



DISSERTAÇÃO DE MESTRADO PROFISSIONAL

**ARQUITETURA INTELIGENTE E PREDITIVA PARA A QUALIDADE  
E GESTÃO DO GASTO PÚBLICO FEDERAL BRASILEIRO:  
UM ESTUDO COM APRENDIZADO DE MÁQUINA.**

**Kelly Santos de Oliveira Bezerra**

**Brasília, 30 de Outubro de 2025**

**UNIVERSIDADE DE BRASÍLIA**

**FACULDADE DE TECNOLOGIA**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**Kelly Santos de Oliveira Bezerra**

**ORIENTADOR: PROFESSOR DR. FÁBIO LÚCIO LOPES DE MENDONÇA**

**DISSERTAÇÃO DE MESTRADO PROFISSIONAL EM ENGENHARIA ELÉTRICA**

**PUBLICAÇÃO: PPEE.MP.101  
BRASÍLIA/DF,30 OUTUBRO de 2025**

UNIVERSIDADE DE BRASÍLIA  
Faculdade de Tecnologia

## DISSERTAÇÃO DE MESTRADO PROFISSIONAL

### **ARQUITETURA INTELIGENTE E PREDITIVA PARA A QUALIDADE E GESTÃO DO GASTO PÚBLICO FEDERAL BRASILEIRO: UM ESTUDO COM APRENDIZADO DE MÁQUINA.**

**Kelly Santos de Oliveira Bezerra**

*Dissertação de Mestrado Profissional submetida ao Departamento de Engenharia*

*Elétrica como requisito parcial para obtenção  
do grau de Mestre em Engenharia Elétrica*

#### Banca Examinadora

Prof. Dr. Fabio Lucio Lopes de Mendonça, FT/UnB \_\_\_\_\_  
*Presidente - Orientador*

Profa.Dra. Edna Dias Canedo, PPEE/UnB \_\_\_\_\_  
*Examinadora Interna*

Prof. Dr. Gilmar dos Santos Marques, UPIS - União \_\_\_\_\_  
Pioneira de Integração Social  
*Examinador Externo*

Prof. Dr. Daniel Alves da Silva, PPEE/UnB \_\_\_\_\_  
*Membro Suplente*

## FICHA CATALOGRÁFICA

BEZERRA, KELLY SANTOS DE OLIVEIRA

ARQUITETURA INTELIGENTE E PREDITIVA PARA A QUALIDADE E GESTÃO DO GASTO PÚBLICO FEDERAL BRASILEIRO: UM ESTUDO COM APRENDIZADO DE MÁQUINA. [Distrito Federal] 2025.

xvi, 64 p., 210 x 297 mm (ENE/FT/UnB, Mestre, Engenharia Elétrica, 2025).

Dissertação de Mestrado Profissional - Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. Qualidade de Gastos

2. Predição orçamentária

3. Aprendizado de máquina

4. Finanças públicas

5. Análise preditiva

I. ENE/FT/UnB

II. PPEE/UnB

## REFERÊNCIA BIBLIOGRÁFICA

BEZERRA, K.S.O.DE (2025). *ARQUITETURA INTELIGENTE E PREDITIVA PARA A QUALIDADE E GESTÃO DO GASTO PÚBLICO FEDERAL BRASILEIRO: UM ESTUDO COM APRENDIZADO DE MÁQUINA.*. Dissertação de Mestrado Profissional, Publicação: PPEE.MP.101, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 64 p.

## CESSÃO DE DIREITOS

AUTOR: Kelly Santos de Oliveira Bezerra

TÍTULO: ARQUITETURA INTELIGENTE E PREDITIVA PARA A QUALIDADE E GESTÃO DO GASTO PÚBLICO FEDERAL BRASILEIRO: UM ESTUDO COM APRENDIZADO DE MÁQUINA..

GRAU: Mestre em Engenharia Elétrica ANO: 2025

É concedida à Universidade de Brasília permissão para reproduzir cópias desta Dissertação de Mestrado Profissional e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Os autores reservam outros direitos de publicação e nenhuma parte dessa Dissertação de Mestrado Profissional pode ser reproduzida sem autorização por escrito dos autores.

---

Kelly Santos de Oliveira Bezerra

Dept. de Engenharia Elétrica (ENE) - FT

Universidade de Brasília (UnB)

Campus Darcy Ribeiro

CEP 70919-970 - Brasília - DF - Brasil

## **DEDICATÓRIA**

Dedico a minha querida mãe, Maria das Graças Santos de Oliveira (in memoriam), que sempre esteve ao meu lado e por sempre acreditar na minha capacidade.

Dedico este trabalho ao meu filho Mateus Santos Bezerra, minha filha, Anna Carolina Santos Bezerra, e ao meu marido Antônio Marcio Lopes Bezerra. Pelo impulsionamento para mais essa conquista em minha vida e também ao tempo que deixei de dedicar à nossa família para intensificar pesquisas e estudos para o sucesso da dissertação do tema.

Aos meus irmãos pelo apoio e incentivo que foram dados durante todo o tempo em que estive envolvido neste trabalho.

## **AGRADECIMENTOS**

Agradeço ao meu orientador, professor Dr. Fábio Lúcio Lopes de Mendonça, que me orientou de forma profissional e amiga nas horas mais complicadas durante este trabalho e aturou tantas dúvidas e problemas relativos ao assunto e outros detalhes pertinentes à criação desta dissertação.

Agradeço imensamente à Professora Edna Dias Canedo que sempre foi uma parceira e amiga nas horas mais complicadas durante este trabalho, ao Professor Daniel Alves da Silva, que contribuiu em diversas dúvidas e me auxiliou bastante com seus ensinamentos.

Aos demais Professores do Programa de Pós-Graduação Profissional em Engenharia Elétrica da Universidade de Brasília PPEE/UNB, Rafael Timóteo de Sousa Júnior, Georges D. Amvame Nze, Demétrio Antônio da Silva, Robson de Oliveira Albuquerque, William Ferreira Giozza, pelas grandes dicas, constante apoio, incentivo e amizade, essenciais para o desenvolvimento deste trabalho.

Agradeço o apoio técnico e computacional do Laboratório de Tecnologias para Tomada de Decisão - LATITUDE, da Universidade de Brasília, que conta com apoio do CNPq - Conselho Nacional de Pesquisa (Outorgas 312180/2019-5 PQ-2 e 465741/2014-2 INCT em Cibersegurança), da Advocacia Geral da União (Outorga AGU 697.935/2019), da Procuradoria Geral da Fazenda Nacional (Outorga PGFN 23106.148934/2019-67), da Polícia Federal (Outorga PF 03/2020), do Mestrado Profissional em Engenharia Elétrica, na área de concentração: Segurança Cibernética – 1ª Turma para Profissionais do Setor de Inteligência (Outorga ABIN 01/2019) ao Decanatos de Pesquisa e Inovação e de Pós-Graduação da Universidade de Brasília (Outorga 7129 FUB/EMENDA/DPI/COPEI/AMORIS) e do Projeto SISTER City – Sistemas Inteligentes Seguros e em Tempo Efetivo Real para Cidades Inteligentes (Outorga 625/2022) e à Fundação de Apoio à Pesquisa do Distrito Federal - FAP/DF

Aos parceiros do DAF/UnB (Jeremias, Lucas Teles, Iara Bastos, Guilherme) que me concederam a oportunidade de executar este trabalho como uma prova de conceito.

A minha parceira de disciplina Verônica Souza dos Santos e meu parceiro Diego Oliveira aos meus amigos e parceiros que me ajudaram durante essa jornada, Felipe Barreto, Orlando, Flávio Praciano, que contribuíram de forma fundamental para a conclusão deste trabalho: meus sinceros agradecimentos.

Agradeço, acima de tudo, a Deus!

---

## RESUMO

O orçamento público federal Brasileiro é o instrumento de planejamento que detalha a previsão dos recursos a serem arrecadados (impostos e outras receitas estimadas) e a destinação desses recursos (ou seja, em quais despesas esses recursos serão utilizados) a cada ano. Ao englobar receitas e despesas, o orçamento é peça fundamental para o equilíbrio das contas públicas e indica as prioridades do Governo para a sociedade. A gestão eficiente dos gastos é essencial para a sustentabilidade financeira de organizações públicas e privadas. Entretanto, a complexidade na alocação de recursos e a quantidade de dados envolvidos dificultam a tomada de decisão. Neste contexto, este estudo propõe uma metodologia para predição de gastos orçamentários utilizando algoritmos de aprendizado de máquina. A proposta é avaliada a partir de dados extraídos de um *Data Warehouse* especializado em finanças públicas brasileiras, contemplando variáveis quantitativas e qualitativas. Os objetivos incluem: identificar padrões de despesas; selecionar as melhores variáveis para predição; avaliar os modelos com base em métricas de desempenho; e comparar os resultados com os gastos do exercício vigente. Os resultados do trabalho demonstram que a gestão eficiente dos gastos é essencial para a sustentabilidade financeira de organizações públicas e privadas, garantindo a transparência pública, principalmente aprimorando as suas competências relacionadas à tecnologia da informação que visa apoiar decisões estratégicas, contribuindo para o uso mais inteligente dos recursos. Para isso será proposto uma arquitetura inteligente de interoperabilidade de dados, baseada em um *Data Lake*, capaz de realizar análises preditivas aplicadas às estruturas de gastos de órgãos do governo federal brasileiro.

