

ANÁLISE SIMULTÂNEA DAS RECEITAS DE MÚLTIPLOS ÓRGÃOS GOVERNAMENTAIS

Otoniel Arruda Costa



Tribunal de Contas do Estado de São Paulo (TCE/SP), São Paulo (SP), Brasil

Henrique Raymundo Góia



Universidade de São Paulo (USP), São Paulo (SP), Brasil

RESUMO

O planejamento orçamentário é obrigatório por lei, mas muitos gestores ainda enfrentam desafios na previsão de receitas. Apesar dos avanços em ciência de dados, há lacunas na aplicação de modelos preditivos para esse fim. Este estudo propõe modelo computacional em R que permite analisar séries temporais de receitas orçamentárias de múltiplos órgãos arrecadadores simultaneamente, comparando diferentes métodos – Média Móvel Integrada Autorregressiva, em inglês Autoregressive Integrated Moving Average (ARIMA) e Suavização Exponencial – de forma automatizada. O algoritmo desenvolvido possibilita que analistas verifiquem todas as informações dos métodos com um único código, eliminando a necessidade de utilizar as mesmas funções repetidamente. O algoritmo foi desenvolvido com dados dos portais do Tribunal de Contas do Estado de São Paulo (TCE-SP) e da Fundação Sistema Estadual de Análise de Dados (Seade). Foram selecionadas duas cidades com características econômicas semelhantes em 31 de dezembro de 2020, Sorocaba e São José dos Campos, sobre as quais foram gerados modelos de previsão de séries temporais das receitas dos exercícios de 2022 e 2023. Como metodologia, compararam-se os modelos por meio do Critério de Informação de Akaike – Akaike Information Criterion (AIC), da versão corrigida do AIC – Corrected Akaike Information Criterion (AICc) e do Critério de Informação Bayesiano (BIC), além da estatística de Erro Percentual Absoluto Médio (MAPE). O método ARIMA apresentou o melhor critério de informação para ambas as cidades e o menor MAPE em São José dos

Campos (9,75%). Com o método de Suavização Exponencial, Sorocaba teve menor MAPE (12,31%). Os resultados demonstram a viabilidade do modelo proposto para facilitar análises comparativas entre municípios e apoiar decisões de gestores públicos, auditores e outros interessados nas informações econômicas governamentais.

Palavras-chave: business analytics; covid-19; Fable; previsão orçamentária; X13-ARIMA-SEATS.

1 INTRODUÇÃO

Um dos fatores cruciais para o equilíbrio entre receitas e despesas públicas – equilíbrio fiscal – é a adoção de processo adequado de planejamento orçamentário. Trata-se de constatação que se obtém da leitura dos arts. 11 e 12 da Lei Complementar 101, de 4 de maio de 2000 – Lei de Responsabilidade Fiscal (LRF).

Para cumprir esse objetivo, os entes federativos devem elaborar planejamento governamental de médio prazo por meio do Plano Plurianual (PPA), instituído por lei ordinária e com vigência de quatro anos. Em consonância com esse instrumento de planejamento, são obrigados a editar, anualmente, Lei de Diretrizes Orçamentárias (LDO) e Lei Orçamentária Anual (LOA), que orientam a elaboração e a execução do orçamento público.

Estudos recentes demonstraram que ainda há dificuldades na previsão orçamentária. Oliveira Junior e Levino (2024) destacaram que a União prestou auxílio financeiro aos municípios durante a pandemia, sem análise técnica robusta, evidenciando a necessidade de modelos preditivos mais precisos para subsidiar decisões fiscais em cenários incertos.

Em outro estudo, Nascimento e Boente (2022, p. 11), ao estudarem os mais de cinco mil municípios brasileiros, entre 2015 e 2018, demonstraram que os erros de previsão de exercícios fiscais passados (em média, 19,7%) afetam os erros de previsão de

exercícios futuros (em média, 17,5%), para mais ou para menos. Toledo Júnior (2010, p. 36), por sua vez, asseverou que, muitas vezes, as receitas orçamentárias são ajustadas ao “desejado tamanho da despesa”.

Por outro lado, felizmente, na atualidade, as ciências de dados disponibilizam ferramentas cada vez mais poderosas em análises, inclusive para o setor público. Fávero e Belfiore (2021, p. 14) destacaram que os aplicativos profissionais “além de oferecerem enorme capacidade de processamento de bases de dados, são capazes de elaborar os mais diversos testes e modelos apropriados e robustos”. Exemplo recente dessa aplicação é o estudo da similaridade da evolução da covid-19 nos estados brasileiros, conduzido por Faveret *et al.* (2021). Os autores utilizaram as técnicas de agrupamento de dados e análise de séries temporais, para examinar padrões de ocorrência dessa doença. Em outra aplicação, o governo do estado do Mato Grosso (Sá et. al, 2020) preconizou o uso de redes neurais como metodologia preditiva.

Apesar dos avanços, a análise de dados ainda é subutilizada por gestores públicos. Araújo, Behr e Schiavi (2023) salientaram que muitas ferramentas utilizadas por auditores não incorporam técnicas modernas de análise de dados, limitando a precisão das previsões. Além disso, os autores também assinalaram que o encapsulamento das ferramentas de análise de dados disponíveis faz com que os profissionais desconheçam o algoritmo em uso. Convergem com essas constatações as conclusões das pesquisas de Batóg e Batóg (2021) e Liu, Liu e Chen (2023), que propuseram a ampliação do estudo de métodos, técnicas e algoritmos preditivos.

Considerando-se esse panorama, o objetivo da pesquisa é propor modelo que facilite a análise de múltiplas séries temporais de órgãos arrecadadores por meio de algoritmo computacional em linguagem R. A finalidade do modelo é permitir que usuários desse tipo de informação econômica obtenham economia de tempo na detecção da técnica mais adequada para diferentes séries temporais. O estudo também pretende contribuir para o aumento da capacidade de comparabilidade entre instituições e a obtenção de ganhos de escala na quantidade de dados examinados.

Suponha-se o caso hipotético de um técnico orçamentário que compare a série temporal das receitas orçamentárias da prefeitura em que atua com a de outro município de características econômicas semelhantes. Nessa situação, as previsões geradas pelo algoritmo poderiam servir como ponto de partida para investigar, por exemplo, se o outro ente estaria se beneficiando de alguma legislação ou política pública que também pudesse ser aplicada ao seu município, caso fossem identificadas diferenças significativas na evolução das receitas orçamentárias para um mesmo período.

Outro caso seria o de um auditor que, ao comparar as receitas de dois órgãos ou entes com características semelhantes, pudesse identificar indícios de irregularidades ou fraudes a partir da detecção de padrões atípicos de arrecadação de receitas.

Nessa perspectiva, a solução proposta visa a fornecer aos diversos interessados nas informações econômico-financeiras meios de acompanhar, de forma proativa, a evolução futura das receitas públicas, utilizando essas previsões como ferramenta de apoio à gestão, ao controle e à tomada de decisão.

Dentre os possíveis interessados na solução, destacam-se os órgãos de controle, os órgãos fazendários, as instituições de pesquisa, os gestores públicos, os cidadãos e outros interessados no acompanhamento da gestão fiscal.

2 REVISÃO DE LITERATURA

Esta seção está subdividida em três subseções, para apresentação da literatura sobre os conceitos de receitas públicas, séries temporais e processos e técnicas preditivas.

2.1 Receitas públicas

O planejamento orçamentário constitui, segundo o Manual de contabilidade aplicado ao setor Público (MCASP), aspecto relevante da gestão pública (Brasil, 2024). No entanto, mesmo diante dos avanços tecnológicos e metodológicos, esse continua

sendo um trabalho desafiador para os governos. Diversos países enfrentam dificuldades nesse processo e buscam alternativas para aprimorar a previsão das receitas públicas.

Batóg e Batóg (2021), ao analisarem os fatores de risco relacionados ao planejamento de receitas regionais na Polônia, concluíram que processos de previsão bem-sucedidos não devem apenas se basear na estrutura de receitas, mas também na seleção de método de previsão adequado. No estudo, os autores propuseram dois modelos: um baseado em séries temporais e outro baseado na arrecadação como uma variável dependente do Produto Interno Bruto (PIB).

Koniagina (2020) analisou problemas de implementação de soluções digitais para os processos de previsão de receitas em governos locais da Federação Russa. Dentre os principais obstáculos para adoção de algoritmos de previsão e planejamento, a autora destacou a “ausência de uma ferramenta única de planejamento e previsão fiscal, integrada no sistema consolidado de planejamento e previsão, para os níveis regional e local” (Koniagina, 2020, p. 6).

Nos Estados Unidos, Levy, Chasalow e Riley (2021) analisaram o emprego de algoritmos no processo decisório da gestão pública sob diferentes perspectivas, incluindo as dimensões computacional, jurídica, social e ética. Os autores observaram que restrições impostas pelos governos estaduais às receitas dos governos locais podem limitar a capacidade financeira desses entes e comprometer sua atuação. Nesse contexto, argumentam que a adoção de ferramentas tecnológicas se torna uma opção considerável para subsidiar a tomada de decisões complexas no âmbito das políticas públicas.

Na Espanha, Muñoz, Bolívar e Arellano (2022) destacaram que as dificuldades enfrentadas pelos governos regionais e locais no controle das finanças públicas favoreceram a adoção de soluções tecnológicas voltadas ao aprimoramento da gestão fiscal e do processo decisório.

