

# Previsão de Despesas Públicas do Estado de Sergipe

**Anthony Eduardo Medeiros Pantaleão<sup>1</sup>, Arthur Fernando da Silva Santos<sup>1</sup>,  
Max Castor Rodrigues Junior<sup>1</sup>, Yúri Faro Dantas de Sant'Anna<sup>1</sup>**

<sup>1</sup>Coordenação de Tecnologia da Informação – Centro Universitário Estácio de Sergipe  
Aracaju – SE – Brazil

{202208703208, 202304252963}@alunos.estacio.br

{max.carojun, yur.anna}@professores.estacio.br

**Abstract.** *Forecasting public expenditures is a challenge in fiscal management, especially at the state level, where the literature is limited. This study aims to compare different time series models in projecting public expenditures for the State of Sergipe. Five methods were used: ARIMA, Holt-Winters, ETS, LSTM, and SVR, using monthly data from 2014 to 2024. To evaluate the performance of the models, the Mean Absolute Percentage Error (MAPE) and Root Mean Squared Error (RMSE) metrics were used. The ETS model demonstrated superiority in public expenditure forecasting with an accuracy of 8.45% (MAPE). These results indicate potential for optimizing budget preparation, contributing to fiscal sustainability.*

**Resumo.** *A previsão das despesas públicas é um desafio na gestão fiscal, especialmente em contextos estaduais onde a literatura ainda é escassa. Este estudo busca comparar diferentes modelos de séries temporais na projeção das despesas públicas do Estado de Sergipe. Foram utilizados cinco métodos: ARIMA, Holt-Winters, ETS, LSTM e SVR, aplicados a uma série mensal de 2014 a 2024. Para avaliar a performance, foram empregadas as métricas de Erro Percentual Absoluto Médio (MAPE) e Raiz do Erro Quadrático Médio (RMSE). O modelo ETS demonstrou superioridade na previsão de despesas públicas com precisão de 8.45% (MAPE). Esses resultados indicam potencial para otimizar a elaboração orçamentária, contribuindo para a sustentabilidade fiscal.*

## 1. Introdução

A administração eficaz das finanças públicas requer a habilidade de prever mudanças nas receitas e despesas, possibilitando harmonia entre a elaboração do orçamento e a situação fiscal dos órgãos governamentais. Logo, a previsão de despesas mensais com base em séries temporais se torna um instrumento fundamental para o planejamento e a sustentabilidade fiscal.

Diversos tipos de modelos preditivos podem ser utilizados para previsões de séries temporais deste escopo. Modelos tradicionais de suavização exponencial, como Holt-Winters, têm se mostrado eficazes em séries com componentes sazonais claramente estabelecidos. No entanto, podem não identificar padrões não lineares complexos ou alterações estruturais súbitas [da Silva and Costa 2010]. Os modelos ARIMA e suas variações sazonais (SARIMA) proporcionam uma estrutura estatística sólida para modelar dependências autorregressivas e médias móveis. [Box et al. 1976]

Em trabalhos recentes, algoritmos de aprendizado de máquina estão ganhando destaque na previsão de séries temporais públicas. Dentre as estratégias adotadas as redes neurais, apresentam superioridade em séries com comportamentos não lineares e mudanças de regime. [Thayyib et al. 2023] Por outro lado, as técnicas baseadas em vetores de suporte, como o SVR, projetam os dados em espaços de alta dimensão para identificar limites de previsão que reduzem erros absolutos e quadráticos, sendo recomendadas para situações com ruído e outliers. [Drucker et al. 1997]

Embora existam vários estudos sobre a análise de séries temporais no âmbito da previsão de arrecadação de tributos[Bernardino et al. 2021, Pimentel et al. 2023], há uma escassez de pesquisas voltadas para a previsão de despesas públicas, especialmente no cenário do nordeste do Brasil. O propósito deste estudo é realizar uma comparação entre cinco métodos: ARIMA, Holt–Winters, ETS, LSTM e SVR com o objetivo de avaliar o que oferece o melhor desempenho na previsão de despesas públicas do estado de Sergipe.