**Palavras Chaves** - Qualidade do gasto; predição orçamentária; aprendizado de máquina; finanças públicas; análise preditiva

---

## ABSTRACT

The Brazilian federal public budget is the planning instrument that details the forecast of resources to be collected (taxes and other estimated revenues) and the allocation of these resources (i.e., the expenses these resources will be used for) each year. By encompassing revenues and expenses, the budget is a fundamental component for balancing public accounts and indicating the government's priorities for society. Efficient expenditure management is essential for the financial sustainability of public and private organizations. However, the complexity of resource allocation and the amount of data involved make decision-making difficult. In this context, this study proposes a methodology for predicting budget expenditures using machine

learning algorithms. The proposal is evaluated using data extracted from a data warehouse specialized in Brazilian public finances, including quantitative and qualitative variables. The objectives include: identifying expenditure patterns; selecting the best variables for prediction; evaluating the models based on performance metrics; and comparing the results with the current fiscal year's expenditures. The results of this study demonstrate that efficient expenditure management is essential for the financial sustainability of public and private organizations, ensuring public transparency, particularly by enhancing their information technology capabilities to support strategic decisions and contribute to the smarter use of resources. To this end, an intelligent data interoperability architecture will be proposed, based on a Data Lake, capable of performing predictive analyses applied to the expenditure structures of Brazilian federal government agencies.

**Keywords** - Quality of expenditure; budget prediction; machine learning; public finance; predictive analytics

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>2</b>
1.1	CONTEXTUALIZAÇÃO E PROBLEMA DE PESQUISA.....	3
1.2	JUSTIFICATIVA.....	4
1.3	OBJETIVOS .....	5
1.3.1	OBJETIVOS GERAL .....	5
1.3.2	OBJETIVOS ESPECÍFICOS.....	5
1.4	METODOLOGIA DE PESQUISA .....	6
1.5	PUBLICAÇÕES.....	7
1.6	ESTRUTURA DA DISSERTAÇÃO .....	8
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>9</b>
2.1	GESTÃO DE GASTOS PÚBLICOS E QUALIDADE DO GASTO .....	9
2.2	APRENDIZADO DE MÁQUINA E ANÁLISE PREDITIVA.....	11
2.2.1	ANÁLISE PREDITIVA E APLICAÇÕES PRÁTICAS .....	12
2.3	MODELOS DE SÉRIES TEMPORAIS (ARIMA, SARIMA).....	13
2.4	LARGE LANGUAGE MODELS (LLMs) NA ANÁLISE DE DADOS.....	15
2.5	DATA WAREHOUSES E GOVERNANÇA DE DADOS.....	17
2.6	TRABALHOS CORRELATOS.....	19
<b>3</b>	<b>PROPOSTA DE ARQUITETURA.....</b>	<b>22</b>
3.1	ARQUITETURA PROPOSTA .....	22
3.1.1	PROPOSTA DE ARQUITETURA DE INTEROPERABILIDADE .....	22
3.1.2	PROPOSTA DE ARQUITETURA DE SERVIÇOS SEGUROS .....	23
3.2	COLETA E PRÉ-PROCESSAMENTO DOS DADOS (MER E MTO).....	24
3.2.1	MODELO ENTIDADE-RELACIONAMENTO (MER) .....	25
3.2.2	GLOSSÁRIO/DICIONÁRIO DE DADOS (MTO).....	26
3.2.3	PROPOSTA DE ARQUITETURA DE ANÁLISE PREDITIVA .....	29
3.3	ANÁLISE EXPLORATÓRIA DOS DADOS .....	33
3.4	TÉCNICAS DE TRATAMENTO DE DADOS INCONGRUENTES E RESTOS A PAGAR .....	34
3.5	MODELOS PREDITIVOS E SUAS JUSTIFICATIVAS .....	35
3.5.1	ARIMA/SARIMA.....	35
3.5.2	LLMs COMO APOIO ANALÍTICO.....	36
3.5.3	PROTOCOLO DE VALIDAÇÃO TEMPORAL .....	37
3.6	CRITÉRIOS DE AVALIAÇÃO DO MODELO.....	38
3.7	GOVERNANÇA, SEGURANÇA, MLOPS E OBSERVABILIDADE .....	39
3.8	DISCUSSÃO CRÍTICA E LIMITAÇÕES .....	40

3.9	SÍNTESE DO CAPÍTULO .....	40
<b>4</b>	<b>ANÁLISE E RESULTADOS .....</b>	<b>41</b>
4.1	ANÁLISE COMPARATIVA DOS MODELOS .....	43
4.1.1	PROTOCOLO DE VALIDAÇÃO E ESTRATIFICAÇÕES .....	44
4.2	AVALIAÇÃO DE PREVISÕES PARA DESPESAS TÍPICAS .....	45
4.3	AVALIAÇÃO DE PREVISÕES PARA DESPESAS DISCRICIONÁRIAS.....	47
4.4	OCORRÊNCIAS DE DESLOCAMENTO TEMPORAL E SUAS IMPLICAÇÕES .	49
4.5	SÍNTESE QUANTITATIVA POR GRANULARIDADE.....	50
<b>5</b>	<b>CONCLUSÃO.....</b>	<b>52</b>
5.1	CONCLUSÃO DA PESQUISA .....	52
5.2	CONTRIBUIÇÕES DO ESTUDO .....	53
5.2.1	CONTRIBUIÇÕES ACADÊMICAS .....	53
5.2.2	CONTRIBUIÇÕES PRÁTICAS .....	53
5.3	RECOMENDAÇÕES E TRABALHOS FUTUROS .....	53
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>		<b>54</b>
<b>APÊNDICES .....</b>		<b>59</b>
.1	PSEUDOCODIGO: BI ORCAMENTARIO – BLUEPRINT END-TO-END .....	59

# LISTA DE FIGURAS

3.1	Proposta de Arquitetura de Interoperabilidade para coleta e análise de dados.....	22
3.2	Exposição via FastAPI/Uvicorn com Nginx como <i>reverse proxy</i> , acessando o banco PostgreSQL.....	24
3.3	Modelo de Entidade e Relacionamento da arquitetura proposta .....	25
3.4	Fluxograma de Execução do MTO.....	27
3.5	Modelo de arquitetura para análise preditiva .....	30
3.6	Modelo de Séries Temporais (Classificação e Regressão).....	32
3.7	Modelos de Séries Temporais .....	38
4.1	Painel Geral de Resultados da Arquitetura Proposta .....	42
4.2	Painel de resultados de restos a pagar .....	43
4.3	Modelo Holt-Winters .....	44
4.4	UE 154040, DET 33901414 longo histórico (2014–2024) .....	46
4.5	UE 154040, DET 33901414 recorte de 2024: Painel Geral de Resultados Preditiva Mês a Mês.....	47
4.6	Despesas discricionárias modelo SARIMA.....	48
4.7	Agregação Suaviza .....	49
4.8	Deslocamento Temporal de RAP .....	49
4.9	Distribuição do MAPE (%) por estrato (UE/UR $\times$ DSP/DET) .....	50
4.10	Distribuição do RMSE por estrato.....	51

## LISTA DE TABELAS

3.1	MTO — principais campos utilizados no pipeline .....	29
4.1	Comparativo agregado por estrato (valores medianos). ....	45
4.2	Indicadores — despesas típicas (valores medianos).....	47
4.3	Indicadores — despesas discricionárias (valores medianos). ....	48

# LISTA DE ABREVIACÕES E SIGLAS

## ***Lista de abreviações Siglas***

PPA	Plano Plurianual
LDI	Lei de Diretrizes Orçamentárias (LDI)
LOA	Lei Orçamentária Anual
DAF/UnB	Departamento de Administração e Finanças da Universidade de Brasília
ML	Machine Learning
BI	Business Intelligence
IA	Inteligência Artificial
IQGP	Índice de Qualidade do Gasto Público
ABC	Activity-Based Costing
RDC	Repositório Digital Confiável
RMSE	Root Mean Squared Error
sMAPE	Symmetric Mean Absolute Percentage Error
MAE	Mean Absolute Error
ARIMA	Autorregressivos Integrados de Médias Móveis
SARIMA	Modelo Autorregressivo Integrado de Média Móvel Sazonal
SVM	Support Vector Machines
LLMs	Large Language Models
PLN	Processamento de Linguagem Natural
XAI	inteligência artificial explicável
DW	Data Warehouses
DGA	Data Governance Act
GDPR	Regulamento Geral sobre a Proteção de Dados
MTO	Manual Técnico de Orçamento
RAP	Restos a pagar
RPNP	Restos a Pagar não processados
RPP	Restos a Pagar processados
UO	Unidade Orçamentaria
UE	Unidade Executora
GND	Grupo de Natureza da Despesa
SGBD	Gerenciamento de banco de dado
MER	Modelo Entidade–Relacionamento
MLOps	Operações de Machine Learning
SLAs	Service Level Agreement (Acordo de Nível de Serviço)
APIs	Interfaces de Programação de Aplicações
ELT	Extract, Load, Transform (processo de integração de dados)

# 1 INTRODUÇÃO

O orçamento público federal brasileiro é estruturado a partir dos princípios estabelecidos pela Constituição Federal de 1988 e regulado principalmente pela Lei nº 4.320/1964 e pela Lei de Responsabilidade Fiscal (LC nº 101/2000). O processo orçamentário brasileiro é baseado no modelo do Orçamento-Programa, o qual busca vincular os recursos públicos a programas de trabalho que expressem as prioridades governamentais em termos de resultados e impactos sociais. A construção do orçamento ocorre em três etapas principais: elaboração, aprovação e execução. A elaboração é conduzida pelo Poder Executivo, coordenada pelo Ministério do Planejamento (atualmente parte do Ministério da Fazenda e Planejamento), seguindo as diretrizes do Plano Plurianual (PPA) e da Lei de Diretrizes Orçamentárias (LDO). O instrumento final, a Lei Orçamentária Anual (LOA), é enviado ao Congresso Nacional para apreciação, podendo sofrer emendas antes de sua aprovação [1].