No Brasil, o estado do Mato Grosso incorporou, em sua Metodologia utilizada nas estimativas de receitas e despesas (Sá *et al.*, 2020), o conceito de rede neural para a

estimação das receitas pública. De acordo com o documento, nesse método, os valores da série temporal são os dados de entrada (variáveis independentes ou regressores) aos quais são atribuídos pesos ponderados automaticamente pelo algoritmo durante o processo de treinamento. A cada nova iteração, os parâmetros do modelo são recalibrados com base nos erros observados nas simulações anteriores, o que permite o aperfeiçoamento das previsões.

Para além dos desafios tradicionais ao processo de previsão das receitas de órgãos arrecadadores, a situação de calamidade internacional em saúde pública decorrente da covid-19 trouxe novos desafios. A principal delas foi a grande variabilidade dos dados, notadamente nos anos de 2020 e 2021, decorrente da paralisação parcial da atividade econômica em todo o mundo. Nesse sentido, Oliveira Junior e Levino (2024), ao aplicarem o teste de Correlação de Spearman, mostraram que o repasse de auxílio financeiro pela União aos municípios afetados pela covid-19 não apresentou correlação evidente com a queda de arrecadação naqueles entes, o que prejudicou a análise técnica no processo de descentralização de recursos aos entes subnacionais. Já Nascimento e Boente (2022, p. 11) asseveraram ser necessária a adoção de técnicas preditivas “mais realistas” pelos municípios. Também propuseram que pesquisas futuras considerem externalidades, como períodos de crises econômicas.

2.2 Séries temporais

O estabelecimento de um modelo preditivo pressupõe o entendimento do conceito de séries temporais. Uma definição adequada para elas é “qualquer conjunto de observações ordenadas no tempo”. Conforme Morettin e Tolo (2018, p. 1), há mais aspectos interessantes na realização de séries temporais, como descrever o comportamento da receita/despesa e investigar seus mecanismos geradores, do que na realização apenas de previsões.

Um dos métodos amplamente utilizados para previsão de séries temporais é a Suavização Exponencial, em inglês Error, Trend and Seasonal (ETS), cuja principal característica consiste em reduzir o impacto das oscilações aleatórias presentes nos dados pela atribuição de maior peso às observações mais recentes. Para os autores

(2018, p. 89), as oscilações presentes nos extremos representam fontes de “aleatoriedade”, o que justifica o uso frequente do método, por sua “simplicidade, eficiência computacional e razoável precisão”. Os modelos ARIMA, segundo Sartoris (2003), baseiam-se em dados passados da própria série, ou seja, funcionam como uma regressão de si mesmos.

Morettin e Tolo (2018) classificam a Suavização Exponencial em três modalidades: a simples, indicada para séries que não possuem tendência nem sazonalidade; a de Holt, recomendada para séries com tendência e sem sazonalidade; e a de Holt-Winters, apropriada para séries que apresentam tendência e sazonalidade simultaneamente.

Ferreira e Duca (2020, p. 75) explicam que tendência é o crescimento ou decrescimento normalmente existente em uma série, “não necessariamente linear”. Também lecionam que sazonalidade é a repetição de valores em períodos anuais.

Outro importante conceito é o da estacionariedade das séries temporais. Sartoris (2003, p. 342) conceitua que uma série temporal dada por Y_t é estacionária quando seu valor histórico tende a zero, de modo que um eventual choque é “dissipado ao longo dos anos”. O autor também preconiza que, nesse tipo de série, a esperança e a variância matemáticas são constantes. Diferentemente, quando há um componente de erro acrescido do valor do período anterior da série, tem-se o chamado passeio aleatório (random walk).

Para Morettin e Tolo (2018, p. 5), “uma das suposições mais frequentes que se faz a respeito de uma série temporal é a de que ela é estacionária, ou seja, de que ela se desenvolve no tempo aleatoriamente ao redor de uma média constante”. Para os autores, as séries temporais geralmente apresentam tendências, quando relativas a séries de dados econômicos e financeiros. Ressaltam, ainda, que a maior parte dos métodos possui a premissa de que os padrões de comportamento das séries temporais estão baseados em dados passados. Ademais, alertam que as séries não estacionárias precisam sofrer processo de transformação à estacionariedade, conhecido como diferenciação. Para tanto, a fim de detectar a existência dessa não estacionariedade (tendências determinísticas ou estocásticas com raízes unitárias),

os autores elencam diversos testes. Um deles é o de Dickey-Fuller, que utiliza o método dos mínimos quadrados, para detectar raízes unitárias e remover as tendências das séries que, quando estocásticas, são feitas por meio de diferenciações.

Há, na literatura, outros dois pontos de preocupação na análise de séries temporais. O primeiro é a necessidade de estabilização de sua variância, para a qual “uma transformação logarítmica pode ser adequada” (Morettin; Toloi, 2018, p. 9). O outro ponto a ser examinado é se os dados são apropriadamente representados pelo modelo (Souza *et al.*, 2022). Para isso, aplica-se o teste de superajustamento. De acordo com Morettin e Toloi (2018), a técnica consiste em adicionar parâmetros ao modelo. Se não houver redução da variância dos resíduos, o modelo encontrado inicialmente é o mais adequado. Alternativamente a esse teste, é possível a utilização da técnica de detecção de correlações entre os resíduos, como o teste de Ljung-Box, descrito por Ferreira e Mattos (2020). Em relação à unidade que mede a diferença entre os valores previstos e os reais, destaca-se o MAPE, conforme discutido por Kim e Kim (2016).

Para o presente estudo, adotou-se a Escala de Precisão da Previsão apresentada por Klimberg, Sillup, Boyle e Tavva (2010). Nela, o MAPE abaixo de 10% possibilita concluir que a previsão é altamente acurada; entre 10% e 20%, diz-se que a previsão é boa; e entre 21% e 50%, a previsão é considerada razoável. Já um MAPE acima de 50% indica modelagem sem acurácia.

2.3 Processos e técnicas preditivos

O processo de previsão de receitas baseado em séries temporais está cada vez mais vinculado à evolução tecnológica. Nos últimos anos, um conceito que tem ganhado força na análise de dados é o de *Business Analytics* (BA), entendido como a aplicação de métodos estatísticos e matemáticos, para extrair conhecimento dos dados e subsidiar o processo de tomada de decisão.

Conforme Araújo, Behr e Schiavi (2023, p. 2), esse conceito foi desenvolvido “para representar o principal componente analítico do *Business Intelligence* [BI]”, enquanto

o BI está mais relacionado à produção e à disponibilização de relatórios destinados a apoiar a tomada de decisão.

Na pesquisa sobre a literatura em BA, Liu, Liu e Chen (2023) identificaram quatro perspectivas, para a definição desse conceito: técnica, de processos, prática e de gestão. Para este estudo, destacam-se as duas primeiras, por serem as que melhor se relacionam com o desenvolvimento e a aplicação de algoritmos de previsão de receitas públicas.

Do ponto de vista da técnica, são considerados BA quaisquer aplicações em ciência ou análise de dados. Já sob o prisma do processo, os autores definem BA como o “encapsulamento de ferramentas, para converter dados em *insights* acionáveis por meio de um processo científico/matemático/inteligente”.

Do ponto de vista técnico, Hyndman e Rostami-Tabar (2024) analisaram estratégias de séries temporais com substanciais mudanças nas séries, como a interrupção de dados em certo período de tempo. Os autores propuseram soluções quando ocorrem, por exemplo, intervenções governamentais específicas em determinados períodos de tempo; eventos disruptivos, como a situação da pandemia da covid-19; ou, ainda, falta de dados. Para tanto, e com base em dados reais de turismo na Austrália, entre 2019 e 2022, analisaram, dentre outros, os seguintes tipos de modelagem: adaptativo; em conjunto; de intervenção; ou o que denominaram estimativa do que poderia ser (Hyndman; Rostami-Tabar, 2024, p. 7). Os autores concluíram, ao final do estudo, que cada situação pode demandar uma solução distinta. Como exemplo, para uma intervenção (governamental) complexa, é mais indicado o método adaptativo. Já a abordagem em conjunto é útil “quando há incerteza sobre qual abordagem usar e geralmente resulta em maior precisão devido ao poder da média” (Hyndman; Rostami-Tabar, 2024, p. 19). No presente estudo, as séries examinadas não possuíam dados interrompidos, mesmo no período de situação de emergência da covid-19.

Ainda quanto à pandemia, uma importante ferramenta no processo de modelagem foi o programa de ajuste sazonal X13-ARIMA-SEATS (Sax; Eddelbuettel, 2018). Essa aplicação foi desenvolvida em 2012 pelo U.S. Census Bureau (Mattos; Ferreira, 2020) e trabalha em conjunto com o pacote Seasonal, em linguagem R. Um dos pontos

fortes do programa, segundo esses autores, é a ferramenta de pré-ajuste, que permite a modelagem das séries com o tratamento de dados relativos a dias úteis, feriados e pontos extremos da série (*outliers*), dentre outros aspectos. Antes dos ajustes automáticos, os usuários podem refinar a modelagem com a possibilidade de ajustes manuais, visto que há diferenciações no calendário de cada país e em cada ano.