O presente trabalho está organizado em seções. Na seção 2 é feita a revisão comparativa da literatura. A seção 3 detalha a metodologia adotada, incluindo a base de dados, o pré-processamento, os modelos avaliados (ARIMA, Holt–Winters, ETS, SVR e LSTM) e o procedimento de grid-search. Em seguida, a seção 3.5 descreve o processo de validação e métricas de desempenho. Na seção 4 são apresentados os resultados obtidos. Por fim, a seção 5 traz as conclusões e sugestões para trabalhos futuros.

## 2. Revisão Comparativa

A previsão de gastos públicos é um recurso fundamental à gestão pública, esta orienta a elaboração da Lei Orçamentária Anual [LOA ] e a execução de políticas fiscais em conformidade com a Lei de Responsabilidade Fiscal [LRF ]. Estimativas de despesa são fundamentais para garantir o equilíbrio fiscal e estabelecer limites de gastos estabelecidos pela LRF [Arraes and Matias-Pereira 2024]. No entanto, estudos indicam que estimativas macroeconômicas são superestimadas, de modo a inflar as previsões de despesas e gerando imprevisibilidade orçamentária [Alves 2021]. Diante desse cenário, modelos de previsões de séries temporais se apresentam como uma abordagem que permite maior efetividade na previsão orçamentária e fiscal. [Silva 2024]

Algoritmos de aprendizado de máquina, como SVR e LSTM, têm sido utilizados para capturar relações não lineares em séries temporais. A Regressão de Vetores de Suporte (SVR), permite reduzir erros quadráticos, mostrando boa robustez a outliers [Drucker et al. 1997]. Redes LSTM, podem armazenar dependências de longo prazo e identificar mudanças de regime em séries complexas [Hochreiter and Schmidhuber 1997]. Contudo, modelos como o ETS podem apresentar superioridade aos modelos de aprendizado de máquina em séries temporais curtas, com forte componente sazonal e tendência bem definida, especialmente quando os padrões são lineares e não há muitos dados históricos disponíveis. [Makridakis et al. 2020]

Apesar da ampla literatura voltada à previsão de receitas públicas[Bernardino et al. 2021, Pimentel et al. 2023], estudos que abordam especificamente a previsão de despesas públicas ainda são escassos, dificultando a comparação direta com os resultados do presente artigo. A seguir, destacam-se alguns dos trabalhos que investigam séries temporais de despesas públicas, apontando metodologia, resultados e limitações encontradas.

No estudo de Okamura [Okamura et al. 2024] foi realizada uma análise de séries temporais das despesas mensais da Agência Brasileira de Promoção de Exportação e Investimentos (ApexBrasil). O melhor modelo encontrado foi o ARIMA(0,1,1)(1,0,0), com MAPE de 17,26% e RMSE de R\$ 4 milhões. Foi identificado padrões sazonais e de tendência de longo prazo, contudo, o estudo se restringe a uma única agência federal, dificultando a generalização para outros perfis de despesa.

Costa [Costa 2021] examinou o impacto da pandemia de Covid-19 nas despesas da Secretaria da Saúde do Estado do Rio Grande do Sul, no período de janeiro de 2015 a dezembro de 2020. Para as despesas de capital, ajustou um ARIMA(2,0,1) com AIC = 101,78 e um modelo autorregressivo com limiar (TAR) (2,0,1) com AIC = 59,88. Para despesas correntes, utilizou ARIMA(2,0,2) (AIC = 2,25) e TAR(1,0,1) (AIC = -45,23). Porém, o estudo ficou limitado ao setor de saúde em um único estado, não abrangendo outras áreas de despesa nem discutindo detalhadamente a escolha de parâmetros ou critérios de seleção de modelos.

Silva et al. [Silva et al. 2022] compararam o desempenho dos modelos Auto ETS e Auto ARIMA para prever despesas de uma prefeitura no interior do Ceará, considerando séries mensais de despesas correntes e de capital. Os autores avaliaram métricas como RMSE (27.275.560,60) e MAPE (23,63% para Auto ARIMA e 36,7% para Auto ETS). Concluíram que o Auto ARIMA apresentou melhor desempenho em termos de MAPE, mas reconheceram que a série curta e o foco em uma única prefeitura limitam a robustez das conclusões, impedindo a aplicação direta a outros municípios ou diferentes subáreas de despesa.