Durante a execução orçamentária, a metodologia se baseia em instrumentos de programação financeira, controle de empenho e liquidação da despesa, assegurando que as ações governamentais estejam alinhadas ao que foi autorizado. Alterações necessárias no decorrer do exercício financeiro, como créditos adicionais, seguem processos formais previstos em lei. O orçamento federal adota o regime de competência para as receitas e o regime de caixa para as despesas, o que influencia a metodologia de registro contábil [2]. Além disso, há ênfase no monitoramento e na avaliação de programas, integrando mecanismos de Avaliação de Políticas Públicas que retroalimentam o ciclo orçamentário, promovendo maior eficiência, transparência e responsabilidade na gestão dos recursos públicos.

Nas últimas décadas, transformações sociais, políticas e tecnológicas têm aumentado a pressão sobre a gestão pública. De acordo com Matias [3], transparência, participação social, integridade e accountability tornaram-se pilares essenciais de boa governança. Contudo, diversos estudos indicam que o aumento do volume de gastos não assegura, por si só, a melhoria da qualidade dos serviços prestados. A literatura nacional e internacional aponta persistentes ineficiências, tais como alocação desigual de recursos, fragilidades no planejamento, hiper-concentração da execução orçamentária ao final do exercício, cancelamentos de despesas e desigualdades regionais [4, 5]. Tais fatores comprometem a efetividade do gasto público e limitam os impactos sociais esperados.

O debate sobre a qualidade do gasto público tem avançado com base em conceitos como eficiência, eficácia, efetividade, economicidade e sustentabilidade. A governança fiscal moderna busca alinhar a alocação de recursos às prioridades estratégicas e sociais, reforçando a necessidade de instrumentos que ampliem a transparência e permitam maior controle social [6]. Contudo, há lacunas importantes na literatura: a carência de modelos teóricos robustos, a predominância de análises qualitativas e a ausência de metodologias preditivas aplicadas à gestão orçamentária [4].

Nesse contexto, as Tecnologias de Informação e Comunicação (TICs) assumem um papel estratégico, com ferramentas de *Business Intelligence* e sistemas de Governo Digital, essas ferramentas têm sido adotados para disponibilizar informações contábeis em linguagem cidadã, aproximando a administração pública da sociedade e fortalecendo a accountability [7]. Além disso, as crises recentes econômicas, sanitárias e geopolíticas aumentaram a desconfiança da população em relação aos governos, ao mesmo tempo em que intensificaram a demanda por serviços públicos mais eficientes e por maior transparência na gestão dos recursos [3].

Diante desse cenário, técnicas de aprendizado de máquina (*Machine Learning* — ML) emergem como soluções promissoras para apoiar a previsão e a análise de gastos públicos. Essas técnicas permitem explorar grandes volumes de dados, identificar padrões, tendências e correlações que seriam difíceis de detectar por métodos convencionais. Assim, a aplicação de algoritmos preditivos, integrados a mecanismos de segurança computacional, representa um avanço inovador para otimizar a gestão e o controle de despesas públicas, contribuindo para maior eficiência, transparência e sustentabilidade fiscal [8].

Neste trabalho, propõe-se o desenvolvimento de um modelo de arquitetura para sistemas de gestão e controle de gastos, que incorpore soluções tecnológicas para entrada estruturada de dados e mecanismos de predição baseados em inteligência artificial. Como prova de conceito, a proposta será aplicada aos dados do Decanato de Administração da Universidade de Brasília (DAF/UnB).

## 1.1 CONTEXTUALIZAÇÃO E PROBLEMA DE PESQUISA

Nas últimas décadas, o tema da eficiência e da qualidade do gasto público tem se tornado central no debate sobre governança e sustentabilidade fiscal. A sociedade brasileira, cada vez mais consciente da elevada carga tributária, passou a exigir que os recursos arrecadados sejam aplicados de forma responsável, transparente e eficiente, reduzindo desperdícios e maximizando resultados sociais [9]. Nesse contexto, órgãos de controle e gestores públicos têm buscado alternativas metodológicas para avaliar e aprimorar a qualidade da despesa, mas ainda persistem desafios estruturais relacionados à alocação de recursos, planejamento e monitoramento das políticas públicas.

Estudos apontam que a execução orçamentária no Brasil frequentemente apresenta ineficiências decorrentes de planejamento inadequado e problemas de execução, o que resulta em desperdício de recursos e impacto limitado na entrega de serviços essenciais, como saúde e educação [9]. Do ponto de vista administrativo, observa-se o crescimento desproporcional das despesas correntes, em especial com pessoal e custeio, comprometendo a capacidade de investimento de estados e municípios. Experiências como o Programa de Eficiência do Gasto Público (PEG), estruturado pelo governo federal, e iniciativas estaduais baseadas em metodologias como o ciclo PDCA e benchmarking, revelam avanços, mas ainda são incipientes em termos de consolidação científica e de impacto prático [10].

Apesar do uso de técnicas tradicionais de mensuração de eficiência, como a Análise Envoltória de Dados (DEA), verifica-se uma lacuna metodológica importante: a ausência de soluções preditivas que permitam antecipar comportamentos orçamentários e apoiar gestores na tomada de decisão em tempo real. Essa lacuna se torna ainda mais crítica diante da complexidade dos dados financeiros públicos, que combinam variáveis quantitativas e qualitativas, exigindo abordagens capazes de lidar com volume, variedade e velocidade de geração de informações.

Diante desse cenário, a principal motivação deste trabalho é investigar a qualidade do gasto público a partir de uma abordagem inovadora, baseada em aprendizado de máquina (*Machine Learning* - ML). Pretende-se propor uma metodologia para predição de despesas orçamentárias, independentemente de sua natureza, utilizando um *Data Warehouse* especializado em informações financeiras do setor público. Como prova de conceito, serão utilizados dados da Universidade de Brasília (UnB), fornecidos pelo Decanato de Administração, visando ao desenvolvimento de um sistema de gestão inteligente para o monitoramento e controle de gastos.

Espera-se, com isso, contribuir para a redução de despesas desnecessárias, o direcionamento mais eficiente dos recursos públicos e a ampliação da transparência e accountability na gestão orçamentária.

## 1.2 JUSTIFICATIVA

A análise preditiva de gastos orçamentários se justifica pela necessidade de aperfeiçoar os mecanismos de planejamento e execução em um contexto de crescente complexidade fiscal e restrições de recursos. Segundo Osborne e Hutchinson [11], a gestão eficiente dos orçamentos públicos depende não apenas da alocação adequada de recursos, mas também da capacidade de antecipar demandas futuras e ajustar estratégias de acordo com cenários dinâmicos. O uso de técnicas de aprendizado de máquina e estatística aplicada permite transformar dados históricos em previsões robustas, reduzindo incertezas e apoiando a tomada de decisão estratégica [12]. Assim, a aplicação de métodos preditivos representa um avanço relevante na governança orçamentária, ao fornecer subsídios técnicos que podem mitigar riscos de desperdícios e aumentar a transparência no uso de recursos.

Estudos nacionais evidenciam que o simples aumento dos dispêndios públicos não garante melhores resultados nas políticas sociais. Cavalcante e Lariu [13] demonstram, em uma análise comparativa abrangendo cerca de 95% dos municípios brasileiros, que as relações entre gasto per capita em saúde, educação e assistência social e os indicadores de desempenho municipal são frágeis ou inexistentes. Tal evidência reforça o desafio de transformar insumos em resultados efetivos e indica a necessidade de inovações metodológicas capazes de superar as limitações das abordagens tradicionais de mensuração da eficiência.

Nesse sentido, a proposta desta pesquisa alinha-se às tendências de digitalização e modernização da administração pública, ao tratar dados financeiros como ativos estratégicos

e ao utilizá-los para gerar inteligência preditiva. Ao empregar algoritmos de aprendizado de máquina, pretende-se oferecer aos gestores públicos instrumentos capazes de antecipar cenários orçamentários, otimizar a alocação de recursos e fundamentar políticas mais sustentáveis e transparentes. Dessa forma, a justificativa para este estudo reside tanto em sua relevância prática apoiar a eficiência e a responsabilidade fiscal quanto em sua contribuição científica, ao propor uma integração inédita entre tecnologia, economia e gestão pública.