Também sobre o X-13-ARIMA-SEATS, destaca-se o estudo de Abeln e Jacobs (2022), que investigaram o impacto da pandemia no PIB da Holanda. Na pesquisa, analisaram essa crise como um *outlier* no contexto da análise de dados. No Brasil, o programa X13-ARIMA-SEATS é utilizado por vários órgãos que trabalham com índices oficiais, como Banco Central do Brasil (Brasil, 2021) e Ministério da Economia (Brasil, 2020).

3 METODOLOGIA

No presente estudo, adotou-se como metodologia, quanto à natureza, a pesquisa aplicada, visto que o objetivo é sua utilização na prática (Gerhardt; Silveira, 2009). Quanto ao propósito, o trabalho é uma pesquisa descritiva, pois examina a aplicação de algoritmo para a realização de processo de comparação das receitas de dois municípios distintos. Quanto à abordagem, a pesquisa é quantitativa, pois os fenômenos examinados se referem à aplicação estatística sobre dados numéricos. Quanto ao procedimento metodológico, trata-se de estudo de caso, pois busca-se, a partir da elaboração e da aplicação de algoritmo, solucionar problema de comparação de dados orçamentários.


Para organização lógica do conteúdo e compreensão gradativa dos processos realizados, a seção foi subdividida nas subseções “caracterização do sujeito da pesquisa”, “coleta de dados”, “análise de dados”, segundo proposta de Volpato (2015), com adaptações.

3.1 Caracterização do sujeito da pesquisa

O objeto da pesquisa são municípios brasileiros do estado de São Paulo (SP). Para obterem recursos, esses entes obedecem à Lei 4.320, de 17 de março de 1964, e à LRF. Por isso, devem editar, anualmente, LDO e LOA, normativos que norteiam o reconhecimento de receitas e a realização de despesas. Apesar de o estudo ter como enfoque municípios, a metodologia pode ser aplicada a outros entes. Nesta pesquisa, considerou-se, na seleção das amostras, o conceito de ente federativo municipal, segundo a Constituição federal de 1988. Portanto, também foram incluídos como órgãos arrecadadores os institutos de previdência, as autarquias, dentre outros entes públicos municipais que, por lei, possuem capacidade arrecadatória em âmbito local. Assim, a municipalidade é o conjunto de todos esses órgãos.

Na sequência, descreve-se o processo de desenvolvimento do modelo, que se caracterizou pela elaboração do algoritmo. O fluxograma da Figura 1, a seguir, representa esse processo, de forma sintética.

Figura 1 — Fluxograma do processo de modelagem de múltiplas séries temporais



Fonte: elaboração própria.

3.2 Coleta de dados

Os dados foram coletados nos sítios do TCE-SP e da Fundação Seade. Do TCE-SP, extraíram-se informações sobre receitas municipais totais, entre 2008 e 2023 (São

Paulo, 2020c). Já o PIB municipal de 2020 (São Paulo, 2020a) e a população estimada de 2020 (São Paulo, 2020b) foram obtidos no Portal da Seade.

Na planilha de receitas totais, estão contidas as codificações, de acordo com a Tabela-Resumo do MCASP (Brasil, 2024). Os dados foram tabulados em planilha eletrônica e, posteriormente, tratados em linguagem R. Os valores encontram-se na Tabela 1.

3.3 Análise de dados

A partir da obtenção dos dados e de seu necessário tratamento, procedeu-se ao desenvolvimento do algoritmo, também conhecido como *script*, que criou os modelos preditivos. Os algoritmos foram desenvolvidos em linguagem R (R Core Team, 2023) e encontram-se disponíveis no repositório Zenodo (<https://zenodo.org/records/21877515>).

3.3.1 Etapa 1

A partir desses três tipos de dados, realizou-se a análise de agrupamento, denominada Etapa 1 do experimento, de acordo com os conceitos e as técnicas de agrupamento (*cluster*) lecionados por Fávero e Belfiore (2021), descritos a seguir.

- Padronização das variáveis (PIB, receitas e população).
- Cálculo das distâncias (ou dissimilaridades) entre as observações por meio da medida denominada “euclidiana”.
- Adoção do esquema de aglomeração hierárquico e do método de encadeamento único (*single linkage*).
- Geração do dendrograma, gráfico que permite a visualização dos agrupamentos.

- Realização da análise de variância entre grupos (teste F). O teste visa a verificar se a variabilidade entre grupos é maior que a variabilidade intragrupo (Fávero; Belfiore, 2021, p. 338), ou seja, ele apura se cada variável escolhida como parâmetro de agrupamento (PIB, receita e população) contribuiu para a formação dos agrupamentos. Realiza-se a partir da elaboração da análise da variância, também conhecida como *analysis of variance* (Anova). Se, na tabela com os resultados, o valor de F for elevado e o p-valor encontrado for menor do que 0,05 (nível de significância adotado nesta pesquisa), então pode-se rejeitar a hipótese nula de que “a variável em análise apresenta a mesma média em todos os grupos formados” (Fávero; Belfiore, 2021, p. 338). Já a hipótese alternativa (H1) ocorre quando pelo menos um grupo difere dos demais e, quando isso acontece, conclui-se que as variáveis em questão contribuíram para a formação de agrupamentos da amostra. Segundo os autores, o teste é impactado fortemente pelo tamanho da amostra e, caso existam variáveis que não possibilitem a formação dos agrupamentos, deve-se excluí-las. Por isso, é necessário que se retroceda à etapa de seleção de municípios no caso de não rejeição da hipótese nula.

3.3.2 Etapa 2

A partir do agrupamento de municípios, passou-se à Etapa 2, iniciada com o exame de municípios que compuseram os estágios selecionados. São relacionadas, a seguir, as atividades realizadas nessa fase.

- Seleção de dois municípios, cujas séries temporais de receitas do período de 2008 a 2021 estavam normalmente distribuídas no nível de significância de 5,0% (Morettin; Tolo, 2018). Para esse diagnóstico, foi adotado o teste Kolmogorov-Sminoff (Método KS), por meio de acesso ao sítio Statistic Kingdom (2017). A partir dessa escolha, foram utilizados os dados das receitas de cada município selecionado, tendo por base a classificação das receitas orçamentárias por natureza (Brasil, 2024), notadamente pelas chamadas “categorias econômicas” e “origens”. Um aspecto importante é que foram retiradas da coluna “categoria” as receitas correntes e de capital

intraorçamentárias, haja vista que nelas estão incluídas receitas que passam das prefeituras para outros órgãos da mesma estrutura orçamentária do ente. Desta forma, evitou-se a dupla contagem de valores. Além disso, receitas intraorçamentárias provenientes de outros entes também foram excluídas. Destaca-se, também, que, nas planilhas de receitas obtidas no sítio do TCE-SP, a coluna que se refere à classificação “origem” é denominada “subcategoria”, tal como preconizado nas tabelas de escrituração contábil do TCE-SP (São Paulo, 2007, p. 9).

- Importação das tabelas para o aplicativo RStudio e carregamento de pacotes, notadamente o Forecast (Hyndman *et al.*, 2024) e o Fable (O’Hara-Wild *et al.*, 2023), que possibilita o “empilhamento” de séries temporais para análise concomitante e múltipla. Além disso, o pacote Fable (O’Hara-Wild *et al.*, 2023) adota parametrizações do pacote Forecast e, portanto, utiliza as estatísticas AIC e BIC para calcular o modelo mais adequado para a série temporal em questão (O’Hara-Wild *et al.*, 2023).
- Separação das amostras em treino (janeiro de 2008 a dezembro de 2021) e teste (janeiro de 2022 a dezembro de 2023).

3.3.2.1 Subetapa 2.1 – Modelagem pelo pacote Fable

Compreendeu as ações relacionadas a seguir.

- Geração dos modelos ARIMA e de Suavização Exponencial.
- Verificação dos coeficientes do modelo e seleção dos menores valores de AIC, AICc e BIC.
- Realização do teste de Ljung-Box, para atestar se existia ou não correlação entre os resíduos.

- Aplicação do teste de KS, para verificar a sua normalidade (Lopes; Branco; Soares, 2013).
- Realização do teste de Archtest, para apurar se neles havia ou não estacionariedade da variância.
- Cálculo do MAPE das previsões.

Ferreira e Mattos (2020) mostram que, se os pressupostos da ausência de autocorrelação, da ocorrência de normalidade e da homoscedasticidade (variância constante) dos resíduos não forem atendidos, o modelo não estará apto a realizar previsões, pois sua parte linear não estará modelada. Assim, em todas as etapas do algoritmo em que os resíduos não forem aprovados nesses três testes, será necessária a seleção de novos municípios.

3.3.2.2 Subetapa 2.2 – Validação da modelagem pelo pacote Forecast

Para aferição da exatidão dos modelos obtidos na subetapa 2.1, realizou-se a modelagem pelo pacote Forecast, seguindo-se as fases de identificação, estimação, diagnóstico e previsão, tal como apresentado por Ferreira e Mattos (2020). Realizaram-se as análises relacionadas a seguir.

- Identificação e estimação dos modelos ARIMA: realizou-se a identificação e a estimação por meio da função *auto.arima*, obtendo-se os componentes autorregressivos “*p*” (AR), integrados “*d*” (I) e de médias móveis “*q*” (MA) e das análogas componentes sazonais “P”, “D” e “Q”.
- Verificação da significância estatística dos coeficientes: foram avaliadas a significância estatística dos coeficientes estimados e a adequação do modelo.
- Diagnóstico dos resíduos: verificaram-se a ausência de autocorrelação dos resíduos, a normalidade e a homocedasticidade.