Silva [Silva 2024] desenvolveu modelos de previsão de fluxo de caixa no setor público. Empregou ARIMA e modelos de suavização exponencial, concluindo que variantes SARIMA apresentaram melhor precisão. Todavia, o autor não detalhou completamente os critérios de seleção de hiperparâmetros, métricas de avaliação utilizadas nem forneceu informações sobre validação cruzada, o que dificulta a replicação e comparação de resultados.

Lima e Oliveira [Lima and Oliveira 2021] focaram na previsão da dívida pública bruta brasileira, aplicando transformação logarítmica para estabilizar a variância e removendo tendência polinomial antes de ajustar um ARMA(1,2). Obtiveram erro percentual absoluto médio (MAPE) de 1,51% em seis observações fora da amostra. Como o escopo era a dívida pública, não abordaram diretamente de séries de despesas e nem compararam diferentes abordagens de modelagem de gastos, limitando a aplicabilidade ao presente estudo sobre despesa pública.

Dragulin e Štefan [Drăgulin and Štefan 2021] investigaram relações de causalidade entre fatores socioeconômicos e a evolução de receitas e despesas públicas, utilizando uma variedade de modelos de aprendizado de máquina, incluindo modelos de média móvel estendida, regressão linear multicamadas, RNN e LSTM. Entre esses, o modelo RRN (Recurrent Random Network) obteve o menor erro absoluto médio (AAE = 53.706). Apesar da relevância para cenários de Big Data, o estudo não segmentou especificamente séries de despesas públicas, mesclando receitas e despesas em uma mesma base, o que dificulta a avaliação isolada do comportamento de gastos.

### 3. Metodologia

#### 3.1. Base de Dados

Os dados mensais de despesas do Estado de Sergipe foram obtidos por meio do portal de transparéncia do Estado de Sergipe [Portal da Transparéncia ] no período de janeiro de 2014 a dezembro de 2024. Cada registro foi composto por duas colunas: Ano/mês e Valor Pago. Após importação, as séries foram tratadas para conter índices temporais e em seguida, normalizadas ou diferenciadas conforme exigido por cada método.

A implementação da metodologia desse trabalho está disponível em repositório público [Pantaleão A. ]. O código foi desenvolvido em Python 3.7 utilizando as seguintes bibliotecas principais: pandas, numpy e matplotlib para manipulação e visualização de dados. statsmodels para ARIMA e Holt–Winters. pmdarima.auto\_arima para busca automática de ordens ARIMA. O método ETSModel da biblioteca statsmodels. Scikit-learn (SVR, MinMaxScaler). Tensorflow-keras para construção e treino de modelos LSTM.

#### 3.2. Pré-Processamento dos Dados e Divisão de Conjuntos

Inicialmente os valores foram padronizados para um mesmo índice temporal, em seguida, o conjunto completo de 2014/01 a 2024/12 foi particionado em três grupos: o período de 2014 à 2022 destinaram-se ao treinamento, 2023 para validação e o ano de 2024 para a fase de testes.

#### 3.3. Modelos Avaliados

Para capturar diferentes características das despesas mensais do Estado de Sergipe, foram avaliados cinco modelos de séries temporais: ARIMA, Holt–Winters, ETS, LSTM e o SVR. Estes serão melhor elucidados nas subseções a seguir.

##### 3.3.1. ARIMA

O modelo ARIMA (*AutoRegressive Integrated Moving Average*) combina três componentes: autorregressão (AR), diferenciação (I) e médias móveis (MA) [Box et al. 1976]. Sendo definido como:

$$(1 - \phi_1 L - \phi_2 L^2 - \cdots - \phi_p L^p) (1 - L)^d y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \cdots + \theta_q L^q) \varepsilon_t, \quad (1)$$

Sendo  $L$  o operador defasagem ( $L y_t = y_{t-1}$ ),  $p$  e  $q$  são as ordens dos termos AR e MA,  $d$  é a ordem de diferenciação,  $\{\phi_i\}$  e  $\{\theta_j\}$  são os coeficientes AR e MA,  $c$  é uma constante opcional, e  $\varepsilon_t$  é ruído branco. Nesta pesquisa, empregou-se a função pmdarima.auto\_arima para dos valores  $p$ ,  $d$  e  $q$ , selecionando o melhor modelo segundo o critério de informação AICc.