## 1.3 OBJETIVOS

### 1.3.1 Objetivos Geral

O objetivo principal desta dissertação é Propor, implementar e avaliar uma arquitetura e metodologia para a previsão de gastos orçamentários, integrando modelos tradicionais de séries temporais (ARIMA/SARIMA) e apresentando os resultados preditivos através de um *Business Intelligence - BI* para o Decanato de Administração da Universidade de Brasília (DAF/UnB) como prova de conceito.

### 1.3.2 Objetivos Específicos

Para alcançar o objetivo geral, foram definidos os seguintes objetivos específicos:

- Propor um modelo de arquitetura de interoperabilidade de dados orçamentários.
- Elaborar diagnósticos situacionais que permitam compreender as necessidades e fragilidades dos processos de gestão orçamentária no DAF/UnB;
- Definir e operacionalizar a arquitetura de integração e interoperabilidade de dados financeiros e administrativos com a apresentação de dashboards;
- Monitorar e avaliar a operacionalização dos processos de gestão de gastos, identificando oportunidades de melhoria contínua;
- Tratar e padronizar dados incongruentes e restos a pagar.
- Comparar modelos preditivos estatísticos e de aprendizado de máquina através de gráficos.
- Avaliar a aplicabilidade de LLMs como assistentes no processo de previsão.
- Medir o desempenho com métricas estatísticas (MAE, RMSE, MAPE).

## 1.4 METODOLOGIA DE PESQUISA

A presente dissertação caracteriza-se como uma pesquisa aplicada, de natureza exploratória e descritiva, conduzida sob uma abordagem quali-quantitativa (método misto). Conforme Gil [14], pesquisas aplicadas buscam gerar conhecimentos orientados à solução de problemas concretos, enquanto a exploração e a descrição permitem compreender fenômenos ainda pouco estudados. A combinação entre técnicas qualitativas e quantitativas justifica-se pela necessidade de integrar a análise interpretativa da literatura e dos processos orçamentários com a experimentação empírica baseada em técnicas estatísticas e de aprendizado de máquina.

O percurso metodológico foi estruturado em seis etapas principais:

Revisão de literatura – Levantamento sistemático sobre qualidade do gasto público, modelos de arquitetura aplicados à gestão orçamentária, uso de inteligência artificial e ferramentas de *Business Intelligence-BI* no setor público. Esse processo seguiu as orientações de Marconi e Lakatos [15], permitindo identificar o estado da arte, lacunas e oportunidades de aplicação.

Definição do problema e formulação das hipóteses – Caracterização das fragilidades nos processos orçamentários e proposição de hipóteses sobre a aplicabilidade de modelos estatísticos e de aprendizado de máquina como mecanismos de previsão e apoio à decisão [16].

Proposição de arquitetura e desenvolvimento do protótipo – A partir dos referenciais teóricos e dos diagnósticos iniciais, foi elaborada uma arquitetura voltada à interoperabilidade de dados financeiros e à análise preditiva, incorporando princípios de governança de dados, segurança da informação e automação de processos [17].

Coleta e tratamento dos dados – A pesquisa utilizou dados provenientes do Decanado de Administração da Universidade de Brasília (DAF/UnB), configurando uma prova de conceito. O processo incluiu extração, transformação e carregamento (ETL), além de técnicas para tratamento de dados incongruentes e de restos a pagar, assegurando qualidade e consistência das informações.

Aplicação e validação dos modelos preditivos – Testaram-se modelos estatísticos tradicionais (ARIMA e SARIMA) e algoritmos de aprendizado de máquina (redes neurais, regressão, ensembles), avaliados por métricas como MAE, RMSE e MAPE [18]. A validação foi operacionalizada por *dashboards* interativos, permitindo análises preditivas e monitoramento em tempo real.

Análise crítica e avaliação dos resultados – Comparação dos resultados com a literatura e com as hipóteses iniciais, destacando potencialidades, limitações e oportunidades de aprimoramento. Esta etapa visou alinhar os achados às exigências de eficiência, transparência e accountability na gestão pública [19].

Os dados utilizados neste estudo foram extraídos de um *Data Warehouse* especializado em informações financeiras do setor público brasileiro, contendo tanto dados quantitativos quanto qualitativos. O uso de Data Warehouses no setor público tem se mostrado eficaz para integrar grandes volumes de dados, permitindo análises detalhadas e integradas que facilitam a tomada

de decisões financeiras e orçamentárias [20]. A seleção das variáveis quantitativas foi realizada com base no conhecimento técnico dos pesquisadores, resultando na escolha de 17 variáveis essenciais que cobrem todas as etapas do ciclo orçamentário, como dotação, empenho, liquidação e pagamento, além de variáveis transversais, como disponibilidades de crédito e restos a pagar, segundo as normas da Lei nº 4.320/64 (Brasil, 1964).

O uso de tecnologias preditivas no setor público também levanta questões políticas e éticas. A introdução de algoritmos pode afetar a autonomia dos gestores na alocação de recursos, deslocando a discricionariedade política para decisões baseadas em dados e modelos automatizados, o que pode gerar resistências institucionais (Muir; Ostergaard, 2023). Assim, a implementação bem-sucedida dessas ferramentas depende de uma abordagem que equilibre a eficiência técnica com a necessidade de manter a transparência e a accountability na gestão pública.

Assim, a metodologia adotada combina fundamentos teóricos consolidados com validação prática, permitindo verificar a viabilidade da arquitetura proposta como instrumento de apoio à gestão orçamentária. O caráter aplicado da pesquisa assegura relevância científica e social, contribuindo tanto para a literatura acadêmica quanto para o aprimoramento dos processos de gestão financeira no setor público brasileiro.

Como prova de conceito, a aplicação da proposta concentrou-se nos dados da Universidade de Brasília (UnB), possibilitando a experimentação prática da arquitetura e a avaliação de seu potencial de apoio à eficiência, transparência e responsabilidade na gestão dos recursos públicos.

## 1.5 PUBLICAÇÕES

Como resultado desta dissertação, foram publicados os seguintes artigos:

Kelly Santos de Oliveira Bezerra, Antônio Márcio Lopes Bezerra, Abimael de Jesus B. Costa, Jeremias Pereira da Silva Arraes, Lucas Teles de Alcântara e Fábio Lúcio Lopes de Mendonça. **Proposta de Arquitetura de um Sistema Inteligente para Gestão e Qualidade dos Gastos no Setor Público Federal Brasileiro.** In: Conferência Ibero-Americana WWW/Internet 2023, 2023, Madeira. Atas da Conferências IBERO-AMERICANAS. Lisboa: IADIS Ibero-Americanas Computação Aplicada, 2023. v. 10. ISBN:978-989-8704-54-2.

Kelly Santos de Oliveira, Felipe Barreto de Oliveira, Valerio Aymoré Martins, Vinícius Coutinho Guimarães Coelho, Georges Daniel Amvame Nze, Fábio Lúcio Lopes de Mendonça. **Previsão Inteligente de Gastos Governamentais: Proposta de uma Arquitetura Baseada em Aprendizado de Máquina para Eficiência e Transparência.** In Revista Ibérica de Sistemas e Tecnologias de Informação Iberian Journal of Information Systems and Technologies (RISTI), nº 26, 4200-422 Porto, Portugal, Edição N.º E77, 08/2025, Pages: 146-159. ISSN: 1646-9895. <<https://www.risti.xyz/issues/ristie77.pdf>>

## 1.6 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está organizada em cinco capítulos, incluindo esta introdução.

O **Capítulo 2** apresenta a fundamentação teórica do estudo, reunindo os principais conceitos, modelos, trabalhos correlatos e referenciais utilizados para embasar a pesquisa.

O **Capítulo 3** descreve a arquitetura do modelo proposto, detalhando as etapas de instalação, configuração e integração dos componentes tecnológicos, bem como o método de verificação adotado para assegurar a consistência dos procedimentos realizados.

O **Capítulo 4** apresenta os testes e resultados obtidos a partir da utilização de dados abertos da Universidade de Brasília (UnB). Inicialmente, os dados são minerados e extraídos para uma base multidimensional; em seguida, são processados por meio de ferramentas de *Extract, Transform, Load* (ETL). A análise contempla a aplicação de modelos estatísticos, com o objetivo de identificar informações relevantes para subsidiar a tomada de decisão gerencial.

Por fim, o **Capítulo 5** reúne as conclusões da pesquisa, destacando as principais contribuições do estudo, as limitações identificadas e as perspectivas para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo estão presentes o conjunto de soluções e utilizadas para alcançar os objetivos da proposta. Alguns conceitos estudados também são apresentados para auxiliar o entendimento das tecnologias, que irão apoiar na execução deste trabalho, podendo assim garantir a possibilidade de replicação dos experimentos utilizados.

### 2.1 GESTÃO DE GASTOS PÚBLICOS E QUALIDADE DO GASTO

A gestão dos recursos públicos é um tema central no campo da administração pública e das finanças governamentais. O conceito de gasto público refere-se à aplicação de recursos financeiros arrecadados pelo Estado, por meio de tributos, contribuições e outras receitas, com o objetivo de financiar bens e serviços destinados ao atendimento das necessidades coletivas. Esses gastos compreendem desde despesas correntes, como folha de pagamento e manutenção administrativa, até investimentos em áreas estratégicas, como saúde, educação, infraestrutura e inovação tecnológica [21].