- Previsão e avaliação da acurácia: foram geradas as previsões e calculada a estatística de erro MAPE.
- Modelagem por Suavização Exponencial: para esse método, utilizou-se a função *forecast.ets*, selecionando-se o modelo com o menor valor de AIC (Hyndman; Khandakar, 2008).
- Comparação dos critérios de informação: verificou-se se os AIC, AICc e BIC obtidos eram iguais aos gerados na subetapa 2.1.
- Diagnóstico dos resíduos do modelo de Suavização Exponencial: verificaram-se a hipótese de não existência de autocorrelação dos resíduos do modelo gerado, a normalidade e a estacionariedade da variância dos resíduos.
- Previsão pelo método de Suavização Exponencial: por fim, foram geradas as previsões e calculada a estatística de erro MAPE.

3.3.2.3 Subetapa 2.3 – Comparação dos resultados com métodos alternativos

Realizou-se a comparação dos resultados obtidos nas subetapas 2.1 e 2.2 com outros métodos, para aferir a adequabilidade do modelo.

- Aplicação de métodos de referência (benchmarks): primeiramente, realizaram-se as previsões de receita pelos métodos de elaboração menos complexos Seasonal Naive, Naive, Drift e Mean, conforme Dhakal (2017).
- Avaliação da acurácia: calcularam-se as medidas da acurácia MAPE de cada um deles.
- Modelagem pelo X13-ARIMA-SEATS: foi gerado um modelo do método ARIMA pelo programa X13-ARIMA-SEATS.

- Divisão da amostra: realizou-se a divisão da série temporal em amostras de treino e teste para validação das previsões.
- Geração e ajuste dos modelos: foram gerados múltiplos modelos de séries temporais e realizados os ajustes de cada série individualmente, por meio da função *seas*.

Sobre o programa X13-ARIMA-SEATS, Mattos e Ferreira (2020, p. 146) asseveram que uma das funcionalidades que “merece destaque é o pré-ajuste da série temporal, isto é, uma correção antes de ser feito, de fato, o ajuste sazonal”. Nela, há o pré-ajuste de eventuais valores discrepantes que não são sazonais, mas que afetam a sazonalidade das séries. Ressalva-se que uma das limitações do estudo é não ter sido realizado o pré-ajuste de dias úteis (entre outras datas específicas) antes do ajuste automático. Por isso, a inversão da ordem do uso dos pacotes Fable e Seasonal, na metodologia proposta, deve ser objeto de futuros estudos. Importa salientar que, se, por um lado, essa função modela apenas uma série por vez (Mattos; Ferreira, 2020), por outro lado, a vantagem é que todas as análises de resíduos já são feitas nessa mesma função. Por fim, as previsões foram realizadas por meio da função *series* (“*basededados_ajustada*”, *forecast.forecasts*).

Ressalta-se, nesse contexto, que o processo de modelagem deve ser iterativo, ou seja, os órgãos e as respectivas séries temporais a serem selecionadas devem passar por constante testagem, notadamente na análise dos resíduos. Além disso, todo esse mecanismo deve estar fundamentado na “teoria subjacente e na experiência do pesquisador” (Fávero; Belfiore, 2021, p. 511) e ser examinado à luz de cada caso específico de quem o está utilizando.

4 RESULTADOS E DISCUSSÃO

Esta seção está subdividida em duas subseções: a primeira apresenta os resultados do processo de agrupamento de municípios, e a segunda demonstra os resultados da modelagem das séries temporais das receitas dos municípios analisados.

4.1 Resultados obtidos na Etapa 1 – Agrupamento econômico de municípios

Os 15 municípios do estado de São Paulo que alcançaram os maiores valores do PIB estão dispostos na Tabela 1, em ordem decrescente.

Tabela 1 — Municípios com os maiores PIBs do estado de São Paulo (2020)

Município	PIB (R\$)	Receitas (R\$)	População
Osasco	63.377.281.663,00	2.855.078.622,94	680.964
Guarulhos	54.753.119.623,00	4.261.460.107,26	1.351.275
Campinas	53.364.538.386,00	5.905.702.404,37	1.175.501
São Bernardo do Campo	39.856.385.608,00	4.363.769.356,61	812.086
Barueri	39.482.997.035,00	3.226.248.352,97	264.390
Jundiaí	39.278.730.712,00	2.284.188.239,98	407.016
São José dos Campos	34.197.969.838,00	3.013.041.783,68	710.654
Paulínia	32.690.552.549,00	1.347.499.218,87	105.037
Ribeirão Preto	31.423.776.118,00	2.949.437.391,30	683.777
Sorocaba	29.554.630.061,00	2.957.377.427,20	658.547
Santo André	25.828.979.709,00	2.638.303.559,53	693.867
Piracicaba	21.130.510.915,00	1.780.043.134,66	389.873
Santos	18.513.709.213,00	2.960.581.983,75	428.703
São José do Rio Preto	16.848.532.921,00	1.996.643.669,15	447.924
Cajamar	16.523.071.678,00	594.102.652,04	77.627

Fonte: Fundação Seade (São Paulo, 2020a, 2020b) e TCE-SP (São Paulo, 2020c).

Posteriormente, de acordo com o proposto por Fávero e Belfiore (2021), a partir dos dados retrotabulados, foram obtidos os resultados do processo de agrupamento, cujos cinco primeiros estágios estão dispostos ordinalmente na Tabela 2. Os números negativos representam as posições das observações (ordem alfabética). Os números sem sinal representam os agrupamentos, de acordo com o estágio em que ocorreram. Assim, o primeiro agrupamento ocorreu com os municípios de Ribeirão Preto (posição 9 na ordem da planilha) e de Sorocaba (posição 15) no estágio 1. E, no estágio 2, as cidades agrupadas no estágio 1 foram acrescidas ao município de São José dos Campos (observação 12). Em seguida, uniu-se ao agrupamento o município de Santo André (observação 13).


Tabela 2 — Estágios de agrupamentos dos municípios com maiores PIBs do estado de São Paulo (2020)

Estágio	Observação 1 / Agrupamento 1	Observação 2 / Agrupamento 2	Coeficientes
1	-9 (Ribeirão Preto)	-15 (Sorocaba)	0,149
2	1	-12 (São José dos Campos)	0,214
3	2	-13 (Santo André)	0,372
4	-8 (Piracicaba)	-11 (São José do Rio Preto)	0,380
5	4	-14 (Santos)	0,756

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

O dendrograma contido na Figura 2, a seguir, sintetiza graficamente esse resultado.

Figura 2 — Dendrograma do agrupamento dos 15 municípios com maiores PIBs do estado de São Paulo (2020)



Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Os resultados da aplicação do teste F são apresentados na Tabela 3.

Tabela 3 — Análise da variabilidade intra e intergrupos do agrupamento dos 15 municípios com maiores PIBs do estado de São Paulo (2020)

Variável de agrupamento	Valor do teste F	P-valor
PIB	20,8	0,01470
Receita	73,44	0,00231
População	332,9	0,00024

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).


Dado que o p-valor foi inferior a 0,05, demonstrou-se, conforme previsto em Fávero e Belfiore (2021), que as variáveis selecionadas justificam a adequabilidade dos agrupamentos obtidos.

4.2 Resultados obtidos na Etapa 2 – Elaboração dos modelos preditivos

Do agrupamento realizado na Etapa 1, selecionaram-se os municípios de São José dos Campos e Sorocaba para análise múltipla de séries temporais. A preterição do município de Ribeirão Preto deveu-se ao fato de que essa cidade, embora possuísse distribuição normal das receitas, não apresentou normalidade de distribuição dos resíduos (Morettin; Toloj, 2018). Esse requisito é essencial para que os modelos gerados captem toda a informação da base de dados, minimizando a perda nos resíduos (Ferreira; Mattos, 2020).

Na continuidade da análise, verificou-se que as receitas dos dois municípios possuíam valores relativamente próximos, quando comparados com os de outros municípios. No mês de dezembro de 2020, São José dos Campos teve uma receita mensal de R\$ 367 milhões e Sorocaba, R\$ 322 milhões (em valores arredondados). Com base nos panoramas econômicos dos dois municípios, observou-se a evolução das receitas de janeiro de 2008 a dezembro de 2021. A análise gráfica das séries temporais (Figura 3) indica uma tendência de crescimento em ambos os municípios. Em 2020, observa-se queda nas receitas, possivelmente associada à crise econômica causada pela pandemia da covid-19, seguida de recuperação nos anos seguintes.

Figura 3 — Séries de tempo das receitas dos municípios de São José dos Campos e de Sorocaba (2008-2021) (em R\$)



Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

A partir da apresentação gráfica da evolução da receita de 2008 a 2021, foram gerados os modelos, apresentados nas seções a seguir.

4.2.1 Subetapa 2.1 – Elaboração dos modelos ARIMA e de Suavização Exponencial

Como resultado da execução do pacote Fable, foram obtidos os modelos listados na Tabela 4.

