivamente.

#### IV.I.2.6. Outras Receitas Tributárias e Correntes

As receitas apresentadas a seguir foram estimadas por métodos não lineares, baseados em informações obtidas nos setores especializados e por um fator de crescimento baseado nos parâmetros macroeconômicos da LDO 2024.

- **Dívida Ativa** – R\$ 585 milhões em 2024 - A dívida ativa é constituída de débitos de contribuintes

com a Fazenda não adimplidos consoante prazos definidos na legislação vigente, dividindo-se em tributárias e não tributárias. Os parâmetros macroeconômicos da LDO 2024 balizaram a previsão para o triênio 2024 - 2026, adotando no ano-base (2023) as estimativas da 2ª Revisão de Receita. Para 2025 e 2026, a previsão do estoque da dívida ativa do ERJ ficou em R\$ 617 milhões e R\$ 652 milhões, respectivamente. O fator de crescimento para esta rubrica de receita considera a variação real do PIB nacional estimada para cada ano, assim como o IPCA - ambos de acordo com o Boletim Focus de 03/03/2023.

- **Multas e Juros** – R\$ 601 milhões em 2024 - A previsão da receita de multas e juros para 2024 está em linha com a expectativa de pagamento de débitos considerada na 2ª Revisão de Receita em 2023 mais um acréscimo fatorial, e é dividida entre receitas tributárias e não tributárias. As estimativas para os anos seguintes, assim como ocorre na Dívida Ativa, também considera um fator de crescimento em linha com os parâmetros (IPCA e PIB) estabelecidos no Boletim Focus de 03/03/2023. Para 2025 e 2026, estão R\$ 635 milhões e R\$ 670 milhões, respectivamente.
- **Taxas DRE** – Esses recursos são desvinculados de outras unidades orçamentárias (UOs), com base na Emenda Constitucional nº 93 de 2016 que estabelece a Desvinculação de Recursos Estaduais (DRE) no percentual de 30% (trinta por cento). Como são receitas próprias dessas Unidades Orçamentárias, as estimativas do próximo triênio são realizadas pelas mesmas. Entretanto, não foi realizada a estimativa de arrecadação dessa rubrica por não ter sido aprovado, até o momento, uma nova Emenda Constitucional ampliando o prazo de vigência da EC 93/2016.
- **Concessão da CEDAE** - R\$ 3,08 bilhões em 2024 e R\$ 1,89 bilhão em 2025 - Receitas da outorga do serviço de saneamento da Companhia Estadual de Águas e Esgotos do Estado do Rio de Janeiro, referente a 3ª parcela dos blocos 1, 2, 3 e 4, conforme processos SEI-040053/000046/2021, SEI-150001/008936/2021, e SEI-150001/000121/2021.
- **Receita Financeira** - R\$ 399 milhões em 2024 - Receita patrimonial referente aos rendimentos em conta corrente de depósitos bancários, juros de empréstimos, aplicações em títulos de renda variável e de renda fixa. As previsões para 2025 e 2026 foram de R\$ 631 bilhões e R\$ 413 bilhões, respectivamente - e estão em grande parte influenciadas pelos rendimentos dos recursos oriundos da concessão da CEDAE.

#### IV.II. Previsão das Receitas de R&PE

- **Royalties e Participação Especiais** – As R&PE são a 2ª receita mais importante do ERJ, e fazem parte das Receitas Patrimoniais. A expectativa de arrecadação sobre a produção de petróleo e gás é de R\$ 23,08 bilhões para 2024. As projeções para o triênio 2024/2026 foram realizadas de acordo com as últimas estimativas de produção de petróleo e gás fornecidas pela Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP), através do Acordo de Cooperação Técnica e Operacional ANP/SEFAZ RJ nº 01/15. Para a variável câmbio, utiliza-se o valor do Boletim FOCUS de 03/03/2023 que norteou os parâmetros da PLDO 2024: R\$/US\$ 5,28 para 2024, R\$/US\$ 5,30 para 2025 e R\$/US\$ 5,35 para 2026. O preço do barril de petróleo foi estimado em US\$ 77,57 para 2024 considerando as estimativas de mercado mais recentes da EIA – Energy Information Administration, e para o período subsequente (2025 e 2026), foi utilizada a média anual dos contratos futuros de Brent extraídos do site investing.com em 08/03/2023. Nessa direção, salientamos que a estimativa de arrecadação das Participações Governamentais é totalmente dependente do comportamento das variáveis assumidas. Para os exercícios de 2025 e 2026, os R&PE foram estimados em R\$ 24,43 bilhões e R\$ 25,56 bilhões, respectivamente.

#### IV.III. Previsão das Receitas de Transferências

As Transferências Correntes são compostas basicamente pelas transferências constitucionais e legais de subsídios da União para o Estado, além de recursos que retornam do Fundo de Desenvolvimento da Educação Básica - FUNDEB, do qual o Estado é o principal financiador. Dentre as transferências que compõem essa rubrica, destacam-se pelo valor o Fundo de Participação dos Estados – FPE e o IPI-Exportação. Além das transferências já citadas, fazem parte desse grupo a Contribuição de Intervenção no Domínio Econômico – CIDE, incidente sobre o preço de combustíveis derivados do petróleo, o Salário Educação, e as transferências previstas na LC nº 176/2020.