Do ponto de vista normativo, a execução do gasto público no Brasil está amparada pela Constituição Federal de 1988, pela Lei nº 4.320/1964<sup>1</sup>, que estabelece normas gerais de direito financeiro, e pela Lei de Responsabilidade Fiscal (LC nº 101/2000)<sup>2</sup>, que define parâmetros para a responsabilidade na gestão fiscal. O processo orçamentário, estruturado no modelo do Orçamento-Programa, vincula os gastos a programas e ações governamentais, buscando alinhar o uso de recursos às prioridades estratégicas e aos resultados sociais esperados. Nesse contexto, princípios como legalidade, impessoalidade, moralidade, publicidade e eficiência (art. 37 da CF/88)<sup>3</sup> orientam a utilização do dinheiro público.

Apesar desse arcabouço jurídico, a literatura evidencia que a simples execução do gasto não garante, por si só, a entrega de serviços públicos de qualidade. Surge, então, o conceito de qualidade do gasto público, entendido como a capacidade do Estado de aplicar recursos de forma eficiente, eficaz, equitativa e transparente, produzindo benefícios sociais que sejam proporcionais, ou mesmo superiores, ao volume investido. A qualidade do gasto está, portanto, diretamente relacionada à transformação de insumos financeiros em resultados que atendam às necessidades e expectativas da sociedade [22].

Segundo Afonso et al. [23], que analisaram a qualidade dos gastos em 23 países desenvolvidos, existe amplo espaço para aprimoramento da alocação de recursos, por meio do aumento da eficiência e do desempenho governamental. No Brasil, Rocha e Giuberti [24]

<sup>1</sup>[https://www.planalto.gov.br/ccivil\\_03/Leis/L4320.htm](https://www.planalto.gov.br/ccivil_03/Leis/L4320.htm)

<sup>2</sup>[https://www.planalto.gov.br/ccivil\\_03/LEIS/LCP101.htm](https://www.planalto.gov.br/ccivil_03/LEIS/LCP101.htm)

<sup>3</sup>[https://www.planalto.gov.br/ccivil\\_03/Constituicao/Constituicao.htm](https://www.planalto.gov.br/ccivil_03/Constituicao/Constituicao.htm)

ressaltam que a composição do gasto público exerce influência decisiva sobre o crescimento econômico, exigindo equilíbrio entre despesas correntes e investimentos produtivos para assegurar sustentabilidade fiscal e desenvolvimento.

Estudos empíricos reforçam a necessidade desse equilíbrio. Soares et al. [25] verificaram que muitos municípios brasileiros apresentam índices de qualidade do gasto público inferiores a 1,000, o que indica baixa eficiência na conversão de despesas em bem-estar social. Em análise semelhante, Da Silva et al. [26] constataram que a eficiência no gasto em saúde, educação e infraestrutura está diretamente associada a melhores indicadores de desenvolvimento humano, demonstrando que a boa gestão dos recursos públicos contribui de forma significativa para a qualidade de vida da população.

Mesquita e Wander [22], ao investigarem municípios do estado de Mato Grosso, observaram resultados distintos entre setores. Enquanto a maioria dos municípios apresentou eficiência relativa no gasto em saúde, em educação predominou a baixa qualidade, com deterioração dos resultados ao longo do tempo. Esse contraste evidencia que a eficiência do gasto não é uniforme entre áreas e que metodologias robustas, como o Índice de Qualidade do Gasto Público (IQGP) e a Análise Envoltória de Dados (DEA), são fundamentais para medir e monitorar o uso dos recursos.

A discussão sobre qualidade do gasto público também passa pela análise dos custos. Alonso [27] argumenta que a ausência de sistemas de custos consolidados no setor público constitui um dos maiores entraves para a melhoria do desempenho governamental. Embora o Sistema Integrado de Administração Financeira (SIAFI) represente um marco na modernização da execução orçamentária, ele se limita a controlar a despesa, não permitindo identificar o custo efetivo dos serviços prestados. A distinção entre despesa e custo é fundamental: enquanto a despesa corresponde ao desembolso financeiro, o custo revela o consumo de recursos necessários para produzir bens ou serviços. Nesse sentido, metodologias como o *Activity-Based Costing* (ABC) oferecem maior precisão ao demonstrar onde e como os recursos são consumidos, possibilitando a identificação de atividades que agregam ou não valor [27].

O debate contemporâneo sobre a qualidade do gasto público integra dimensões econômicas, sociais e institucionais. Cavalcante [28] destaca a necessidade de metodologias consistentes de avaliação, com indicadores que permitam mensurar eficiência, eficácia e accountability. No mesmo sentido, Malena et al. [29], ao analisarem o estado do Tocantins, apontaram que, apesar da existência de iniciativas como o Programa de Eficiência do Gasto Público (PEG), a gestão estadual ainda carece de práticas estruturadas e científicas para reduzir desperdícios. O estudo revelou que despesas administrativas recorrentes, como combustíveis, água, telefonia, material de expediente e limpeza são pontos críticos que poderiam ser otimizados mediante práticas de racionalização. Dessa forma, a literatura converge em alguns pontos centrais:

1. A qualidade do gasto público não se restringe ao volume de recursos aplicados, mas à sua capacidade de gerar resultados efetivos;
2. Instrumentos normativos e jurídicos estabelecem a base, mas não asseguram, por si só,

- eficiência e transparência;
3. Faltam metodologias sistemáticas e consolidadas de mensuração, especialmente em nível subnacional;
  4. A ausência de sistemas de custos e de cultura de mensuração de resultados limita o avanço na gestão pública;
  5. Novas ferramentas de análise, como metodologias de custeio avançadas e técnicas de ciência de dados, podem ampliar a eficiência e accountability.

Assim, a busca pela qualidade do gasto público exige uma abordagem multidimensional que combine: (i) fundamentos normativos, (ii) metodologias de mensuração de desempenho, (iii) sistemas de custos modernos e (iv) inovações tecnológicas aplicadas à gestão orçamentária. É nesse ponto que se insere a presente dissertação, ao propor o uso de técnicas de aprendizado de máquina e análise preditiva como instrumentos capazes de apoiar o planejamento, a execução e o monitoramento dos gastos públicos, contribuindo para maior eficiência, transparência e responsabilidade fiscal.

## 2.2 APRENDIZADO DE MÁQUINA E ANÁLISE PREDITIVA

O avanço das tecnologias digitais e o crescente volume de dados disponíveis têm impulsionado o uso de técnicas de Aprendizado de Máquina (*Machine Learning* – ML) como ferramentas centrais na análise preditiva aplicada à gestão pública e privada. O ML, subárea da Inteligência Artificial (IA), busca desenvolver algoritmos capazes de aprender padrões a partir de dados históricos e, com isso, realizar previsões ou classificações em novos cenários [30]. Essa característica torna o ML particularmente relevante em contextos complexos e dinâmicos, como a gestão de gastos públicos, nos quais a identificação de anomalias, padrões de consumo e tendências futuras é crucial para subsidiar decisões mais eficientes.

O aprendizado de máquina pode ser definido como o processo pelo qual sistemas computacionais adquirem conhecimento de forma autônoma a partir de dados, sem necessidade de programação explícita para cada tarefa. Essa capacidade está estruturada em diferentes paradigmas, sendo os principais:

- **Aprendizado supervisionado:** o modelo é treinado com dados rotulados, nos quais as entradas estão associadas a saídas conhecidas. É amplamente utilizado em tarefas de regressão e classificação, como prever o valor de uma despesa ou identificar se um gasto público é legítimo ou suspeito.
- **Aprendizado não supervisionado:** os algoritmos buscam identificar padrões e estruturas ocultas em dados não rotulados, como agrupamento de comportamentos de consumo ou segmentação de unidades gestoras com perfis semelhantes de gasto.

- **Aprendizado por reforço:** sistemas aprendem por meio de interação com o ambiente, recebendo recompensas ou penalidades de acordo com as ações tomadas. Esse paradigma tem aplicações promissoras em otimização de processos orçamentários.

A escolha do paradigma depende dos objetivos da análise e da disponibilidade de dados, sendo que, em contextos orçamentários, o aprendizado supervisionado e o não supervisionado são os mais explorados.

### 2.2.1 Análise Preditiva e Aplicações Práticas

A análise preditiva corresponde ao uso de técnicas estatísticas, algoritmos de aprendizado de máquina e mineração de dados para identificar probabilidades de ocorrências futuras com base em informações históricas. Diferente da análise descritiva, que apenas resume dados passados, e da análise diagnóstica, que busca explicar causas, a análise preditiva tem caráter prospectivo, orientando a tomada de decisão em cenários de incerteza [12].

No setor público, a análise preditiva vem sendo utilizada para:

- **Detecção de fraudes:** algoritmos identificam padrões anômalos em transações financeiras, auxiliando órgãos de controle a prevenir irregularidades.
- **Previsão orçamentária:** modelos preditivos projetam o comportamento futuro de receitas e despesas, apoiando a formulação de políticas fiscais mais realistas.
- **Automação de processos:** ferramentas baseadas em ML aceleram atividades de auditoria, como reconhecimento automático de documentos fiscais e análise de conformidade.