##### 3.3.2. Holt–Winters

O método de Holt–Winters[Winters 1960], também conhecido como suavização exponencial tripla, é uma extensão do modelo de Holt que incorpora um componente de sazonalidade(aditiva ou multiplicativa). Esse modelo estima recursivamente três componentes

principais: o nível  $\ell_t$ , a tendência  $b_t$  e a sazonalidade  $s_t$ , conforme as seguintes equações na versão aditiva:

$$\begin{aligned}\ell_t &= \alpha(Y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1}), \\ b_t &= \beta(\ell_t - \ell_{t-1}) + (1 - \beta)b_{t-1}, \\ s_t &= \gamma(Y_t - \ell_t - b_{t-1}) + (1 - \gamma)s_{t-m},\end{aligned}\tag{2}$$

onde  $\alpha$ ,  $\beta$  e  $\gamma$  são os parâmetros de suavização, e  $s$  representa o período sazonal da série temporal. A previsão  $h$  passos à frente é então dada por:

$$\hat{Y}_{t+h} = \ell_t + h b_t + s_{t+h-m}.\tag{3}$$

No presente trabalho, utilizou-se o método Holt da biblioteca statsmodels para avaliar o modelo de Holt puro (sem sazonalidade) e também foi utilizado o ExponentialSmoothing para ajustar a versão completa de Holt–Winters (com componente sazonal aditivo), comparando seus desempenhos via RMSE e MAPE.

### 3.3.3. ETS

O modelo ETS (Error–Trend–Seasonality) captura componentes de erro, tendência (aditiva ou multiplicativa) e sazonalidade (aditiva ou multiplicativa) em séries temporais, oferecendo flexibilidade para representar padrões complexos de variação ao longo do tempo [Hyndman and Athanasopoulos 2018]. Na versão aditiva, é calculado como:

$$\begin{aligned}y_t &= \ell_{t-1} + b_{t-1} + s_{t-m} + \varepsilon_t, \\ \ell_t &= \ell_{t-1} + b_{t-1} + \alpha \varepsilon_t, \\ b_t &= b_{t-1} + \beta \varepsilon_t, \\ s_t &= s_{t-m} + \gamma \varepsilon_t,\end{aligned}\tag{4}$$

Sendo  $y_t$  o valor observado,  $\ell_t$  o componente de nível,  $b_t$  o componente de tendência,  $s_t$  o componente sazonal com período  $m$ ,  $\varepsilon_t$  o erro aleatório, e  $\alpha, \beta, \gamma \in (0, 1)$  os parâmetros de suavização. Para previsão  $h$  utiliza-se

$$\hat{y}_{t+h} = \ell_t + h b_t + s_{t+h-m}.\tag{5}$$

Utilizou-se o método ETSModel da biblioteca statsmodel para o modelo.

### 3.3.4. Support Vector Regression (SVR)

O SVR estende a Support Vector Machine para problemas de regressão, projetando os dados em um espaço de alta dimensão através de um kernel e encontrando uma função que minimiza o erro dentro de uma margem  $\varepsilon$  [Drucker et al. 1997]. Utilizou-se a biblioteca sklearn para o modelo.

### 3.3.5. LSTM

As redes LSTM (Long Short-Term Memory) são um tipo de RNN especialmente desenhado para capturar dependências de longo prazo em séries temporais, através de células de memória e portas de entrada, esquecimento e saída [Hochreiter and Schmidhuber 1997]. Utilizou-se a biblioteca tensorflow.keras para o modelo.

### 3.4. Grid Search

Para garantir a escolha dos melhores parâmetros para cada modelo, foi realizada uma busca exaustiva de hiperparâmetros por meio da técnica de *Grid Search*. Essa abordagem consiste em testar todas as combinações de parâmetros, avaliando o desempenho de cada uma com base nas métricas MAPE e RMSE aplicadas sobre um conjunto de validação. A Tabela 1 apresenta os hiperparâmetros considerados para cada modelo e as melhores combinações encontradas.