- **FPE** – R\$ 2,67 bilhões – O Fundo de Participação dos Estados é composto por percentual de 21,5% da arrecadação do Imposto de Renda e Proventos de Qualquer Natureza (IR) e do Imposto sobre Produtos Industrializados (IPI). A previsão para 2023 leva em consideração a expectativa de repasse de FPE pelo Governo Federal para 2023, divulgada pela Secretaria do Tesouro Nacional com base no Projeto de Lei Orçamentária Anual – PLOA 2023, acrescida do mesmo fator de atualização utilizado em receitas anteriores para o ano seguinte (PIB e IPCA previstos para 2024). Para o biênio 2025 – 2026 as estimativas foram realizadas com base no mesmo fator utilizado em 2024, isto é, calculado com previsões do PIB e IPCA para cada ano de acordo com o Boletim Focus de 03/03/2023. Para 2025, a expectativa de repasse é de R\$ 2,82 bilhões; e para 2026, a estimativa está em R\$ 2,98 bilhões.
- **IPI-Exportação** - R\$ 1,25 bilhão – A Constituição de 1988 determina em seu artigo 159 inciso II o repasse de 10% da arrecadação do IPI para os Estados e Distrito Federal, distribuídos proporcionalmente ao valor das respectivas exportações de produtos industrializados, como forma de compensação à desoneração das exportações. A previsão em 2024 está em linha com as estimativas de repasse da PLOA União de 2023 para o ano corrente, mais um fator para 2024 em diante, também em linha com receitas anteriores. Dessa forma, a previsão para 2025 é de R\$ 1,32 bilhão; e para 2026 é R\$ 1,39 bilhão.
- **Salário Educação** – R\$ 532 milhões - Para os exercícios 2025 - 2026 a receita está estimada em R\$ 562 milhões e R\$ 594 milhões, respectivamente, e considera o fator de crescimento anual com base nos valores previstos para IPCA e PIB no relatório Focus de 03/03/2023.
- **Transferências LC nº 176/2020** – R\$ 109 milhões. Em contrapartida à ausência de repasse compensatório relativo às desonerações de ICMS nas exportações de produtos primários e semimanufaturados, a LC nº 176/2020 disciplinou novas transferências da União aos Estados e Municípios. A previsão para 2024, assim como nos anos posteriores, foi realizada com base no mesmo coeficiente médio de repasse ao ERJ utilizado em 2023.
- **Contribuição de Intervenção no Domínio Econômico – CIDE** - R\$ 5,7 milhões – Essa receita em 2024, assim como a maioria das transferências constitucionais, foi estimada com base no Projeto de Lei Orçamentária Anual – PLOA 2023 mais um fator anual de crescimento – e inclui as receitas destinadas aos municípios fluminenses. Já as estimativas para 2025 e 2026 são, respectivamente, R\$ 6,0 milhões e R\$ 6,4 milhões.

Tabela 1: Previsões a preços correntes das principais Receitas do Tesouro (em R\$ milhões)

Receita*	PLDO 2024	PLDO 2025	PLDO 2026
IRRF	7.202	7.605	8.029
IPVA	4.028	4.172	4.324

ITD	1.702	1.808	1.917
FECF	5.421	5.546	5.792
ICMS	43.793	44.803	46.806
TAXAS - Tesouro	11	12	12
Taxas - DRE	-	-	-
Multas e Juros (MJ)	601	635	670
Dívida Ativa (DA)	585	617	652
<b>TOTAL TRIBUTÁRIAS</b>	<b>63.342</b>	<b>65.198</b>	<b>68.202</b>
Receita Financeira	399	631	413
Royalties & PE	23.083	24.438	25.560
FPE	2.675	2.825	2.982
IPI	1.253	1.323	1.397
CIDE	6	6	6
Transferências da União - LC 176/2020	109	109	109
Outras MJ	132	139	147
Outras DA	59	63	66
Ressarcimento de pessoal cedido	59	62	66
Restituições e Indenizações	75	80	84
Demais Receitas	64	67	71
CEDAE	3.081	1.898	-
Outros	36	38	40
Salário Educação	532	562	594
Operações de Crédito	52	59	59

<b>TOTAL GERAL</b>	<b>94.957</b>	<b>97.498</b>	<b>99.795</b>
--------------------	---------------	---------------	---------------

*\*Receita Bruta (com FUNDEB & Transferências aos Municípios)*

Tabela 2: Previsões a preços constantes das principais Receitas do Tesouro (em R\$ milhões de dezembro/2022)

Receita*	PLDO 2024	PLDO 2025	PLDO 2026
IRRF	6.538	6.669	6.802
IPVA	3.657	3.658	3.663
ITD	1.545	1.585	1.624
FECF	4.921	4.863	4.907
ICMS	39.754	39.286	39.654
TAXAS - Tesouro	10	10	10

Taxas - DRE	-	-	-
Multas e Juros (MJ)	545	556	568
Dívida Ativa (DA)	531	541	552
<b>TOTAL TRIBUTÁRIAS</b>	<b>57.500</b>	<b>57.170</b>	<b>57.781</b>
Receita Financeira	362	554	350
Royalties & PE	20.954	21.429	21.655
FPE	2.429	2.477	2.527
IPI	1.137	1.160	1.183
CIDE	5	5	5
Transferências da União - LC 176/2020	99	95	92
Outras MJ	120	122	124
Outras DA	54	55	56
Ressarcimento de pessoal cedido	53	54	56
Restituições e Indenizações	68	70	71
Demais Receitas	58	59	60
CEDAE	2.796	1.664	-
Outros	33	33	34
Salário Educação	483	493	503
Operações de Crédito	47	52	50

<b>TOTAL GERAL</b>	<b>86.199</b>	<b>85.492</b>	<b>84.547</b>
--------------------	---------------	---------------	---------------

*\*Receita Bruta (com FUNDEB & Transferências aos Municípios)*

## ANEXO I - NOTAS EXPLICATIVAS DOS MODELOS ECONOMÉTRICOS UTILIZADOS

Para realizar a projeção das receitas tributárias, concernente ao período de 2024 a 2026, foram utilizados dois modelos de previsão: o Modelo ARIMA com variável exógena e o Modelo Híbrido. Para o ano de 2023 vale a metodologia empregada na 2ª Revisão de Receita. Desse modo, iremos descrever, de forma não exaustiva, os modelos utilizados para prever o ICMS, IPVA e o ITD.

### 1) Modelo ARIMA com variável exógena

A previsão de Imposto sobre Circulação de Mercadorias e Serviços (ICMS), para o ano de 2024 a 2026, foi aplicado um modelo SARIMA que utiliza uma matriz de regressores externos, com o mesmo número de observações que a série univariada objeto de previsão. Para tal, foram utilizados como variáveis

externas o Índice de Atividade Econômica (IBC-BR) e a taxa de câmbio real. Desse modo, para gerar os dados de previsão de ICMS do Estado do Rio de Janeiro (ERJ), foram realizadas as etapas propostas por Box e Jenkins (1976), cujos fundamentos serão expostos a seguir.