Tabela 4 — Modelos ARIMA e de Suavização Exponencial das séries temporais das receitas de São José dos Campos e de Sorocaba (2008-2021)

Continua

Município	Tipo de modelagem	Identificação do modelo
São José dos Campos	ARIMA	(0,1,1) (0,0,1) [12]

			Conclusão
Município	Tipo de modelagem	Identificação do modelo	
São José dos Campos	Suavização Exponencial	Multiplicativo, aditivo, multiplicativo	
Sorocaba	ARIMA	(1,0,1) (0,1,1) [12] com constante	
Sorocaba	Suavização Exponencial	Multiplicativo, aditivo, multiplicativo	

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Nos modelos ARIMA, é possível perceber que, em São José dos Campos, a série é integrada de ordem 1 na parte não sazonal. Em Sorocaba, a série é integrada de ordem 1 na parte sazonal. Isso significa que é necessário realizar uma diferenciação na série original, para eliminar raízes unitárias, tanto na parte não sazonal quanto na sazonal, a fim de que se possa estabilizar a média e a variância dos valores das séries e, com isso, obter previsões mais precisas. Em seguida, foram obtidos, por meio do algoritmo, os menores valores de AIC, AICc e BIC, necessários para identificação e especificação do modelo (O'Hara-Wild *et al.*, 2023). Os resultados são apresentados na Tabela 5.

Tabela 5 — Valores de AIC, AICc e BIC para os modelos ARIMA e de Suavização Exponencial de São José dos Campos e de Sorocaba (2008-2021)

Continua


Município	Tipo de modelagem	AIC	AICc	BIC	Parâmetros
São José dos Campos	ARIMA	6313	6313	6322	Ma1=-8,58e-1; Sma1=3,83e-1
São José dos Campos	Suavização Exponencial	6678	6682	6732	Alpha=1,00e-2; Beta=1,04e-4; Gama=1,00e-4.
Sorocaba	ARIMA	5650	5651	5666	Ar1=9,17e-1; Ma1=-8,32e-1; Sma1=-5,78e-1; Constante = 1,22e+6

Município	Tipo de modelagem	AIC	AICc	BIC	Parâmetros
Sorocaba	Suavização Exponencial	6379	6383	6432	Alpha=1,28e-1; Beta=7,35e-3; Gama=1,77e-4.

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Na sequência da verificação, o correlograma (Figura 4) mostrou que há rompimento das linhas de significância estatística dos resíduos dos modelos ARIMA para os dois municípios. Em outras palavras, houve indicativo de correlação entre os resíduos (Ferreira, 2020).

Figura 4 — Correlograma dos resíduos das séries temporais dos modelos ARIMA e de Suavização Exponencial (2008-2021)



Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Diante dessa situação, para aferir se essa hipótese se confirmaria ou não, procedeu-se aos testes sobre os resíduos. Na Tabela 6, todos os valores na coluna “Teste Ljung-Box” são superiores a 0,05. Portanto, os resíduos não são correlacionados. Na sequência, o teste Kolmogorov-Smirnoff mostrou que há normalidade na distribuição dos resíduos. E, por fim, o Archtest, a 5,0% de significância, mostrou que não se pode rejeitar a hipótese de homocedasticidade da variância dos resíduos. Assim, não foi possível, para São José dos Campos rejeitar nem a hipótese nula de ausência de autocorrelação linear, nem a hipótese de normalidade e nem a hipótese de homocedasticidade da variância dos resíduos. Para Sorocaba, a única diferença foi o

nível de significância estatística para a hipótese de não rejeição da hipótese de homoscedasticidade da variância, de 1,0%. Os valores constam da Tabela 6.

Tabela 6 — Resultados do diagnóstico dos resíduos das séries temporais para os modelos ARIMA e de Suavização Exponencial (2008-2021)

Município	Tipo de modelagem	Teste Ljung-Box	Teste de Kolmogorov - Smirnov	ArchTest
São José dos Campos	ARIMA	0,11	0,08	0,99
São José dos Campos	Suavização Exponencial	0,57	0,48	0,99
Sorocaba	ARIMA	0,31	0,06	0,02
Sorocaba	Suavização Exponencial	0,38	0,88	0,25

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Diante desses valores, todos acima de 1,0%, tal como lecionam Mattos e Ferreira (2020), concluiu-se que a componente linear da série temporal havia sido modelada, o que permitiu a realização das previsões. Assim, o quarto e último procedimento da modelagem do pacote Fable foi o das previsões para 2022 e 2023. Na Tabela 7, estão dispostos os valores das estatísticas de erro MAPE.


Tabela 7 — Comparação dos erros de previsão (MAPE) entre os modelos ARIMA e de Suavização Exponencial para São José dos Campos e para Sorocaba (2022-2023)

Município	Tipo de modelagem	MAPE
São José dos Campos	ARIMA	9,75%
São José dos Campos	Suavização Exponencial	13,2%
Sorocaba	ARIMA	15,3%
Sorocaba	Suavização Exponencial	12,3%

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

A partir da Tabela 7, é possível concluir que São José dos Campos possui um modelo de previsão de receitas mais preciso com o método ARIMA, visto que a estatística de erro MAPE foi de 9,75%. Já em relação a Sorocaba, os 12,3% de MAPE indicam que o método de Suavização Exponencial é o mais indicado para se realizar previsões. Graficamente, a evolução das previsões está exposta na Figura 5. Na linha preta, constam os valores reais das séries (os dados anteriores a 2021 foram removidos da figura para proporcionar maior nitidez).

Figura 5 — Previsões das séries temporais de São José dos Campos e de Sorocaba para os modelos ARIMA e de Suavização Exponencial (2022-2023)



Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Depois de todos esses procedimentos, verificou-se que o pacote Fable dispõe de todas as funcionalidades para realização do processo de modelagem de múltiplas séries temporais. Deste modo, foi concluída a subetapa 2.1.

4.2.2 Subetapa 2.2 – Aferição e validação de resultados

Na subetapa 2.2, já na primeira verificação – após a execução da função *auto.arima*, constatou-se que os valores de AIC, AICc e BIC obtidos no pacote Forecast foram os mesmos do pacote Fable. Em seguida, a aferição da significância estatística dos coeficientes (Ferreira; Mattos, 2020), por meio da função *BETS:t_test*, do pacote BETS (Ferreira *et al.*, 2022), mostrou que todos os coeficientes do modelo ARIMA

atendiam a essa exigência, conforme se observa na Figura 6. Nota-se que o valor crítico “*t Crit. Value*”, de 1,97, está compreendido no intervalo das estatísticas obtidas para os erros-padrão “*Std. Errors*”, o que impede a rejeição da hipótese nula de que os coeficientes dos modelos ARIMA sejam estatisticamente iguais a zero. Por isso, o resultado apresentado é “True”.

Figura 6 — Análise da significância estatística dos coeficientes dos modelos ARIMA

```
> BETS::t_test(city1.treino.autoarima) # Análise dos Coeficientes
      Coeffs Std.Errors      t Crit.Values Rej.H0
ma1  -0.8579742 0.04284415 20.025470    1.974446  TRUE
sma1   0.3828907 0.06756902  5.666661    1.974446  TRUE
> BETS::t_test(city2.treino.autoarima) # Análise dos Coeficientes
      Coeffs Std.Errors      t Crit.Values Rej.H0
ar1   9.168114e-01 7.113143e-02 12.888977    1.974535  TRUE
ma1  -8.324925e-01 9.058996e-02  9.189677    1.974535  TRUE
sma1  -5.783509e-01 7.489816e-02  7.721830    1.974535  TRUE
drift  1.220164e+06 1.031064e+05 11.834029    1.974535  TRUE
```

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Ressalva importante deve ser feita sobre a constante da função linear obtida (termo de *drift*). É possível que o modelo gerado no pacote Fable apresente valor diferente do gerado pelo pacote Forecast. Essa inconsistência é explicada no próprio *Manual do pacote Fable* (2023, p. 59): “Forecast standard errors allow for uncertainty in estimating the drift parameter (unlike the corresponding Forecasts obtained by fitting an ARIMA model directly)”. Além disso, quando algum dos coeficientes não é estatisticamente significativo, é possível a reestimação do modelo por meio da função ARIMA (Mattos; Ferreira, 2020), bastando suprimir tantas unidades de coeficientes quantas forem as não significantes.

Na sequência, quanto à normalidade dos resíduos, realizaram-se os testes de ausência de autocorrelação linear, normalidade e homocedasticidade da variância. Com a utilização da função *accuracy* (pacote Forecast), verificou-se que São José dos Campos apresentou um MAPE de 9,75% e Sorocaba, 12,3% para os modelos ARIMA. Esses resultados convergiram com os valores encontrados pela modelagem do pacote Fable. Para a verificação da adequabilidade dos modelos de Suavização

Exponencial, o processo foi mais simples. Gerou-se o modelo a partir da função *ets*. Na sequência, procedeu-se aos testes e diagnósticos sobre os resíduos.

Como foi possível observar, tanto o modelo gerado quanto as previsões obtidas por meio do pacote Fable resultaram nos mesmos valores e nas conclusões obtidos por meio do pacote Forecast, o que corroborou o fato de os dois pacotes utilizarem a mesma parametrização (O'Hara-Wild *et al.*, 2023).

4.2.3 Subetapa 2.3 – Benchmark e outros métodos

Na subetapa 2.3 do algoritmo gerado no RStudio, os modelos “inocentes” de previsões Drift, Mean, Naive e Seasonal Naive apresentaram os valores de erro (MAPE), no biênio 2022 e 2023, conforme mostrado na Tabela 8.