**Tabela 1. Parâmetros utilizados no Grid Search e melhores combinações por modelo.**

Modelo	Componentes	Parâmetros Testados	Melhor Combinação
ETS	Erro	add, mul	mul
	Tendência	add	add
	Sazonalidade	add	add
	Inicialização	estimated, heuristic	heuristic
	Período	12	12
Holt-Winters	Tendência	add, mul, None	None
	Sazonalidade	add, mul, None	mul
	Período	12	12
SVR	Kernel	rbf, sigmoid, linear, poly	sigmoid
	Gamma	scale, auto	auto
	Shrinking	True, False	True
	Verbose	True, False	True
LSTM	Unidades	20,50,100	20
	Batch-size	16,32	32
	Epochs	50,100	50
ARIMA	p	Método automático	4
	d		1
	q		1
	Step-wise	False	

### 3.5. Validação e Métricas

O *Mean Absolute Percentage Error* (MAPE) quantifica, em porcentagem, o erro médio absoluto entre os valores observados  $y_t$  e previstos  $\hat{y}_t$ , facilitando comparações entre séries de diferentes escalas [Makridakis et al. 1998]:

$$\text{MAPE} = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|. \quad (6)$$

O *Root Mean Squared Error* (RMSE) penaliza erros maiores de forma quadrática, retornando uma medida na mesma unidade de  $y_t$  e destacando discrepâncias significativas [Hyndman and Athanasopoulos 2018]:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}. \quad (7)$$

### 3.5.1. Análise de Ruído dos Resíduos

Para verificar desvios de normalidade na distribuição dos dados, foi utilizado o Teste de Jarque–Bera(JB)[Jarque and Bera 1980]. Adotou-se como critério de significância  $p < 0,05$ . No presente estudo, o cálculo do teste de Jarque–Bera foi realizado por meio do método `jarque_bera` da biblioteca `statsmodels`.

## 4. Resultados

A Tabela 2 apresenta os erros percentuais absolutos das previsões dos cinco modelos (ARIMA, ETS, Holt–Winters, SVR e LSTM) para cada mês de 2024. Observa-se que, em janeiro de 2024, todos os modelos exibiram erros elevados (entre 40% e 83%), sugerindo dificuldades iniciais na adaptação aos dados do período. Ao longo dos meses, o ETS e o SVR mostraram desempenho mais estável, enquanto Holt–Winters e LSTM alternaram entre boas previsões e picos de erro. O ARIMA apresentou erro baixo em fevereiro e março, mas voltou a aumentar significativamente em dezembro.

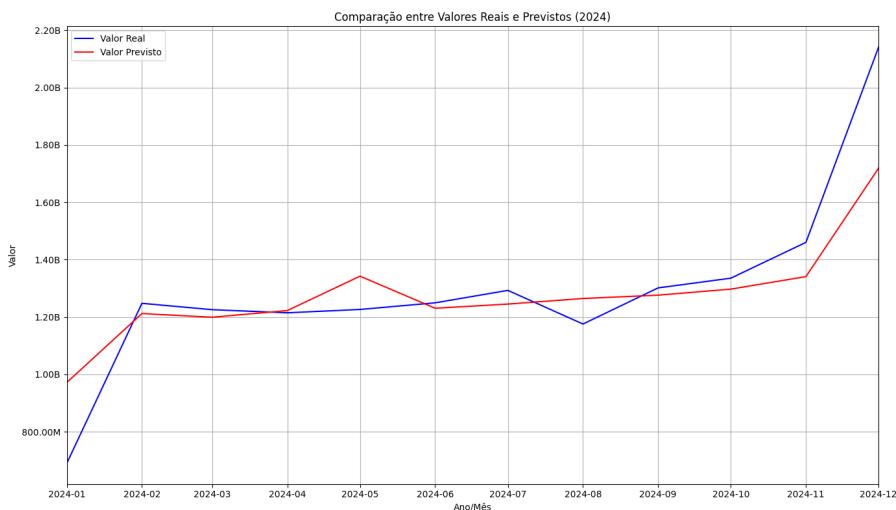
**Tabela 2. Erros percentuais absolutos das previsões por modelo para cada mês de 2024.**