Haja vista que os modelos ARIMA foram sistematizados por Box e Jenkins (1976), Gomes (1989) ressalta que tais modelos são robustos do ponto de vista conceitual e estatístico, proporcionam previsões probabilísticas e são de fácil implementação, além de representar uma generalização dos diversos métodos de análise de séries temporais. Desse modo, o autor apresenta de forma resumida o modelo ARIMA (p,d,q) da seguinte forma:

$$w_t = \mu + \frac{\theta(B)}{\varphi(B)} \alpha_t \quad (1)$$

Onde  $t$  é o índice de tempo,  $w_t$  é a  $t$ -ésima diferença da variável de interesse  $z_t$ ,  $\mu$  é o "ponto de referência" do nível do processo,  $\theta(B)$  é o operador de "médias-móveis" e  $\varphi(B)$  é o operador autorregressivo,  $B^p$  é o operador de retrocesso e  $\alpha_t$  é o "ruído branco" ou erro aleatório. Desse modo, o modelo ARIMA (p, d, q) pode ser expandido como:

$$w_t = \varphi_0 + \varphi_1 w_{t-1} + \dots + \varphi_p w_{t-p} + \alpha_t - \theta_1 \alpha_{t-1} - \dots - \theta_q \alpha_{t-q} \quad (2)$$

Onde,  $\varphi_0 = \mu(1 - \varphi_1 - \dots - \varphi_p)$ .

A modelagem ARIMA representa as séries temporais como uma ponderação dos próprios valores e/ou erros passados da série. Desse modo, um modelo ARIMA (p, d, q) possui  $p+q+2$  parâmetros desconhecidos, que devem ser estimados a partir do ponto de referência do nível de processo ( $\mu$ ), dos  $p$  parâmetros autorregressivos  $\varphi_1, \dots, \varphi_p$ , e dos  $q$  parâmetros das médias móveis  $\theta_1, \dots, \theta_q$ .

Assim, para a construção dos modelos ARIMA, Box e Jenkins (1976) sugeriram as seguintes etapas:

a) Identificar um modelo ARIMA que corresponde à determinação do nível de diferenciação  $d$ , da ordem máxima dos termos autorregressivos  $p$ , e da ordem máxima dos termos média móveis  $q$ .

b) Uma vez identificada a ordem (p, d, q) do modelo, estimar os parâmetros  $\mu$ , os parâmetros autorregressivos  $\varphi_1, \dots, \varphi_p$ , os parâmetros das médias móveis  $\theta_1, \dots, \theta_q$  e a variação do ruído branco  $\sigma^2$ .

c) Verificar a adequação do modelo, que deve ser feita em duas dimensões. Primeiro é preciso realizar a aderência do modelo, utilizando o Mean Absolute Percentage Error (MAPE) e em seguida examinar a aleatoriedade dos resíduos do modelo. O MAPE é a medida de acurácia de previsão mais amplamente utilizada na literatura e pode ser computado da seguinte maneira:

$$MAPE = \left( \frac{1}{N} \sum_{t=1}^N \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \right) * 100 \quad (3)$$

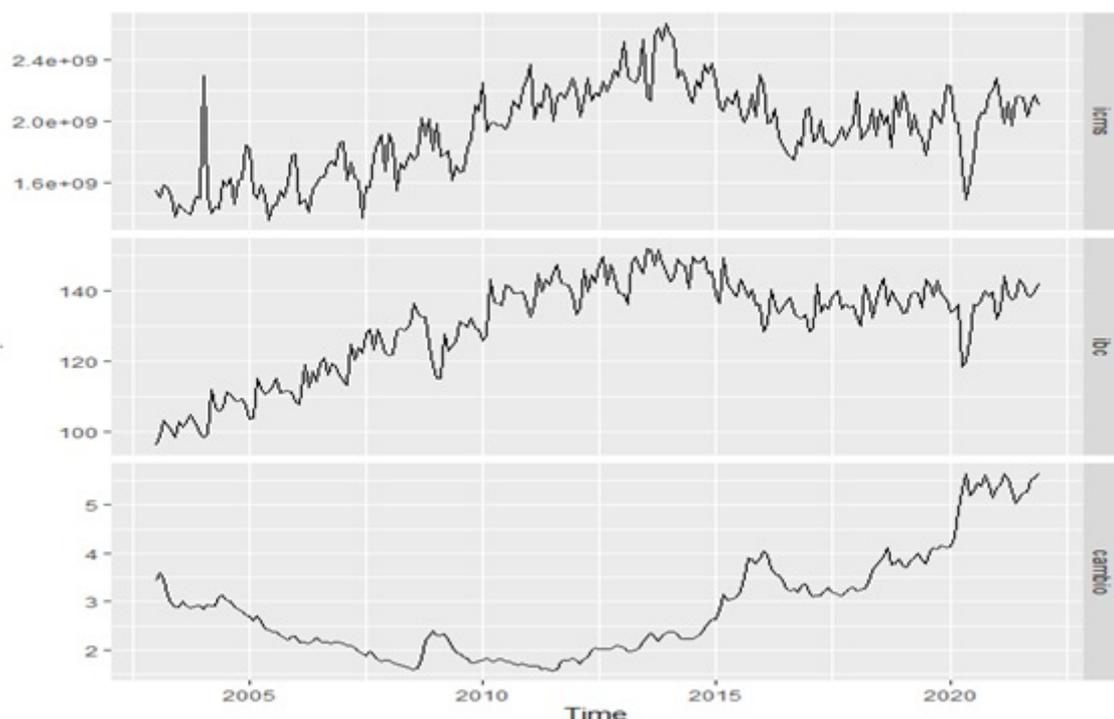
d) Após a validação do modelo, é possível construir uma função a fim de obter previsões mais plausíveis dentro de um horizonte temporal previamente especificado, com limites inferiores e superiores dentro do intervalo de confiança estabelecido pelo estatístico.

Dessa forma, o modelo utilizado para realizar a previsão do ICMS do ERJ é um SARIMA, cujo significado é similar ao ARIMA, porém o “S” representa a sazonalidade. Desse modo, o modelo SARIMA significa modelos Autorregressivos Integrados de Médias Móveis com Sazonalidade, e o mesmo possui a capacidade de fazer a modelagem de séries temporais, que apresentam um componente sazonal, sendo descritos como:  $ARIMA(p,d,q)(P,D,Q)_m$ , onde o primeiro parêntese se refere à parte não-sazonal do modelo, o segundo parêntese é a parte sazonal e  $m$  corresponde ao número de períodos sazonais. Além disso, o SARIMA permite a utilização de regressores externos que tenham alguma influência na determinação da série. Assim, os regressores externos escolhidos para a determinação do ICMS real foram o Índice de Atividade Econômica (IBC-BR) e a taxa de câmbio real, estimados exogenamente de acordo com as previsões de mercado (Boletim Focus).