Tabela 8 — Estatística de erro MAPE das séries de tempo das receitas de São José dos Campos e de Sorocaba pelos métodos Naive (2022-2023)

Município	Drift	Mean	Naive	Seasonal Naive
São José dos Campos	14,4	41,6	11,7	14,4
Sorocaba	8,69	49,2	11,7	21,3

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Considerando-se os resultados dessa tabela, para São José dos Campos, o método Naive, com MAPE de 11,7%, foi o mais próximo do resultado apresentado pelo método ARIMA, com 9,75%. O método Naive é aquele que considera o valor real mais recente da série como a previsão dos períodos seguintes. Para Sorocaba, o método Drift, com MAPE de 8,69%, foi o mais próximo do resultado apresentado pelo método de Suavização Exponencial, com 12,3%. Este é o método que leva em consideração a tendência da série para realizar as previsões, de acordo com o que se observa na Figura 7.

Figura 7 — Previsões das séries de tempo das receitas dos municípios de São José dos Campos e de Sorocaba pelos métodos Naive (2022-2023)



Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Como se pode constatar, os modelos ARIMA e de Suavização Exponencial são de elaboração mais complexa que os modelos Naive, o que corrobora os estudos de Dhakal (2017). Quanto à utilização do programa X13-ARIMA-SEATS, por meio do pacote Seasonal, os resultados estão dispostos na Tabela 9.

Tabela 9 — Modelagem das séries de tempo das receitas de São José dos Campos e de Sorocaba pelo programa X13-ARIMA-SEATS (2008-2021)

Continua		
Elemento da modelagem	São José dos Campos	Sorocaba
Identificação do modelo	(0,1,1) (0,1,1)	(0,1,1) (0,1,1)
Estimação – Coeficientes	Não sazonal: MA=0,9 Sazonal: MA=0,61	Não sazonal: MA=0,71 Sazonal: MA=0,73
Crítérios de informação AIC; AICc; BIC	-; 5793; 5830	-; 5498; 5527
QS Teste – A série ajustada apresentou sazonalidade?	Não	Não
Ljung-Box – A série possui autocorrelação residual?	Não	Não

Elemento da modelagem	São José dos Campos	Sorocaba
Shapiro Wilk – Os resíduos possuem distribuição normal?	Não	Sim
Previsões MAPE (2022 e 2023)	7,54%	11,78%

Fonte: elaboração própria, com base em cálculos na linguagem R (R Core Team, 2023).

Como se nota, há uma diferença entre os modelos identificados nos modelos gerados pelo pacote Fable (ou Forecast) e pelo Seasonal (X13-ARIMA-SEATS). Primeiro, porque, neste, constatou-se que foram realizadas duas diferenciações, sazonal e não sazonal para cada uma das duas cidades, enquanto, no pacote Fable, houve apenas uma diferenciação para a série temporal de cada município. Segundo, porque o componente autorregressivo apresentou valor zero no modelo referente a Sorocaba.

Quanto às estatísticas de erro MAPE, para o pacote Fable, São José dos Campos teve MAPE de 9,75% e Sorocaba 15,3%. Sob o teste de Shapiro Wilk, os resíduos de São José dos Campos não são normais a 5% de significância, o que demandaria ajustes adicionais sob o método X13-ARIMA-SEATS. Em Sorocaba, o pacote Seasonal realizou uma transformação logarítmica. Desta forma, verificou-se que o pacote Fable, no método ARIMA, apresentou MAPEs e critérios de informação superiores aos do pacote Seasonal (programa X13-ARIMA-SEATS) para ambas as cidades.

Apesar disso, o modelo obtido para São José dos Campos no programa X13-ARIMA-SEATS não pôde ser utilizado para comparação com aquele gerado no pacote Fable, por não atendimento ao pressuposto de normalidade dos resíduos. Também não pôde ser utilizado para realizar previsões ou calcular o MAPE. Para que isso pudesse ser feito, seriam necessários ajustes manuais (Mattos; Ferreira, 2020), não previstos neste estudo.

Diante de tais resultados, ressalta-se que cada uma dessas técnicas possui pressupostos; por exemplo, a qualidade e a quantidade dos dados; a necessidade de ajustes dos dados em relação a possíveis impactos de dados destoantes (*outliers*); a

complexidade dos algoritmos a serem desenvolvidos. Verificou-se, ainda, na presente pesquisa, que os modelos desenvolvidos no X13-ARIMA-SEATS utilizaram menos linhas de comando que aqueles implementados pelo pacote Fable. Contudo, a depender da série analisada, a complexidade da modelagem pode aumentar.

Além disso, para São José dos Campos, embora o método ARIMA implementado no pacote Fable tenha apresentado menor precisão do que aquele implementado no pacote Seasonal, foi o único que atendeu a todos os pressupostos da modelagem. Em Sorocaba, por sua vez, observou-se maior precisão nas previsões obtidas com o pacote Seasonal. Como se verificou, o algoritmo gerou as séries de dois municípios ao mesmo tempo e em dois métodos distintos – ARIMA e Suavização Exponencial, o que possibilitou maior celeridade na modelagem e na comparação dos órgãos em questão.

Quanto à precisão dos resultados obtidos, considerando-se a escala de precisão apresentada por Klimberg, Sillup, Boyle e Tavva (2010), verificou-se que São José dos Campos, com MAPE de 9,75%, apresentou previsão de alta acurácia, enquanto Sorocaba, com MAPE de 12,31%, apresentou acurácia boa. Além disso, os valores de MAPE dos modelos ARIMA e de Suavização Exponencial encontrados no modelo gerado nesta pesquisa foram inferiores à média de 17,5% de erro por exercício, encontrada nos estudos de Nascimento e Boente (2022).

5 CONSIDERAÇÕES FINAIS

Este estudo demonstrou a viabilidade de um modelo preditivo para análise simultânea de múltiplas séries temporais de receitas públicas, facilitando o planejamento orçamentário e a tomada de decisão em órgãos arrecadadores. Os resultados mostraram que há plena compatibilidade entre os pacotes Forecast e Fable, com a vantagem de que, neste, existe a possibilidade de geração de múltiplos modelos (Suavização Exponencial, ARIMA), de forma concomitante.

Assim, os interessados na informação contábil, em vez de efetuarem a modelagem pelo método de Suavização Exponencial e pelo método ARIMA, separadamente, para

verificar qual apresenta os menores valores de AIC, AICc, BIC ou o menor MAPE para os dados em análise, podem fazê-lo com um único algoritmo no pacote Fable. E isso pode ser realizado com mais de um município no mesmo código. Outra vantagem é a transparência no algoritmo, que possibilita aos analistas a compreensão de cada etapa e de cada resultado parcial obtido.

No aspecto estatístico, os resultados mostraram que mesmo municípios com dados econômicos similares (agrupamentos) podem resultar em valores de AIC, AICc, BIC e MAPEs distintos e, portanto, demandar métodos de modelagem diferentes. Essa situação pode ser o ponto de partida para investigações sobre o motivo pelo qual municípios com trajetórias de receitas semelhantes podem apresentar resultados futuros diferentes, como no caso de uma auditoria financeira.

Propõem-se novos estudos conduzidos por outras hipóteses, como a utilização de séries temporais que não possuam distribuição normal. Do mesmo modo, do ponto de vista da formação de agrupamentos, outras variáveis podem ser acrescentadas às análises, além de se diversificar o tamanho das amostras.

Relembra-se que o processo de modelagem é útil não só para realizar previsões, mas também para entender o comportamento das séries temporais. Ademais, é um processo de apoio à tomada de decisão. Por isso, a utilização dessas ferramentas tecnológicas de modelagem deve estar associada à experiência profissional, ao arcabouço conceitual das ciências econômicas, à ciência de dados, bem como ao atendimento da legislação, no caso de uso por órgãos governamentais.

REFERÊNCIAS

ABELN, Barend; JACOBS, Jan P. A. M. Covid-19 and seasonal adjustment. **Journal of Business Cycle Research**, v. 18. p. 159-169, jul. 2022. DOI: <https://doi.org/10.1007/s41549-022-00071-z>. Disponível em: <https://link.springer.com/article/10.1007/s41549-022-00071-z>. Acesso em: 23 set. 2024.

ARAÚJO, Letícia; BEHR, Ariel; SCHIAVI, Giovana Sordi. Adoption of business analytics in accounting. **Revista Contabilidade & Finanças**, São Paulo, v. 34, n. 93, e1771, dez. 2023. DOI: <https://doi.org/10.1590/1808-057x20231771.en>. Disponível em: <https://www.scielo.br/j/rcf/a/h8BSKTCgthvCfwCf9dNSCKH/?lang=en>. Acesso em: 23 set. 2024.

BATÓG, Barbara; BATÓG, Jacek. Regional government revenue forecasting: risk factors of investment financing. **Risks**, v. 9, n. 12, p. 1-15, nov. 2021. DOI: <https://doi.org/10.3390/risks9120210>. Disponível em: <https://www.mdpi.com/2227-9091/9/12/210>. Acesso em: 23 set. 2024.

BRASIL. Banco Central do Brasil. **Efeitos da pandemia sobre o ajuste sazonal dos indicadores econômicos**. Estudo Especial 108/2021. Brasília, DF: BCB, 2021. Disponível em: https://www.bcb.gov.br/conteudo/relatorioinflacao/EstudosEspeciais/EE108_efeitos_pandemia_sobre_ajuste_sazonal.pdf. Acesso em: 23 set. 2024.