Pereira et al. [31] exemplificam essa aplicação ao propor uma ferramenta de código aberto para automatizar o reconhecimento de notas fiscais em processos de auditoria de gastos públicos. Utilizando algoritmos como Tesseract (OCR), BERT e modelos de classificação supervisionada, o sistema foi capaz de distinguir entre imagens de notas fiscais e documentos não fiscais, atingindo níveis de acurácia superiores a 90%. A iniciativa reforça a relevância da análise preditiva não apenas para otimizar o trabalho de fiscalização, mas também para ampliar a transparência e o controle social.

Em outro campo de aplicação, Santos et al. [32] propuseram uma arquitetura de tempo real para detecção de fraudes em cartões de crédito utilizando modelos de aprendizado supervisionado, com destaque para o *Random Forest*. Os resultados alcançaram métricas de acurácia próximas a 99,98%, com revocação de 100%, demonstrando a robustez do ML para identificar transações suspeitas em ambientes críticos e dinâmicos. Apesar de voltado ao setor financeiro, o estudo ilustra o potencial do aprendizado de máquina em cenários de elevada complexidade e risco, aplicáveis também à gestão de recursos públicos.

Dentre os algoritmos mais aplicados em análise preditiva, destacam-se:

- **Árvores de decisão e Random Forest:** interpretáveis e eficientes para dados estruturados, permitem identificar combinações de variáveis que explicam padrões de gasto.
- **Support Vector Machines (SVM):** eficazes em problemas de classificação com alta dimensionalidade, úteis na detecção de fraudes e irregularidades.
- **XGBoost e Gradient Boosting:** algoritmos de ensemble que combinam múltiplos modelos para obter maior acurácia preditiva.
- **Redes Neurais e Deep Learning:** adequadas para grandes volumes de dados e tarefas mais complexas, como reconhecimento de imagens de documentos fiscais.

Esses algoritmos podem ser avaliados por métricas como acurácia, precisão, revocação e F1-score, cuja escolha depende das prioridades do problema. Por exemplo, em auditorias financeiras, é preferível minimizar falsos negativos (não detectar uma fraude), ainda que haja mais falsos positivos.

Apesar do potencial do aprendizado de máquina, sua adoção na análise de gastos públicos enfrenta alguns desafios:

- **Qualidade e disponibilidade dos dados:** dados inconsistentes, incompletos ou não estruturados limitam a performance dos modelos.
- **Privacidade e segurança:** o uso de dados sensíveis exige conformidade com legislações como a LGPD, impondo restrições à coleta e ao tratamento.
- **Interpretação dos modelos:** a necessidade de explicabilidade dos algoritmos é fundamental para garantir confiança de gestores e órgãos de controle.

Por outro lado, as oportunidades são expressivas. A integração entre aprendizado de máquina, *Business Intelligence* e governança digital pode transformar a forma como recursos são planejados, executados e monitorados. A utilização de painéis preditivos (*dashboards*) possibilita a visualização de tendências em tempo real, favorecendo uma administração pública mais proativa, responsável e transparente [32].

Diante do exposto, observa-se que o aprendizado de máquina e a análise preditiva constituem ferramentas estratégicas para aprimorar a qualidade da gestão de gastos. Ao permitir a identificação de padrões, a antecipação de riscos e a detecção de irregularidades, essas tecnologias ampliam a capacidade de controle interno e externo, fortalecendo a eficiência, a responsabilidade fiscal e a confiança social no uso dos recursos públicos.

## 2.3 MODELOS DE SÉRIES TEMPORAIS (ARIMA, SARIMA)

A análise de séries temporais constitui um dos métodos estatísticos mais consolidados para a previsão de variáveis econômicas e financeiras, sendo amplamente empregada no contexto da

contabilidade gerencial e da gestão orçamentária. Uma série temporal pode ser definida como um conjunto de observações de uma variável registradas sequencialmente ao longo do tempo, em intervalos regulares, de forma que cada observação guarda dependência com os valores passados [33]. O objetivo da modelagem de séries temporais é capturar essa estrutura de dependência para descrever o comportamento histórico e projetar valores futuros com base em padrões observados.

Os modelos Autorregressivos Integrados de Médias Móveis (ARIMA), popularizados por Box e Jenkins, são amplamente utilizados em previsões de séries temporais não estacionárias. O termo ARIMA  $(p, d, q)$  representa a combinação de três componentes:

- $p$ : número de defasagens do termo autorregressivo (AR);
- $d$ : ordem da diferenciação necessária para tornar a série estacionária;
- $q$ : número de defasagens dos termos de média móvel (MA).

O modelo ARIMA ajusta-se bem a séries que apresentam tendência e flutuações estocásticas, eliminando a não estacionariedade por meio do processo de diferenciação [34]. Essa flexibilidade explica sua ampla aplicação em contextos de previsão de receitas e despesas públicas, bem como em análises financeiras privadas.

Em muitas situações práticas, especialmente no âmbito orçamentário, as séries apresentam padrões sazonais recorrentes, como picos de despesas em determinados meses do ano. Para lidar com essas características, adota-se o modelo SARIMA (Seasonal ARIMA), representado por ARIMA  $(p, d, q)(P, D, Q)_m$ , no qual:

- $P, D, Q$  são os parâmetros sazonais autorregressivos, de diferenciação e de médias móveis, respectivamente;
- $m$  corresponde ao período da sazonalidade (por exemplo,  $m = 12$  em séries mensais).

A modelagem sazonal permite captar variações sistemáticas que se repetem em ciclos regulares, o que aumenta a precisão das previsões em ambientes sujeitos a sazonalidade, como execução orçamentária anual. Queiroz [35] aplicou modelos de séries temporais para prever custos de tecnologia da informação em uma empresa revendedora de automóveis de Minas Gerais, utilizando dados orçamentários entre 2008 e 2013. Os resultados indicaram que, embora os modelos tenham obtido assertividade parcial para custos fixos e variáveis, apresentaram baixa adequação para a previsão de investimentos, sugerindo que variáveis fortemente dependentes de decisões estratégicas e eventos externos são mais difíceis de modelar por métodos quantitativos.

No setor público, Okamura et al. [33] utilizaram a metodologia ARIMA e SARIMA para projetar despesas da Agência Brasileira de Promoção de Exportações e Investimentos (Apex-Brasil), a partir de dados históricos entre 2016 e 2023. O estudo identificou tendência de crescimento a partir de 2021 e sazonalidade significativa nos finais de exercício, características bem capturadas pelo modelo SARIMA. O modelo ajustado apresentou bom desempenho, com

erro percentual médio absoluto (MAPE) em torno de 17%, desempenho superior a métodos simplificados de previsão, como a replicação dos valores do ano anterior. Os autores destacam que a replicabilidade e a adaptabilidade do modelo permitem sua aplicação contínua em ciclos orçamentários futuros, subsidiando decisões estratégicas.

Os modelos ARIMA e SARIMA são instrumentos robustos para previsão orçamentária, permitindo identificar padrões históricos, estimar impactos de sazonalidade e apoiar a formulação de políticas de alocação de recursos [33, 35]. No entanto, apresentam limitações relevantes:

- Sensibilidade a choques externos, como crises econômicas e pandemias, que introduzem quebras estruturais nas séries.
- Dependência da qualidade dos dados: séries curtas ou com registros inconsistentes comprometem a acurácia dos modelos.
- Restrição na explicabilidade: embora úteis para previsão, os modelos não oferecem, por si só, uma análise causal das variáveis que afetam as despesas.

Ainda assim, quando integrados a métodos de ciência de dados e a painéis de apoio à decisão, ARIMA e SARIMA representam ferramentas poderosas para aumentar a racionalidade, a transparência e a eficiência na gestão de recursos públicos. Em síntese, os modelos de séries temporais ARIMA e SARIMA apresentam grande relevância prática na análise orçamentária, pois permitem capturar dependências estatísticas, identificar padrões sazonais e projetar cenários futuros de despesas. Sua aplicação, conforme evidenciado nos estudos empíricos de Queiroz [35] e Okamura et al. [33], contribui significativamente para o planejamento estratégico, o controle de gastos e a melhoria da qualidade das decisões financeiras tanto no setor privado quanto na administração pública.

## 2.4 LARGE LANGUAGE MODELS (LLMS) NA ANÁLISE DE DADOS

Os *Large Language Models* (LLMs) representam um avanço significativo no campo do *Processamento de Linguagem Natural* (PLN), permitindo que computadores compreendam, gerem e analisem textos em linguagem natural com níveis inéditos de sofisticação. Baseados em arquiteturas do tipo *transformers* [36], esses modelos se destacam por sua capacidade de capturar relações complexas em grandes volumes de dados textuais, o que os torna aplicáveis em diversas áreas, desde a análise de sentimentos até a tradução automática e a classificação documental.

O princípio fundamental dos LLMs consiste no pré-treinamento em enormes corpora textuais, geralmente extraídos da web, para aprender representações semânticas e contextuais das palavras. Essa abordagem, associada ao uso de mecanismos de atenção multicabeça, permite que o modelo considere dependências de longo alcance nos textos e gere previsões consistentes. Posteriormente, esses modelos podem ser ajustados (*fine-tuning*) para tarefas específicas, como

classificação de documentos financeiros, gastos públicos ou análise de séries temporais em políticas públicas [37].