### 1.1) Justificativa de Escolha das Variáveis Externas

A escolha do IBC-BR como um dos regressores externos utilizados para compor o modelo de previsão do ICMS partiu de estudos que corroboram com a narrativa de que o nível de atividade econômica exerce uma contribuição importante para a arrecadação do imposto em questão. Além disso, os dados mostram que existe uma forte correlação positiva entre o ICMS real do Estado do Rio de Janeiro e o IBC-BR, assim como há uma correlação positiva (mais fraca que o IBC-BR) entre o ICMS real e a taxa de câmbio real. Para entender essas relações, podemos analisar graficamente cada uma das séries usada pelo modelo. A figura 1 apresenta a trajetória das séries históricas tratadas por tal modelo, e mostra que o ICMS real e o IBC-BR possuem trajetórias muito similares, porém a relação entre o ICMS real e o câmbio real é mais discreta e torna-se positiva a partir de 2010, sendo que antes desse período havia uma relação negativa.

Figura 1: Comportamento das series históricas de ICMS real, IBC-BR e Taxa de câmbio real

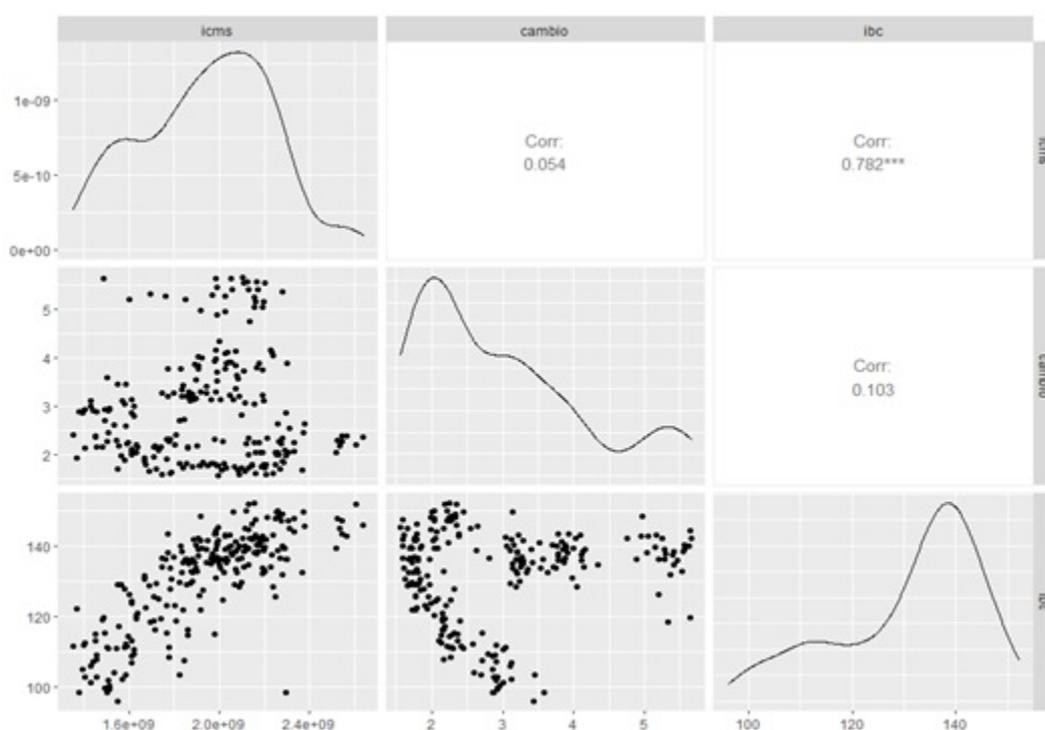


O IBC-BR é calculado mensalmente pelo Banco Central a fim de mensurar a evolução da

atividade econômica no país, utilizando dados sobre a produção nos setores agrícola, industrial e de serviços acrescidas dos impostos sobre produtos, que são estimados a partir da evolução da oferta total (produção mais importações). Desse modo, torna-se um bom indicador para prever a trajetória do PIB e ajuda a autoridade monetária na definição da taxa básica de juros (Selic).

Conforme destacado anteriormente, a escolha dessas variáveis externas para explicar o ICMS se justifica pela literatura. Pedrosa & Moura (2017) verificaram a hipótese da relação entre a arrecadação do ICMS pelos estados e o PIB estadual ser um fato estilizado, onde as razões de grandezas macroeconômicas tendem a ser constantes ao calcular a média dos dados por longos períodos. O estudo mostra que a relação ICMS/PIB possui comportamento aproximadamente constante no longo prazo. Logo, se houver uma melhora no cenário econômico, haverá uma melhora na mesma proporção na arrecadação do ICMS. Da mesma forma, o maior o nível de atividade econômica implica que haverá um crescimento maior do PIB. Embora a alíquota de ICMS seja fixa, se houver um cenário de inflação, os preços dos bens e serviços podem subir, assim como a quantidade de bens e serviços produzidos pode aumentar (devido ao aumento do PIB), e conseqüentemente a massa total arrecadada aumenta. Do mesmo modo, Mendonça & Medrato (2017) corroboram ao concluir que o PIB é a principal variável explicativa da dinâmica da carga tributária bruta no Brasil e que sua elasticidade - PIB parece estar próxima da unidade. A figura 2 e a figura 3 mostram que existe uma forte correlação positiva entre ICMS e IBC - BR de 0,78, e de 0,05 em relação ao câmbio real:

Figura 2: Correlação entre as séries de ICMS real, IBC-BR e Taxa de câmbio real



A outra variável externa que o modelo utiliza é a taxa de câmbio real. Na literatura é comum tratar o ICMS como sendo inversamente relacionado com a taxa de câmbio, uma vez que esse imposto incide sobre as importações e estas são parcialmente influenciadas por variações na taxa de câmbio, logo espera-se que uma desvalorização cambial afete negativamente a arrecadação de ICMS ao desincentivar as importações, principalmente se as importações estiverem um grande peso no sistema de arrecadação. Todavia, a importação correspondente à fabricação de coqueiras, produtos derivados do petróleo, biocombustíveis, eletricidade e gás correspondeu, em média, a 60% do ICMS importação do Estado do Rio de Janeiro em 2021, e mostrou-se inelástico às variações cambiais devido sua

essencialidade para essa economia. logo, conforme afirma Braatz e Gonçalves (2018), as variações uniformes na taxa de câmbio nacional têm efeitos distintos sobre a arrecadação de cada unidade da federação, dependendo da sua estrutura produtiva e de sua inserção no comércio internacional.