BRASIL. [Constituição (1988)]. **Constituição da República Federativa do Brasil de 1988**. Brasília, DF: Presidência da República, 1988. Disponível em: http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm. Acesso em: 27 jul. 2026.

BRASIL. **Lei n. 4.320, de 17 de março de 1964**. Estatui normas gerais de Direito Financeiro para elaboração e controle dos orçamentos e balanços da União, dos estados, dos municípios e do Distrito Federal. Brasília, DF: Presidência da República, 1964. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l4320.htm. Acesso em: 28 jul. 2026.

BRASIL. **Lei Complementar n. 101, de 4 de maio de 2000**. Estabelece normas de finanças públicas voltadas para a responsabilidade na gestão fiscal e dá outras providências. Brasília, DF: Presidência da República, 2000. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/lcp/lcp101.htm. Acesso em: 28 jul. 2026.

BRASIL. Ministério da Economia. **Metodologia**: ajuste sazonal. Brasília, DF: ME, 2020. Disponível em: https://balanca.economia.gov.br/balanca/IPQ/arquivos/metodologia_ajuste_sazonal.pdf. Acesso em: 23 set. 2024.

BRASIL. Secretaria do Tesouro Nacional. **Manual de contabilidade aplicado ao setor público**. 11. ed. Brasília, DF: STN, 2024. Disponível em: <https://www.gov.br/tesouronacional/pt-br/contabilidade-e-custos/manuais/manual-de-contabilidade-aplicada-ao-setor-publico-mcasp-1>. Acesso em: 6 fev. 2026.

DHAKAL, Chuda Prasad. A naïve approach for comparing a forecast model. **International Journal of Thesis Projects and Dissertations (IJTPD)**, v. 5, n. 1. p. 1-3, jan./mar. 2017. Disponível em: <https://www.researchpublish.com/papers/a-naive-approach-for-comparing-a-forecast-model>. Acesso em: 23 set. 2024.

FAVERET, Guilherme; AGUILAR, Soraida; BAIÃO, Fernanda; SIMÕES, Paulo Henrique; MAÇAIRA, Paula. Estudo de similaridade da evolução da covid-19 nos estados brasileiros. *In*: Simpósio Brasileiro de Pesquisa Operacional, 53, João Pessoa, 2021. **Anais [...]**, v. 53. João Pessoa: Sociedade Brasileira de Pesquisa Operacional (SOBRAPO), 2021. Disponível em: <https://proceedings.science/sbpo/sbpo-2021/trabalhos/estudo-de-similaridade-da-evolucao-da-covid-19-nos-estados-brasileiros?lang=pt-br>. Acesso em: 23 set. 2024.

FÁVERO, Luiz Paulo; BELFIORE, Patrícia. **Manual de análise de dados**: estatística e modelagem multivariada com Excel®, SPSS® e Stata®. 1. ed. Rio de Janeiro: LTC, 2021.

FERREIRA, Pedro Costa; SPERANZA, Talitha; COSTA, Jonatha; TEIXEIRA, Fernando; MARCOLINO, Daiane. Pacote 'BETS: Brazilian Economic Time Series'. **The comprehensive R archive network**. Documentation. Reference manual. Versão 0.4.9. set. 2018. Disponível em: <https://cran.r-project.org/src/contrib/Archive/BETS/>. Acesso em: 23 set. 2024.

FERREIRA, Pedro Guilherme Costa; DUCA, Victor Eduardo Leite de Almeida. Modelos de suavização exponencial. *In*: FERREIRA, Pedro Guilherme Costa (org.). **Análise de séries temporais em R**: curso introdutório. 1. ed. São Paulo: GEN Atlas; FGV IBRE, 2020. p. 75-93.

FERREIRA, Pedro Guilherme Costa. **Processos não estacionários**. *In*: FERREIRA, Pedro Guilherme Costa (org.). *In*: FERREIRA, Pedro Guilherme Costa (org.). **Análise de séries temporais em R**: curso introdutório. 1. ed. São Paulo: GEN Atlas; FGV IBRE, 2020. p. 95-120.

FERREIRA, Pedro Guilherme Costa; MATTOS, Daiane Marcolino de. **Modelo SARIMA**. *In*: FERREIRA, Pedro Guilherme Costa (org.). **Análise de séries temporais em R**: curso introdutório. 1. ed. São Paulo: GEN Atlas; FGV IBRE, 2020. p. 121-143.

GERHARDT, Tatiana Engel; SILVEIRA, Denise Tolfo (org.). **Métodos de Pesquisa**. Série Educação a distância. Universidade Aberta do Brasil (UAB); Universidade Federal do Rio Grande do Sul (UFRGS) (coord.). Porto Alegre: Editora da UFRGS, 2009. Disponível em: www.ufrgs.br/cursopqdr/downloadsSerie/derad005.pdf. Acesso em: 27 jul. 2026.

HYNDMAN, Rob; ATHANASOPOULOS, George; BERGMEIR, Christoph; CACERES, Gabriel; CHHAY, Leanne; KUROPTEV, Kirill; MÜCKE, Maximilian; O'HARA-WILD, Mitchell; PETROPOULOS, Fotios; RAZBASH, Slava; WANG, Earo; YASMEEN, Farah; GARZA. Forecast: forecasting functions for time series and linear models. **The comprehensive R archive network**. Documentation. Reference manual. Versão 8.21.1. 2024. DOI: <https://doi.org/10.32614/CRAN.package.forecast>. Disponível em: <https://cran.r-project.org/web/packages/forecast/index.html>. Acesso em: 23 set. 2024.

HYNDMAN, Rob J.; KHANDAKAR, Yeasmin. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, p. 1-22, jul. 2008. DOI: <https://doi.org/10.18637/jss.v027.i03>. Disponível em: <https://www.jstatsoft.org/article/view/v027i03>. Acesso em: 23 set. 2024.

HYNDMAN, Rob. J.; ROSTAMI-TABAR, Bahman. Forecasting interrupted time series. **Journal of the Operational Research Society**, v. 76, n. 4, p. 790-803, set. 2024. DOI: <https://doi.org/10.1080/01605682.2024.2395315>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01605682.2024.2395315>. Acesso em: 23 set. 2024.

KIM, Sungil; KIM, Heeyoung. A new metric of absolute percentage error for intermittent demand forecasts. **International Journal of Forecasting**, v. 32, n. 3, p. 669-679, jul./set. 2016. DOI: <https://doi.org/10.1016/j.ijforecast.2015.12.003>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169207016000121?via%3Dihub>. Acesso em: 14 mar. 2025.

KLIMBERG, Ronald K.; SILLUP, George P.; BOYLE, Kevin J.; TAVVA, Vinay. Forecasting performance measures: what are their practical meaning? In: LAWRENCE, Kenneth D.; KLIMBERG, Ronald K (eds.). **Advances in business and management forecasting**. 7. ed. Leeds: Emerald Books, 2010. p. 137-147. DOI: [https://doi.org/10.1108/S1477-4070\(2010\)0000007012](https://doi.org/10.1108/S1477-4070(2010)0000007012). Disponível em: <https://www.emerald.com/books/edited-volume/11151/chapter-abstract/80949903/Forecasting-performance-measures-what-are-their?redirectedFrom=fulltext>. Acesso em: 14 mar. 2025.

KONIAGINA, Maria N. Forecast of budget revenues from taxes in the context of economy digitalization. **IOP Publishing**, IOP conference series: materials science and engineering, v. 940, 012040. 2020. DOI: <https://doi.org/10.1088/1757-899X/940/1/012040>. Disponível em: <https://iopscience.iop.org/article/10.1088/1757-899X/940/1/012040>. Acesso em: 23 set. 2024.

LEVY, Karen; CHASALOW, Kyla E.; RILEY, Sarah. Algorithms and decision making in the public sector. **Annual review of law and social science**, v. 17, p. 309-334, out. 2021. DOI: <https://doi.org/10.1146/annurev-lawsocsci-041221-023808>. Disponível em: <https://www.annualreviews.org/content/journals/10.1146/annurev-lawsocsci-041221-023808>. Acesso em: 14 mar. 2025.

LIU, Shiyu; LIU, Ou; CHEN, Junyang. Review on business analytics: definitions, techniques, applications and challenges. **Mathematics**, v. 11, n. 4, p. 1-20, fev. 2023. DOI: <https://doi.org/10.3390/math11040899>. Disponível em: <https://www.mdpi.com/2227-7390/11/4/899>. Acesso em: 23 set. 2024.

LOPES, Manuela de Mesquita; BRANCO, Verônica Teixeira Franco Castelo; SOARES, Jorge Barbosa. Utilização dos testes estatísticos de Kolmogorov-Smirnov e Shapiro-Wilk para verificação da normalidade para materiais de pavimentação. **Revista Transportes**, São Paulo, v. 21, n. 1, p. 59-66, abr. 2013. DOI: <https://doi.org/10.4237/transportes.v21i1.566>. Disponível em: <https://transportes.anpet.org.br/anpet/article/view/566>. Acesso em: 23 set. 2024.

MATTOS, Daiane Marcolino de; FERREIRA, Pedro Guilherme Costa. Ajuste sazonal. In: FERREIRA, Pedro Guilherme Costa (org.). **Análise de séries temporais em R**: curso introdutório. 1. ed. São Paulo: GEN Atlas; FGV IBRE, 2020. p. 145-163.