Um aspecto central dos LLMs é sua capacidade de operar em cenários multilíngues. Modelos como o mBERT, o XLM-RoBERTa e o mT5 foram desenvolvidos para lidar com diferentes idiomas, permitindo aplicações mais abrangentes em países com diversidade linguística, como o Brasil. No estudo de Bernhard [38], por exemplo, foram comparados três modelos multilíngues na tarefa de classificação de documentos de prestação de contas do Tribunal de Contas do Estado do Maranhão (TCE/MA). Os resultados mostraram que o XLM-RoBERTa obteve o melhor desempenho (F1-score de 98,99%), superando o mBERT e o mT5. Isso demonstra o potencial dos LLMs para automatizar tarefas complexas de análise documental, promovendo maior eficiência, padronização e confiabilidade no processo de fiscalização.

Outra contribuição importante dos LLMs é a possibilidade de realizar classificações e sumarizações em documentos extensos, como relatórios financeiros ou balanços orçamentários. Enquanto modelos de aprendizado de máquina tradicionais apresentam limitações em relação ao tamanho do contexto processado, os LLMs conseguem fragmentar e reconstruir informações de forma coerente, preservando nuances semânticas [38, 39]. Essa característica é particularmente útil na gestão pública, em que documentos frequentemente ultrapassam centenas de páginas e incluem múltiplos formatos de informação.

Além da classificação, os LLMs têm sido explorados na extração de informações relevantes para auditoria e fiscalização. Pesquisas recentes sugerem que esses modelos podem identificar indícios de inconsistências contábeis, padrões de despesas atípicas e possíveis fraudes, atuando como ferramentas de apoio à tomada de decisão em tempo real [40]. A incorporação de técnicas de ajuste supervisionado e de *prompt engineering* aumenta ainda mais sua aplicabilidade prática, permitindo a customização dos modelos para contextos específicos, como a análise de gastos públicos.

No entanto, apesar de seu elevado desempenho, a adoção de LLMs também apresenta desafios [41]. Entre eles, destacam-se a necessidade de elevados recursos computacionais, as preocupações éticas relacionadas a vieses nos dados de treinamento e os riscos à transparência das decisões algorítmicas. Essas limitações tornam essencial o desenvolvimento de práticas de governança algorítmica e a integração de mecanismos de *explainable AI* (XAI), especialmente quando os modelos são aplicados a contextos sensíveis como a gestão de recursos públicos [42].

Em síntese, os LLMs consolidam-se como ferramentas poderosas para análise de dados textuais em larga escala, oferecendo suporte inovador à gestão pública e à auditoria de contas. Ao viabilizar a automação de tarefas como classificação, extração de padrões e detecção de inconsistências, esses modelos não apenas ampliam a eficiência, mas também fortalecem a transparência e a accountability nos processos de governança. Seu uso em cenários de análise de gastos orçamentários abre novas perspectivas para a combinação de inteligência artificial e políticas públicas baseadas em evidências, aproximando a administração pública de práticas mais modernas, eficientes e responsivas às demandas da sociedade.

## 2.5 DATA WAREHOUSES E GOVERNANÇA DE DADOS

O crescimento exponencial da produção de dados nos últimos anos tem transformado a forma como organizações públicas e privadas lidam com a gestão da informação. A necessidade de integrar, consolidar e analisar grandes volumes de dados levou à disseminação de arquiteturas de *Data Warehouses* (DW), que se tornaram centrais para processos de apoio à decisão e de inteligência organizacional. Paralelamente, o tema da governança de dados tem ganhado relevância, estabelecendo-se como um campo multidisciplinar que busca alinhar aspectos técnicos, legais, organizacionais e sociais no uso responsável e estratégico da informação [17].

Um *Data Warehouse* pode ser definido como uma coleção de dados integrados, orientados por assunto, não voláteis e variáveis no tempo, projetados para dar suporte a processos de análise e tomada de decisão [43]. Sua principal função é consolidar informações de múltiplas fontes, estruturando-as em um repositório único que facilita consultas analíticas e relatórios gerenciais. Em ambientes de gestão pública, os DWs são particularmente relevantes por integrarem dados orçamentários, contábeis e financeiros oriundos de diferentes sistemas de informação governamentais.

A arquitetura de um DW inclui três etapas fundamentais: extração, transformação e carga dos dados (ETL – *Extract, Transform, Load*). Esses processos permitem não apenas a integração técnica, mas também a padronização semântica da informação, o que é crucial em organizações públicas caracterizadas por sistemas fragmentados e heterogêneos. Dessa forma, os DWs favorecem a análise multidimensional de despesas, receitas e indicadores de desempenho, apoiando a gestão baseada em evidências [44].

A governança de dados é definida como o conjunto de processos, papéis, políticas, padrões e métricas que asseguram o uso eficaz da informação para atingir os objetivos de uma organização [45]. No setor público, assume uma dimensão ampliada, pois envolve não apenas a eficiência administrativa, mas também a transparência, a accountability e o alinhamento com valores democráticos. A governança de dados deve ser entendida como um sistema de direitos e responsabilidades que define quem pode realizar quais ações sobre determinados dados, em quais circunstâncias e utilizando quais métodos [45].

No contexto europeu, o tema ganhou relevância com a adoção do *Data Governance Act* (DGA), aprovado em 2022, que estabelece regras para o compartilhamento e a reutilização de dados do setor público, incluindo aqueles considerados sensíveis. Buttow e Weerts [17] destacam que o DGA visa não apenas ampliar a abertura de dados governamentais, mas também garantir que seu uso esteja orientado para a inovação responsável e o bem comum. Para tanto, o regulamento introduz mecanismos como os *public data trusts*, instituições intermediárias que buscam equilibrar interesses econômicos e sociais no acesso e na reutilização de dados.

Embora os DWs ofereçam a infraestrutura necessária para consolidar dados e apoiar análises, sua eficácia depende diretamente da existência de políticas de governança de dados robustas. Sem governança, os DWs correm o risco de se tornarem repositórios redundantes, inconsistentes ou

mesmo opacos, minando seu potencial de promover transparência e eficiência. Nesse sentido, a integração entre DWs e governança de dados deve contemplar:

- **Padronização e qualidade dos dados:** assegurar que os dados integrados ao DW sejam precisos, completos e consistentes;
- **Segurança e privacidade:** implementar controles de acesso e anonimização em conformidade com legislações como a LGPD e o GDPR;
- **Responsabilidade e papéis institucionais:** definir claramente quem pode acessar, modificar ou compartilhar os dados armazenados;
- **Interoperabilidade:** garantir que os DWs possam dialogar com diferentes sistemas e bases de dados, ampliando o alcance das análises;
- **Transparência e accountability:** disponibilizar informações em linguagem cidadã, favorecendo o controle social e a participação democrática.

Nesse contexto, o uso de DWs associado a modelos de governança contribui não apenas para a eficiência administrativa, mas também para o fortalecimento da confiança entre governo e sociedade. Estudos recentes indicam que a simples abertura de dados não é suficiente para gerar impacto social significativo [17]; é necessário construir mecanismos institucionais que promovam uso efetivo e responsável da informação.

Apesar de seu potencial, a integração entre DWs e governança de dados enfrenta desafios consideráveis. Entre os principais estão: (i) a fragmentação de sistemas de informação no setor público; (ii) a carência de competências técnicas para exploração de dados em larga escala; (iii) a tensão entre abertura e proteção de dados sensíveis; e (iv) a necessidade de recursos financeiros e tecnológicos para a manutenção de infraestruturas complexas [17].

Por outro lado, emergem oportunidades significativas. A adoção de modelos inovadores, como os *public data trusts*, e o alinhamento com princípios de *Responsible Research and Innovation* (RRI) [45], apontam para uma governança de dados mais democrática, inclusiva e orientada ao bem comum. A integração com tecnologias emergentes, como aprendizado de máquina e painéis interativos (*dashboards*), amplia ainda mais o potencial dos DWs como instrumentos de apoio à tomada de decisão estratégica.

Em síntese, os *Data Warehouses* e a governança de dados constituem elementos complementares em uma estratégia abrangente de modernização da gestão pública. Enquanto os DWs oferecem a base técnica para integrar e analisar grandes volumes de informação, a governança de dados fornece o arcabouço institucional e normativo que garante o uso responsável, transparente e socialmente orientado desses dados. A convergência entre essas duas dimensões é fundamental para avançar em direção a uma administração pública mais eficiente, inovadora e alinhada às demandas da sociedade contemporânea.

## 2.6 TRABALHOS CORRELATOS

O presente estudo insere-se em uma interseção entre duas vertentes de pesquisa: (i) a literatura sobre qualidade e eficiência do gasto público e (ii) os avanços metodológicos em ciência de dados aplicados à previsão, classificação e auditoria de despesas. A seguir, são descritos os trabalhos mais diretamente relacionados, destacando-se o contexto em que foram conduzidos, os métodos empregados e os principais achados.

Afonso et al. [23] realizaram um estudo comparativo em 23 países desenvolvidos, utilizando indicadores de eficiência técnica e de desempenho econômico para avaliar a qualidade do gasto público. Os autores demonstram que há espaço considerável para melhoria por meio da alocação mais racional de recursos, apontando que o aumento do gasto não garante, por si só, melhores resultados sociais. Esse trabalho é referência fundamental para a discussão sobre eficiência em perspectiva internacional.