A hipótese principal desse estudo é que a desvalorização cambial incentiva o aumento da exportação e desincentiva a importação, levando, portanto, a melhora da balança comercial, que impacta positivamente o nível de atividade econômica e conseqüentemente a arrecadação, ou seja, tem um efeito indireto sobre a arrecadação da economia fluminense. Por outro lado, a correlação positiva entre o ICMS real do Estado do Rio de Janeiro e a taxa de câmbio real pode ser explicada pela peculiaridade dessa economia possuir uma forte vocação na produção de derivados do petróleo e conseqüentemente se torna dependente a fatores externos.

Embora haja uma relação fraca e dúbia entre o ICMS real e o câmbio real, no período de 2003 a 2022, vale ressaltar que foram testados vários modelos, com diferentes variáveis externas e o modelo ARIMA que gerou o menor MAPE foi aquele que utilizou como variável externa o IBC-BR e o câmbio real, cujos resultados demonstraram ser mais aderentes ao atual cenário do Rio de Janeiro.

Desse modo, para executar o modelo iremos usar dados do ICMS (variável dependente), das variáveis externas (variáveis independentes) e do IPCA mensal com ano base em 2012. Além disso, para a prever o ICMS para frente, serão utilizadas como variáveis externas as previsões do Focus para o PIB anual (que serve como base para projetar o IBC-BR para a frente), taxa de câmbio mensal e inflação mensal.

## 1.2) Resultados

Uma vez obtido os dados de ICMS, das variáveis exógenas do modelo e das previsões das variáveis exógenas encontradas no Sistema de Expectativas de Mercado do Banco Central (Pesquisa Focus), foram feitas análises gráficas de cada uma das séries, os testes de raiz unitária Dickey-Fuller (que testa a hipótese nula de que uma raiz unitária está presente em um modelo de série temporal autorregressivo) e testes de autocorrelação.

A escolha do modelo foi feita a partir de um método de seleção automática de modelos ARIMA, que possibilita a utilização de uma variação do algoritmo Hyndman-Khandakar (Hyndman & Khandakar, 2008), onde valor de  $d$  é escolhido com base em repetidos testes de raiz de unidade KPSS, e os valores de  $p$  e  $q$  são então escolhidos minimizando o AICc após diferenciar os dados  $d$  vezes. O passo seguinte foi testar se as observações das séries são aleatórias e independentes, uma vez que, a presença de autocorrelação pode reduzir a precisão de um modelo preditivo baseado no tempo, gerando assim, uma interpretação equivocada dos dados. Desse modo, foi usado o teste Ljung-Box que verifica se existe autocorrelação em uma série temporal. Trata-se de um teste amplamente utilizado em econometria e em outros campos nos quais os dados de séries temporais são comuns. Desse modo, a hipótese nula é se os resíduos são distribuídos de forma independente.

Para um modelo ser bem especificado o ideal é que a hipótese nula não seja rejeitada, ou seja, o p-valor deve ser maior que 5%, pois assim não rejeita a hipótese de que os resíduos do modelo sejam independentes. Vale destacar que se o modelo for adequado, espera-se que os resíduos não apresentem nenhum padrão bem definido, i.e., possam ser classificados como ruído branco. Conforme a figura 4, ao testar o modelo obtemos o p-valor igual a 15,04%, o que mostra que o modelo é bem especificado e possui boa capacidade preditiva.

Entretanto, antes de considerar as previsões geradas pelo modelo escolhido é necessário avaliar a sua qualidade de previsão. Para isso, foram feitos alguns testes de aderência utilizando outras variáveis externas com diferentes combinações. O modelo que obteve melhor performance (melhor MAPE) foi aquele que utilizou como variável exógena a taxa de câmbio real e o IBC. Desse modo ao realizar os testes de aderência para os anos de 2013 a 2021, o modelo escolhido gerou os seguintes MAPEs:

Tabela 1: MAPEs do modelo de previsão para o ICMS

ANO	MAPE AJUSTADO	MAPE PREVISTO
2013	4,670546	5,413465
2014	4,357186	6,414655
2015	4,346768	11,24829
2016	4,718086	6,619596
2017	4,707631	3,665829
2018	4,646222	6,495696
2019	4,716486	4,051505
2020	4,240320	4,334641
2021	4,668888	5,779852

Após a realização das etapas propostas por Box e Jenkins (1976), o modelo escolhido estava apto para realizar a previsão *out-of-sample* de ICMS, uma vez que se trata de um ruído branco e apresenta melhor performance nos testes de aderência. Portanto, finalmente, é possível gerar uma previsão factível.

## 2) Metodologia do modelo Híbrido

O modelo híbrido combina os modelos ARIMA, de suavização exponencial (ETS), Theta (THETAF), TBATS, Processo ingênuo ou passeio aleatório (NAIVE), o modelo de decomposição linear (STL) e o modelo de rede neural (NNETAR). De forma geral, tais modelos conseguem, de forma individual, ter uma boa capacidade preditiva quando a série possui um comportamento regular ao longo do tempo. Assim, a previsão combinada entre os modelos apresentados acima, para o horizonte de previsão  $t + h$ , é dado por:

$$\hat{x}_t = \sum_{i=1}^p w_i \hat{x}_t^{(i)} \quad (4)$$

Em que  $\hat{x}_t^{(i)}$  é a previsão para o horizonte de tempo  $t + h$  através do modelo de previsão  $i$  e,  $w_i$  é o peso atribuído ao modelo  $i$  e  $p$  são o número de modelos adotados.

Desse modo, o Modelo Híbrido foi desenvolvido para melhorar a acurácia através da combinação desses diferentes modelos, baseado em uma média ponderada. Caso seja necessário, também é possível fazer um ajustamento dentro de cada parâmetro dos modelos selecionados para a previsão. O resultado é obtido por meio de algoritmo computacional em que a ponderação escolhida pode ser definida de três formas: com o peso igual para cada modelo, pela melhor métrica de acurácia dentro da amostra como a Raiz do Erro Quadrático Médio (RMSE), Erro Absoluto Médio (MAE) e o Erro Escalado Médio Absoluto (MASE) ou por meio de um processo de validação cruzada (que consiste em estimar o erro de previsão para um passo à frente). No caso, a métrica de acurácia, adotada para realizar a previsão do ITD e do IPVA, foi a Raiz do Erro Quadrático Médio (RMSE) pelo fato de ser uma métrica de avaliação

amplamente utilizada e reconhecida pela comunidade acadêmica, no sentido de medir o desempenho de modelos de regressão.