Ano/Mês	ARIMA (%)	ETS (%)	Holt–Winters (%)	SVR (%)	LSTM (%)
1/2024	67.58	40.87	83.62	42.17	63.13
2/2024	0.24	2.86	2.58	9.21	6.85
3/2024	0.39	2.15	5.31	0.91	3.69
4/2024	9.39	0.64	6.96	5.18	2.02
5/2024	16.63	9.47	6.51	0.09	1.50
6/2024	9.05	1.51	4.97	3.85	2.54
7/2024	5.29	3.69	1.79	8.14	5.12
8/2024	15.40	7.57	12.24	3.58	5.41
9/2024	6.05	1.95	1.60	7.45	3.94
10/2024	5.86	2.85	0.81	5.01	5.45
11/2024	2.85	8.18	9.18	0.89	13.18
12/2024	33.41	19.71	38.00	30.43	41.44

**Tabela 3. RMSE e MAPE do conjunto de validação e das previsões para 2024 por modelo.**

Modelo	RMSE (Validação)	MAPE (Validação)	RMSE (Previsões 2024)	MAPE (Previsões 2024)
ARIMA	285.259.503,74	26,08%	265.837.380,48	14,35%
ETS	112.157.421,76	7,87%	158.110.410,00	8,45%
Holt–Winters	143.315.584,85	8,98%	212.553.847,09	13,58%
SVR	131.635.226,48	11,59%	215.170.207,48	9,74%
LSTM	202.510.084,79	18,11%	294.622.507,40	12,86%

Os resultados apresentados na Tabela 3 mostram que o modelo ETS apresentou o melhor desempenho na fase de validação, com RMSE de 112.157.421,76 e MAPE de 7,87 %. Nas previsões para 2024, o ETS obteve, mais uma vez, o melhor resultado.



**Figura 1. Previsão dos valores da despesa do Estado de Sergipe por meio do modelo ETS. Comparação entre valores reais e previstos.**

A Figura 1 apresenta a comparação entre os valores reais e os valores previstos para as despesas utilizando o modelo ETS.

**Tabela 4. Resultados da análise de ruído dos resíduos por modelo.**

Modelo	Jarque-Bera	Valor P	Assimetria	Curtose
ARIMA	100.0509	0.0000	1.6861	6.2957
ETS	7.6482	0.0218	0.5671	3.6430
Holt-Winters	2.1655	0.3387	1.0241	3.3682
SVR	1.8587	0.3948	0.9187	3.5840
LSTM	3.0007	0.2231	1.2067	3.4201

Na Tabela 4, são apresentados o resultados da análise do ruído da validação dos modelos. Holt-Winters, SVR e LSTM têm resíduos compatíveis com normalidade (p-valor maior que 0,05), com leve assimetria e curtose próxima de 3. O ETS rejeita a normalidade de forma moderada (p-valor de 0,02) e ARIMA amplamente (p-valor = 0,00), demonstrando forte enviesamento.

## 5. Conclusão e Trabalhos Futuros

Este trabalho comparou o desempenho de diferentes modelos de previsão de séries temporais aplicados às despesas públicas do Estado de Sergipe, utilizando os modelos ETS, Holt-Winters, SVR, LSTM e ARIMA. Os resultados demonstraram que o modelo ETS apresentou desempenho superior, com menores erros de previsão (RMSE e MAPE), superando inclusive abordagens mais complexas como LSTM. Observou-se que este algoritmo foi capaz de prever os valores futuros de maneira satisfatória, mesmo em cenários sujeitos a diversos fatores externos e componentes subjetivos que impactam diretamente em seu comportamento.

Esses resultados representam um avanço para o aprimoramento da previsão orçamentária, contribuindo para o planejamento financeiro de médio e longo prazo. Os resultados alcançados podem fortalecer a tomada de decisão governamental ao oferecer

maior previsibilidade das despesas, apoiando o equilíbrio fiscal e o uso mais eficiente dos recursos públicos.

Como continuidade deste trabalho, propõe-se o uso de modelos que permitam a inclusão de variáveis externas como inflação, repasses federais e eventos políticos, com o intuito de aprimorar a capacidade dos modelos. Além da possível aplicação de métodos de seleção dinâmica para seleção do melhor modelo ideal para cada observação.