MORETTIN, Pedro A.; TOLOI, Clélia M. C. **Análise de séries temporais**: modelos lineares univariados. Volume 1. 3. ed. São Paulo: Bluncher, 2018.

MORETTIN, Pedro A.; TOLOI, Clélia M. C. **Análise de séries temporais**: modelos multivariados e não lineares. Volume 2. 1. ed. São Paulo: Bluncher, 2020.

MUÑOZ, Laura Alcaide; BOLÍVAR, Manuel Pedro Rodríguez; ARELLANO; Cinthia L. Villamayor. Factors in the adoption of open government initiatives in Spanish local governments. **Government information quarterly**, v. 39, n. 4, p. 1-13, out. 2022. DOI: <https://doi.org/10.1016/j.giq.2022.101743>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0740624X2200079X?via%3Dihub>. Acesso em: 5 mar. 2025.

NASCIMENTO, Maria de Nazaré Souza; BOENTE, Diego Rodrigues. Fatores associados aos erros de previsão orçamentária da receita do setor público. **Administração pública e gestão social**, Universidade Federal de Viçosa, v. 14, n. 2, p. 1-15, abr./jun. 2022. Disponível em: <https://doi.org/10.21118/apgs.v14i2.12945>. Acesso em: 23 set. 2024.

O'HARA-WILD, Mitchell; HYNDMAN, Rob; WANG, Earo; CACERES, Gabriel; BERGMEIR, Christoph; HENSEL, Tim-Gunnar; HYNDMAN, Timothy. Fable: forecasting models for tidy time series. **The comprehensive R archive network**. Documentation. Reference manual. Versão 0.3.3. 2023. DOI: <https://doi.org/10.32614/CRAN.package.fable>. Disponível em: <https://cran.r-project.org/web/packages/fable/index.html>. Acesso em: 23 set. 2024.

OLIVEIRA JUNIOR, João Paulo de; LEVINO, Natallya de Almeida. Impacto da pandemia covid-19 nas finanças dos municípios do Nordeste: uma análise da efetividade dos critérios de distribuição do auxílio financeiro. **Revista Brasileira de Planejamento e Desenvolvimento**, Curitiba, v. 13, n. 2, p. 369-400, maio/ago., 2024. Disponível em: <https://periodicos.utfpr.edu.br/rbpd/article/view/16231/10175>. Acesso em: 23 set. 2024.

SÁ, Rogério de Oliveira; AMORIM, Junior José; SANTOS, Cleidiany Dias dos; ZAMBRIM, Dejan Arruda de Carli; GOMES, Vallência Maira. **Metodologia utilizada nas estimativas de receitas e despesas (2021-2025)**. Cuiabá: Secretaria de Estado de Fazenda, 2020. Disponível em: <https://www5.sefaz.mt.gov.br/documents/6071037/15333979/Metodologias+utilizada+s+nas+proje%C3%A7%C3%B5es+04.09.2020.pdf/38604051-d9da-f912-e9e0-e0150e1c1148>. Acesso em: 23 set. 2024.

SÃO PAULO. Fundação Sistema Estadual de Análise de Dados. **Tabela – PIB 2020**. São Paulo, SP: Fundação Seade, 2020a. Disponível em: <https://repositorio.seade.gov.br/dataset/pib-municipal-ate-2021/resource/13af6a0f-e731-4fc7-8664-73e57de8f465>. Acesso em: 23 set. 2024.

SÃO PAULO. Fundação Sistema Estadual de Análise de Dados. **Taxa de crescimento populacional – 2000 a 2050**. São Paulo, SP: Fundação Seade, 2020b. Disponível em: <https://repositorio.seade.gov.br/dataset/populacao-por-idade-sexo/resource/2a0551df-ec74-473c-b0c3-387f0f128523>. Acesso em: 23 set. 2024.

SÃO PAULO. Tribunal de Contas do Estado de São Paulo. **Conjunto de dados**. São Paulo, SP: TCE-SP, 2020c. Disponível em: <https://transparencia.tce.sp.gov.br/conjunto-de-dados>. Acesso em: 23 set. 2024.

SÃO PAULO. Tribunal de Contas do Estado de São Paulo. **Projeto Audeesp**. Tabela de escrituração contábil. São Paulo, SP: TCE-SP, 2007. Disponível em: https://www.tce.sp.gov.br/sites/default/files/audesp-documentacao/tabelas_escrituracao_contabil_sistema_audesp_versao_janeiro_2007.pdf. Acesso em: 23 set. 2024.

SARTORIS, Alexandre. **Estatística e introdução à econometria**. 1. ed. São Paulo: Saraiva, 2003.

SAX, Christoph; EDDELBUETTEL, Dirk. Seasonal adjustment by X-13ARIMA-SEATS in R. **Journal of Statistical Software**, Áustria, v. 87. n. 11, p. 1-17, dez. 2018. DOI: <http://doi.org/10.18637/jss.v087.i11>. Disponível em: <https://www.jstatsoft.org/article/view/v087i11>. Acesso em: 23 set. 2024.

SOUZA, Celso Correia; CARNEIRO JUNIOR, João Bosco Arbués; CRISTALDO, Márcia Ferreira; CASTELÃO, Raul Asseff; FRAINER, Daniel Massen; VIAGNÓ, Hevelynne Henn da Gama. Previsão de produção de cana-de-açúcar e seus derivados, através de ARIMA, no período de 2020 a 2025, na macrorregião Centro-Sul do Brasil. **Research, society and development**, Vargem Grande Paulista, v. 11, n. 4, e6211427048, mar. 2022. DOI: <https://doi.org/10.33448/rsd-v11i4.27048>. Disponível em: <https://rsdjournal.org/rsd/article/view/27048>. Acesso em: 5 mar. 2025.

STATISTICS KINGDOM. Multiple linear regression calculator. **Statistics Kingdom**, 2017. Aplicativo. Disponível em: https://www.statskingdom.com/410multi_linear_regression.html. Acesso em: 27 set. 2024.

TOLEDO JÚNIOR, Flávio Corrêa de. Os conteúdos da Lei Orçamentária Anual. **Revista do TCU**, Brasília, v. 118, n. 1, p. 35-44, maio/ago. 2010. Disponível em: <https://revista.tcu.gov.br/ojs/index.php/RTCU/article/view/231>. Acesso em: 28 set. 2024.

VOLPATO, Gilson Luiz. O método lógico para redação científica. **Revista Eletrônica de Comunicação Informação & Inovação em Saúde**, Rio de Janeiro, v. 9, n. 1, p. 1-14, jan./mar. 2015. DOI: <https://doi.org/10.29397/reciis.v9i1.932>. Disponível em: <https://www.recis.icict.fiocruz.br/index.php/reciis/article/view/932>. Acesso em: 1º de novembro de 2024.

CONTRIBUIÇÃO DE AUTORIA (CRediT)

Otoniel Arruda Costa: concepção; metodologia; investigação; curadoria de dado; análise formal; software; redação original; administração do projeto; recursos; e visualização.

Henrique Raymundo Góia: metodologia; análise formal; software; revisão e edição; administração do projeto; supervisão; e validação.

FINANCIAMENTO

Esta pesquisa não recebeu financiamento ou apoio específico de agência de fomento, instituição pública ou privada, empresa ou organização sem fins lucrativos.

CONFLITO DE INTERESSES

Não há conflito de interesses relacionado ao desenvolvimento, aos resultados ou à publicação deste trabalho.

DISPONIBILIDADE DOS DADOS

Os dados que subsidiaram a escolha dos municípios objeto da pesquisa estão disponíveis em dois repositórios. O primeiro deles é o Seade Repositório, do qual foram obtidos os dados populacionais dos municípios do estado de São Paulo em 2020, podendo ser acessados por meio do link <https://repositorio.seade.gov.br/dataset/populacao-por-idade-sexo/resource/2a0551df-ec74-473c-b0c3-387f0f128523> (Taxa de Crescimento populacional – 2000 a 2050), e os dados dos PIBs dos municípios paulistas em 2020,

por meio do link <https://repositorio.seade.gov.br/dataset/pib-municipal-ate-2021/resource/13af6a0f-e731-4fc7-8664-73e57de8f465> (Tabela PIB - 2020). O segundo foi o portal do Tribunal de Contas do Estado de São Paulo, por meio do qual foram obtidos os dados das receitas anuais dos municípios paulistas, podendo ser acessados no link <https://transparencia.tce.sp.gov.br/conjunto-de-dados>. Os códigos de programação (script) da modelagem proposta neste artigo estão no repositório Zenodo (<https://zenodo.org/records/21877515>).

APROVAÇÃO ÉTICA

Esta pesquisa não envolve procedimento, dado ou participante que exige aprovação ética.

PUBLICAÇÃO DE PREPRINT

Este trabalho não foi disponibilizado previamente em servidor ou plataforma de preprints.

USO DE IA

Não foi utilizada ferramenta de inteligência artificial generativa no desenvolvimento deste trabalho.

HISTÓRICO DE AVALIAÇÃO DO TRABALHO

Data de submissão: 4/11/2024

Data de publicação: 24/9/2026

Editor responsável: Alessandra Caballero Brügger Freitas (editora-executiva)

[Link para o histórico de avaliação completo](#)