Assim, iremos fazer uma breve análise de cada um dos modelos Híbridos, de forma não exaustiva, de modo a apresentar suas características e parâmetros. O primeiro é o Modelo ARIMA, que como exposto anteriormente, é baseado na metodologia de Box-Jenkins (1976), cuja projeção é realizada apenas com os valores e erros passados da própria série de interesse ou com a sua transformação em uma regressão dinâmica com a adição de fatores exógenos. Como tal tema já fora tratado na seção anterior, iremos nos concentrar nos demais modelos de previsão atrelados ao Modelo Híbrido.

## 2.1) Decomposição STL (Seasonal-Trend Decomposition Using Loess)

Cleveland et al. (1990) desenvolveu o método STL, que consiste em decompor a série temporal em três componentes aditivos: Sazonalidade, Tendência e a diferença entre a soma dos dois primeiros e a série temporal, chamado de resto (*remainder*). O método consiste em aplicar amortecimentos baseados em Regressão Local (Loess Locally Weighted Regression) várias vezes, gerando estimativas para os componentes de tendência e sazonalidade. Após a aplicação do método, a decomposição da série pode ser descrita da seguinte maneira:

$$Y_t = T_t + S_t + R_t \quad (5)$$

Onde  $Y_t$  é a série temporal no instante  $t$ ,  $T_t$  é o componente de tendência no instante  $t$ ,  $S_t$  é o componente sazonal em  $t$ , e  $R_t$  é o resto no mesmo instante.

## 2.2) Método Ingênuo (*Naive*)

É a forma mais simples de modelo. Essa abordagem diz que a previsão para qualquer período é igual ao valor real do período anterior. Tal modelo não requer um grande número observações, pois o último período que é necessário para a fazer a previsão. Pode levar em conta a sazonalidade, tendência ou ambos.

$$\text{Modelo Naive Simples: } \hat{Y}_{t+1} = Y_t \quad (6)$$

$$\text{Modelo Naive com Tendência: } \hat{Y}_{t+1} = Y_t + (Y_t - Y_{t-1}) \quad (7)$$

$$\text{Modelo Naive com Sazonalidade: } \hat{Y}_{t+1} = \hat{Y}_{t-k} \quad (8)$$

## 2.3) Modelo Theta

Tal método busca aumentar o grau de exploração das informações úteis embutidas nos dados antes de aplicar um método de previsão. Essas informações têm componentes de curto e longo prazo, e são identificados no modelo Theta e depois extrapolados separadamente (Assimakopoulo; Nikopoulos, 2000). O modelo é baseado no conceito de modificar as curvaturas locais da série temporal. Esta alteração é obtida usando o coeficiente theta, ou simplesmente  $\theta$ , que é aplicado diretamente à segunda diferença da série temporal. Os dados  $X_i$  da série podem ser escritos como:

$$X_i = X_1 + (i - 1)(X_2 - X_1) + \left(\sum_{t=2}^{i-1} (i - t) \cdot X''_{t+1}\right) \quad (9)$$

Onde  $t$  é o tempo:

$$X_t'' = X_t - 2X_{t-1} - X_{t-2} \quad (10)$$

Os pontos  $Y_i$  de uma linha teta por definição são:

$$Y_i = Y_1 + (i - 1)(Y_2 - Y_1) + \theta \left( \sum_{t=2}^{i-1} (i - t) \cdot X_{t+1}'' \right) \quad (11)$$

Desse modo, deve-se aplicar a minimização de erros quadráticos:

$$\min(\sum_i e_i^2) = \min(\sum_i (Y_i - X_i)^2) \quad (13)$$

Como mostrado em Assimakopoulos e Nikopoulos (2000) o resultado desta minimização implica que tanto a média quanto a inclinação das linhas Theta são iguais às da série original. Diferentes combinações de linhas  $\theta$  podem ser usadas para cada horizonte de previsão. Um dos casos mais simples é a combinação de duas linhas teta, sendo  $\theta = 0$  e  $\theta = 2$ , ou seja, os dados podem ser decompostos da seguinte forma:

$$X_t = \frac{1}{2} (L(\theta = 0)) + (L(\theta = 2)) \quad (14)$$

Assimakopoulos e Nikopoulos (2000) mostra que  $L(\theta = 0)$  é a regressão linear dos dados. Já  $L(\theta = 2)$  pode ser obtido de forma simplificada usando a equação anterior. Dessa forma:

$$L(\theta = 2) = 2X_t - L(\theta = 0) \quad (15)$$

Enquanto  $L(\theta = 0)$  descreve a série como uma tendência linear,  $L(\theta = 2)$  dobra as curvaturas locais estendendo a ação de curto prazo. Nas previsões,  $L(\theta = 0)$  é extrapolado por uma tendência linear e  $L(\theta = 2)$  é extrapolado por suavização exponencial simples (SES). A simples combinação de duas previsões dá a previsão final  $\hat{X}_t(h)$  para o modelo Theta, a saber:

$$\hat{X}_t(h) = \frac{1}{2} \left( \hat{L}(\theta = 0) \right)_h + \left( \hat{L}(\theta = 2) \right)_h \quad (16)$$

#### 2.4) Método ETS (*Exponential Smoothing State Space Model*)

As previsões realizadas pelo Métodos de Suavização Exponencial consideram as médias ponderadas de observações passadas, cujo peso associado a cada observação perde importância à medida em que se recua mais no tempo. Desse modo, as observações recentes terão um peso maior em tal modelo preditivo. Trata-se, portanto, de um modelo que é usado em larga escala nas mais diversas aplicações. Como destacado anteriormente, o modelo ingênuo (NAIVE) atribui peso 1 para a última observação e um modelo de média simples atribui peso igual para todas as observações passadas, a suavização simples poderia ser descrita como um meio termo entre ambos. Sua formulação matemática não é complexa:

$$\hat{y}_{T+1|T} = \alpha y_t + \alpha(1 - \alpha)y_{T-1} + \alpha(1 - \alpha)^2 y_{T-2} + \dots \quad (17)$$

O parâmetro  $\alpha$  é chamado de parâmetro de suavização e está definido no intervalo de 0 a 1.