## Referências

- Alves, G. H. T. (2021). Fatores associados ao erro de previsão de despesa orçamentária nos municípios brasileiros. *Caderno de Finanças Públicas*.
- Arraes, J. P. S. and Matias-Pereira, J. (2024). Desvendando a influência da lei de responsabilidade fiscal nos estados brasileiros: Inferências quanto a sustentabilidade do endividamento, a eficiência do gasto com pessoal e a gestão fiscal responsável. *Revista Contabilidade, Gestão e Governança*, 27(1):128–156.
- Bernardino, W., de Moura Soeiro, T., de Araújo, J. G. N., and dos Prazeres, R. V. (2021). Previsão da Arrecadação de ICMS para o Estado de Sergipe: Modelagem a partir da Metodologia de Box e Jenkins. *Revista Brasileira de Contabilidade e Finanças Públicas*.
- Box, G. E. P., Jenkins, G. M., and Reinsel, G. C. (1976). *Time Series Analysis: Forecasting and Control*. Holden-Day.
- Costa, R. R. d. (2021). Séries temporais: Análise das despesas da secretaria da saúde do estado do rio grande do sul antes e durante a pandemia do covid-19. Master's thesis, Instituto Metrópole Digital, UFRN, Natal, RN.
- da Silva, D. A. and Costa, D. F. (2010). A utilização do modelo holt winters na elaboração de um orçamento de resultado de uma cooperativa de crédito rural. In *Anais do Congresso Brasileiro de Custos (ABC)*, Belo Horizonte, MG. ABC.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A. J., and Vapnik, V. (1997). Support vector regression machines. In *Advances in Neural Information Processing Systems*, Cambridge, MA. MIT Press.
- Drăgulin, B. and řtefan, V. (2021). Analysis and forecasting of budget accounting systems using machine learning algorithms. *Hyperion Economic Journal*, 8(2):14–28.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Hyndman, R. J. and Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts, 2nd edition. Capítulo 7 (ETS models).
- Jarque, C. M. and Bera, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, 6(3):255–259.
- Lima, P. A. and Oliveira, R. S. (2021). Análise e previsão da série temporal da dívida pública brasileira. *Perspectiva Econômica*, 8(2):112–130.
- LOA. Lei nº 14.791, de 29 de dezembro de 2023 — Lei Orçamentária Anual de 2024. Brasília, DF, 2023.

LRF. Lei Complementar nº 101, de 4 de maio de 2000 — Lei de Responsabilidade Fiscal. Brasília, DF, 2000.

Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2020). Statistical and machine learning forecasting methods: Concerns and ways forward. *International Journal of Forecasting*, 36(1):1–27.

Makridakis, S., Wheelwright, S. C., and Hyndman, R. J. (1998). *Forecasting: Methods and Applications*. Wiley.

Okamura, A. B., Souza, L. M., and Ramos, T. F. (2024). Análise e projeção de séries temporais de despesas da agência brasileira de promoção de exportação e investimentos. *Revista Gestão Pública em Data*, 4(2):123–140.

Pantaleão A. Repositório GitHub. <https://github.com/anthonyMeds/previsao-despesas-sergipe-pibic>. Acesso em: 02 jun. 2025.

Pimentel, C., Lobato, F., and Junior, A. J. (2023). Aplicação de técnicas de aprendizagem de máquina com seleção de variáveis na previsão de receitas públicas de 8 capitais. In *Anais do Computer on the Beach*, volume 14, pages 264–271.

Portal da Transparência. Portal da Transparência – Despesas Mensais do Estado de Sergipe. <https://www.transparencia.se.gov.br/>. Acesso em: 02 jun. 2025.

Silva, J. P. d., Mendes, C. R., and Sousa, F. A. (2022). Avaliação de modelos de previsão de séries temporais aplicado às despesas de uma prefeitura no interior do ceará. *Brazilian Journal of Public Economics*, 6(1):45–60.

Silva, L. S. (2024). Modelos avançados de previsão de fluxo de caixa no setor público: Análise e projeções para a sustentabilidade fiscal em 2024. *International Journal of Public Finance*, 10(1):30–48.

Thayyib, P. V., Thorakkattle, M. N., Usmani, F., Yahya, A. T., and Farhan, N. H. S. (2023). Forecasting indian goods and services tax revenue using tbats, ets, neural networks, and hybrid time series models. *Cogent Economics & Finance*, 11(1):2285649.

Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3):324–342.