#### 2.5) Método TBATS (*Trigonometric, Box-Cox Transformation, ARMA errors, Trend and*

De Livera, Hyndman e Snyder (2011) propuseram um método de previsão e decomposição de séries temporais com o intuito de lidar com dados que apresentam padrões sazonais complexos. Trata-se de uma extensão do modelo BATS, é formulado de forma similar aos métodos de amortecimento exponencial no contexto de espaço de estados. Nesse sentido, tal modelo busca incorporar uma transformação do tipo Box-Cox para lidar com não linearidades e heterocedasticidade, um filtro do tipo ARMA para os resíduos, além dos padrões de sazonalidade serem tratados a partir de funções trigonométricas como séries de Fourier. Desse modo, temos o seguinte modelo<sup>[2]</sup>:

$$y_t^{(\lambda)} = l_{t-1} + \varphi b_{t-1} + \sum_{i=t}^T s_{t-m}^{(i)} + d_t \quad (18)$$

$$l_t = l_{t-1} + \varphi b_{t-1} + \alpha d_t \quad (19)$$

$$b_t = \phi b_{t-1} + \beta d_t \quad (20)$$

$$d_t = \sum_{i=1}^p \varphi d_{t-1} + \sum_{i=1}^q \theta e_{t-i} + e_t \quad (21)$$

Onde  $y_t^{(\lambda)}$  é a série temporal no período t,  $s_t^{(i)}$  é o i-ésimo competente sazonal,  $b_t$  é a tendência com amortecimento,  $d_t$  é um processo ARMA(p,q) para os resíduos e  $e_t$  é um ruído branco Gaussiano. A parte sazonal é dada por:

$$s_t^{(i)} = \sum_{j=1}^{k_i} s_{j,t}^{(i)} \quad (22)$$

$$s_{j,t}^{(i)} = s_{j,t-1}^{(i)} \cos(\omega_i) + s_{j,t-1}^{*(i)} \text{sen}(\omega_i) + \gamma_1^{(i)} d_t \quad (23)$$

$$s_{j,t}^{*(i)} = -s_{j,t-1}^{(i)} \text{sen}(\omega_i) + s_{j,t-1}^{*(i)} \cos(\omega_i) + \gamma_2^{(i)} d_t \quad (24)$$

$$\omega_i = 2 \pi j / m_i \quad (25)$$

Onde T é a quantidade de sazonalidades,  $m_i$  é o tamanho do i-ésimo período sazonal,  $k_i$  quantidade de harmônicos para i-ésimo período sazonal,  $\lambda$  é a transformação Box-Cox,  $\alpha$  e  $\beta$  é a suavização,  $\phi$  é a tendência com amortecimento,  $\varphi$  e  $\theta$  são os coeficientes ARMA (p,q),  $\gamma_1^{(i)}$  e  $\gamma_2^{(i)}$  é a suavização sazonal (dois para cada período).

## **2.6) Redes Neurais (Neural Network Time Series – NNETAR)**

Os modelos anteriores fornecem relações de efeito entre tendência, sazonalidade e covariáveis, diferentemente do ajuste da rede neural, que é decomposta em diferentes componentes através da aplicação em cadeia de filtros, chamados neurônios. Esse mecanismo resulta em um sistema automatizado que ajusta o padrão de comportamento da série com base em tais neurônios. O ajuste da rede neural é visto como uma ferramenta poderosa no processo de previsão.

As entradas podem ser conectadas em muitos neurônios, resultando, em uma série de saídas, onde cada neurônio representa uma saída. As diferentes possibilidades de conexões entre as camadas de neurônios podem gerar n números de estruturas diferente.

## 2.7) Resultados

Assim como foi feito no ICMS, antes de considerar as previsões geradas pelo modelo, precisamos avaliar a qualidade da sua previsão. Desse modo, para o IPVA foram feitos testes de aderência, de modo a comparar com outros modelos e fazendo diferentes combinações. O modelo que obteve melhor performance (melhor MAPE) foi o Modelo Híbrido utilizando o IBC como variável exógena. Desse modo ao realizar os testes de aderência para os anos de 2013 a 2021, o modelo escolhido gerou os seguintes MAPES:

Tabela 2: MAPES do Modelo Híbrido de IPVA

<b>ANO</b>	<b>MAPE AJUSTADO</b>	<b>MAPE PREVISTO</b>
2013	13,63786	12,77557
2014	14,10971	12,8891
2015	14,24733	16,93008
2016	14,76411	15,7629
2017	15,03761	12,80609
2018	15,69128	16,93999
2019	15,83249	12,21376
2020	15,96402	28,57838
2021	16,27642	10,43389

Como foi mencionado, o modelo Híbrido faz uma combinação de diferentes modelos, de modo a atribuir um peso para cada um desses modelos, utilizando como métrica de acurácia o RMSE. Desse modo, segue abaixo os pesos de cada modelo atribuídos ao IPVA.

Tabela 3: Pesos do Modelo Híbrido de IPVA

<b>MODELO</b>	<b>PESO</b>
AUTO.ARIMA	18%
ETS	16,00%
THETAM	2,70%
NNETAR	29,80%
STLM	20,30%
TBATS	13,40%

Nesse sentido, o quadro abaixo mostra dois modelos de seleção de métodos, que é o Critério de Informação Akaike (AIC) e o Critério Bayesiano de Schwarz (BIC), e as variâncias que o

Modelo Híbrido gerou para cada modelo na previsão do IPVA. Vale ressaltar que o AICc é uma versão do critério de informação de Akaike (AIC, que é usado em estatística), que possui uma correção para tamanhos de amostra pequenos.

Tabela 4: Modelos de seleção do Modelo Híbrido de IPVA

<b>MODELOS</b>	<b>AIC</b>	<b>AICc</b>	<b>BIC</b>	<b><math>\sigma^2</math></b>
ARIMA(2,0,0)(0,1,2)[12]	-243,5	-243,14	-222,61	0,02034
ETS ( $\alpha = 0,3571$ )	470,2	472,23	523,14	0,0085 <sup>2</sup>
THETAM ( $\alpha = 0,1727$ )	497,02	497,12	507,61	0,1675
NNETAR (9,1,6) [12]	-	-	-	0,006824 <sup>2</sup>
STLM	335,74	335,83	346,32	0,1217 <sup>2</sup>
TBATS	581,29	-	-	0,184389 <sup>2</sup>

No caso do ITD, o modelo que obteve melhor performance foi o Modelo Híbrido univariado. Desse modo, temos os seguintes MAPES:

Tabela 5: MAPES do Modelo Híbrido de ITD

<b>ANO</b>	<b>MAPE AJUSTADO</b>	<b>MAPE PREVISTO</b>
2013	13,29	15,11
2014	13,70	15,71
2015	13,66	22,73
2016	13,89	28,53
2017	15,53	36,52
2018	16,12	52,82
2019	17,72	14,41
2020	17,45	33,71
2021	17,90	18,57

Assim como o IPVA, no ITD o modelo Híbrido faz uma combinação de diferentes modelos utilizando como métrica de acurácia o RMSE. Desse modo, segue abaixo os pesos de cada modelo atribuídos ao ITD.

Tabela 6: Pesos do Modelo Híbrido de ITD

<b>MODELO</b>	<b>PESO</b>
AUTO.ARIMA	15%

ETS	17,40%
THETAM	14,10%
NNETAR	17,40%
STLM	18,80%
TBATS	17,14%

Finalmente, o quadro abaixo mostra o resultado dos modelos de seleção AIC e BIC, além das variâncias de cada um dos modelos:

Tabela 7: Modelos de seleção do Modelo Híbrido de ITD

MODELOS	AIC	AICc	BIC	$\sigma^2$
ARIMA (1,1,1) (0,0,2) [12]	126,29	126,64	147,45	0,09316
ETS ( $\alpha = 0.2061$ )	746,95	749,89	810,48	0,0154 <sup>2</sup>
THETAM ( $\alpha = 0.2265$ )	724,66	724,76	735,25	0,2632
NNETAR (4,1,3) [12]	-	-	-	0.06812 <sup>2</sup>
STLM	678,99	679,09	689,58	0,0138 <sup>2</sup>
TBATS	739,48	-	-	0.015272 <sup>2</sup>

Portanto, o modelo Híbrido com IBC-BR e o modelo Híbrido univariado mostraram-se aptos a realizar a previsão *out-of-sample* de IPVA E ITD, respectivamente - uma vez que apresentaram melhor performance nos testes de aderência, e geraram resultados satisfatórios para o cenário fluminense.

**Luiz Gustavo Veloso Castello**  
 Coordenador de Projeções de Receitas Tributárias  
 ID.: 5097870-5

**Eduardo Brandão de Andrade**  
 Superintendente de Acompanhamento da Receita Pública  
 ID.: 5007485-7

De acordo,

**Liliane Figueiredo da Silva**  
 Especialista em Finanças Públicas  
 Subsecretária Adjunta de Política Fiscal  
 ID.: 5010187-0

**Stephanie Guimarães da Silva**  
 Subsecretária do Tesouro  
 ID.: 4412059-1

---

[1] Receitas de TACT's, REFIS ou algumas relacionadas ao REPETRO, como a importação de plataformas de petróleo, foram retiradas da série histórica de arrecadação.

[2] [https://rpubs.com/chenx/tbats\\_notes](https://rpubs.com/chenx/tbats_notes)

BOX, G. E. P.; JENKINS, G. M. Time series analysis forecasting and control. Holden-Day, San Francisco, 1976.

ASSIMAKOPOULOS, V.; NIKOLOPOULOS, K. The theta model: a decomposition approach to forecasting. International Journal of Forecasting v.16 p. 521 –530, 2000.

CLEVELAND, R. B. et al. STL: A seasonal-trend decomposition. Journal of official statistics, v. 6, n. 1, p. 3–73, 1990.

DE LIVERA, Alysha M.; HYNDMAN, Rob J.; SNYDER, Ralph D. Forecasting time series with complex seasonal patterns using exponential smoothing. Journal of the American statistical association, v. 106, n. 496, p. 1513-1527, 2011.

BRAATZ, J.; GONÇALVES, R. Impactos regionais assimétricos da política cambial sobre a arrecadação do ICMS no brasil: uma abordagem com o método VAR. Revista Estudo & Debate, V.3, n.25, 2018.

Gomes, F. C. Os modelos Arima e a abordagem de Box-Jenkins uma aplicação na previsão do IBOVESPA a curtíssimo prazo. Revista de Administração de Empresas, V.29, p. 63-70, 1989.

MENDONÇA, Mario Jorge Cardoso de; MEDRANO, Luis Alberto Toscano. Estimando a elasticidade-renda da arrecadação tributária federal. 2017.

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

HYNDMAN R. J.; KHANDAKAR, Y. Automatic Time Series Forecasting: the forecast package for R. Journal of Statistical Software, v. 27, n. 3, p. 1-22, 2008.



Documento assinado eletronicamente por **Stephanie Guimarães da Silva, Subsecretária**, em 27/03/2023, às 12:57, conforme horário oficial de Brasília, com fundamento nos art. 21º e 22º do [Decreto nº 46.730, de 9 de agosto de 2019](#).



Documento assinado eletronicamente por **Liliane Figueiredo da Silva, Subsecretária Adjunta**, em 27/03/2023, às 12:58, conforme horário oficial de Brasília, com fundamento nos art. 21º e 22º do [Decreto nº 46.730, de 9 de agosto de 2019](#).



Documento assinado eletronicamente por **Eduardo Brandão de Andrade, Superintendente**, em 27/03/2023, às 13:11, conforme horário oficial de Brasília, com fundamento nos art. 21º e 22º do [Decreto nº 46.730, de 9 de agosto de 2019](#).



Documento assinado eletronicamente por **Luiz Gustavo Veloso Castello, Coordenador**, em 27/03/2023, às 13:47, conforme horário oficial de Brasília, com fundamento nos art. 21º e 22º do [Decreto nº 46.730, de 9 de agosto de 2019](#).



A autenticidade deste documento pode ser conferida no site [http://sei.fazenda.rj.gov.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=6](http://sei.fazenda.rj.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=6), informando o código verificador **48523424** e o código CRC **44C9ABDF**.

Referência: Processo nº SEI-120001/001534/2023

SEI nº 48523424