No Brasil, Rocha e Giuberti [24] analisaram a composição dos gastos estaduais e sua relação com o crescimento econômico, concluindo que o equilíbrio entre despesas correntes e investimentos é determinante para resultados sustentáveis. De forma complementar, Soares et al. [25] construíram um Índice de Qualidade do Gasto Público (IQGP) aplicado a municípios, identificando que muitos apresentam valores inferiores a 1,000, o que denota baixa eficiência na conversão de insumos financeiros em bem-estar social. Esses estudos reforçam a relevância da avaliação crítica da alocação orçamentária.

Mesquita e Wander [22], por sua vez, avaliaram a eficiência do gasto em saúde e educação em municípios do estado de Mato Grosso, utilizando técnicas de Análise Envoltória de Dados (DEA). Os resultados evidenciaram que, enquanto a saúde apresentou índices de eficiência relativos satisfatórios, a educação revelou baixa qualidade e deterioração ao longo do tempo. Esse contraste entre setores reforça a necessidade de abordagens mais sofisticadas de previsão e monitoramento, capazes de considerar especificidades de cada área.

Outro ponto de destaque é o trabalho de Malena et al. [29], que investigaram as despesas administrativas no estado do Tocantins, no contexto do Programa de Eficiência do Gasto Público (PEG). Utilizando análise situacional das contas públicas, os autores constataram que gastos recorrentes com combustíveis, telefonia e material de expediente representam pontos críticos de ineficiência. A ausência de metodologias científicas de gestão reforça a necessidade de ferramentas tecnológicas para racionalizar custos.

Esses estudos, em conjunto, estabelecem o pano de fundo do presente trabalho: a qualidade do gasto público permanece um desafio estrutural, carecendo de metodologias que permitam prever tendências, identificar padrões e apoiar a tomada de decisão com base em evidências.

A aplicação de técnicas de aprendizado de máquina (ML) em problemas de gestão financeira vem ganhando espaço na literatura recente. Pereira et al. [31] propuseram uma ferramenta de código aberto baseada em OCR (Tesseract) e modelos de classificação (BERT e Random Forest) para o reconhecimento automatizado de notas fiscais em auditorias de gastos públicos. O estudo,

de caráter experimental, atingiu níveis de acurácia superiores a 90%, demonstrando a viabilidade de automação de tarefas repetitivas e o potencial para reduzir custos e ampliar a confiabilidade das análises.

Na área de detecção de fraudes, Santos et al. [32] desenvolveram uma arquitetura de tempo real para identificar transações suspeitas em cartões de crédito, utilizando algoritmos supervisionados como Random Forest. Embora aplicado ao setor privado, o estudo alcançou métricas de acurácia próximas a 99,98%, evidenciando a robustez do ML para cenários de alto risco e complexidade. A metodologia pode ser transposta para o setor público, em especial na identificação de padrões anômalos em despesas orçamentárias.

No campo da previsão orçamentária, Queiroz [35] aplicou modelos ARIMA para estimar custos de tecnologia da informação em uma empresa do setor automotivo. Embora os modelos tenham capturado parcialmente padrões de custos fixos e variáveis, apresentaram limitações para investimentos, reforçando que variáveis estratégicas ou dependentes de fatores externos desafiam a modelagem quantitativa.

Okamura et al. [33] utilizaram modelos ARIMA e SARIMA para prever despesas da Agência Brasileira de Promoção de Exportações e Investimentos (Apex-Brasil), entre 2016 e 2023. O modelo SARIMA apresentou melhor ajuste, captando sazonalidade típica do ciclo orçamentário brasileiro. O desempenho (MAPE em torno de 17%) superou métodos simplificados, demonstrando a aplicabilidade da técnica para subsidiar planejamento e controle de gastos públicos.

Com a evolução dos modelos de linguagem, trabalhos recentes exploraram sua aplicação na análise documental em auditorias e prestação de contas. Bernhard [38] comparou mBERT, XLM-RoBERTa e mT5 na classificação de documentos de prestação de contas no Tribunal de Contas do Estado do Maranhão. O XLM-RoBERTa obteve o melhor desempenho (F1-score de 98,99%), indicando o potencial dos LLMs para automatizar atividades de fiscalização e reduzir gargalos operacionais. Esse estudo se aproxima do presente trabalho por tratar da aplicação de inteligência artificial no setor público, ainda que focado em análise textual.

Finalmente, Buttow e Weerts [17] discutem a governança de dados no setor público à luz do *Data Governance Act* europeu, destacando o papel dos *public data trusts* como novos arranjos institucionais para equilibrar inovação e bem comum. Embora não tratem diretamente de previsão de gastos, esses trabalhos contribuem ao demonstrar a importância de mecanismos de governança e confiança no uso de dados públicos em larga escala.

Os trabalhos analisados revelam três tendências principais:

1. A literatura sobre qualidade do gasto público tem se concentrado em indicadores de eficiência e em análises setoriais (saúde, educação, despesas administrativas), apontando para a necessidade de metodologias mais avançadas de previsão.
2. A aplicação de técnicas de ML e séries temporais mostra resultados promissores tanto na previsão quanto na detecção de irregularidades, mas ainda é incipiente no contexto

orçamentário brasileiro.

3. Pesquisas sobre LLMs e governança de dados indicam uma crescente preocupação com transparência, automação e uso ético da informação, aspectos fundamentais para qualquer iniciativa de análise preditiva de gastos públicos.

Portanto, o presente trabalho distingue-se por propor a integração de técnicas preditivas de aprendizado de máquina com uma arquitetura de sistema de gestão orçamentária, aplicada a dados reais da Universidade de Brasília. Essa integração busca preencher uma lacuna identificada na literatura: a ausência de soluções práticas que unam métodos estatísticos, inteligência artificial e governança de dados em prol da melhoria da qualidade do gasto público.

### 3 PROPOSTA DE ARQUITETURA

Neste capítulo, é apresentada a proposta de arquitetura do sistema de qualidade de gastos *ACCOUNTABILITY*, concebido para integrar informações de diferentes sistemas governamentais, apoiar a análise de dados financeiros e permitir a aplicação de modelos preditivos sobre a execução orçamentária. A arquitetura busca alinhar conceitos de governança de dados, interoperabilidade, transparência e eficiência administrativa, respondendo às demandas da sociedade e dos órgãos de controle por maior *accountability* na gestão pública.

#### 3.1 ARQUITETURA PROPOSTA

A solução arquitetural foi desenvolvida em três eixos complementares: (i) interoperabilidade e integração de dados, (ii) exposição segura de serviços e análise via *dashboards*, e (iii) aplicação de modelos preditivos para apoiar a tomada de decisão. Essas três frentes compõem uma visão sistêmica que conecta a coleta de dados, o tratamento e a disponibilização de informações para diferentes perfis de usuários.

##### 3.1.1 Proposta de Arquitetura de Interoperabilidade

O objetivo principal desta proposta é viabilizar a integração de dados orçamentários e financeiros a partir de múltiplas fontes, em especial o SIAFI (Sistema de Administração Financeira)<sup>1</sup>. O modelo adota um fluxo em quatro fases: (a) mapeamento de dados, (b) obtenção e armazenamento em um *Data Warehouse* (DW), (c) gestão de dados mestres e (d) análise e apoio à decisão por meio de ferramentas de *Business Intelligence* (BI).

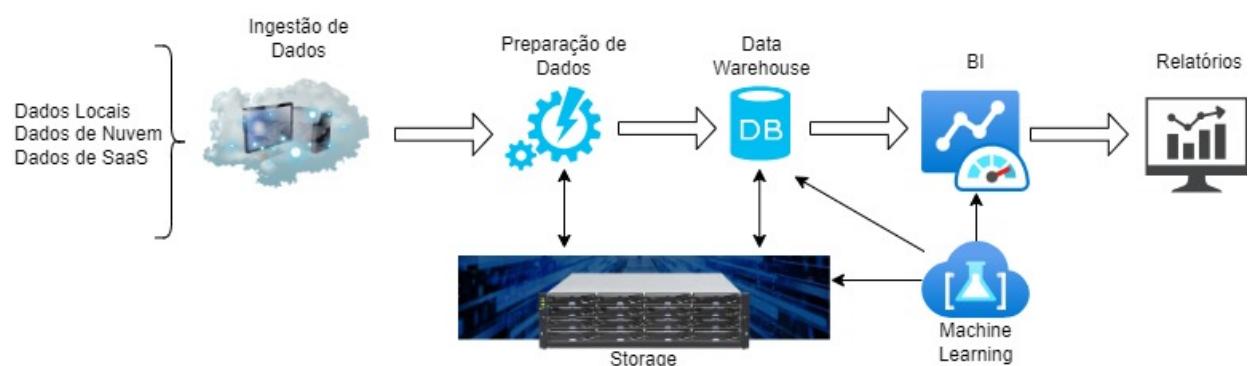


Figura 3.1: Proposta de Arquitetura de Interoperabilidade para coleta e análise de dados.

A Figura 3.1 destaca: (1) conectores para fontes governamentais (SIAFI e catálogos de dados abertos), (2) camada de ingestão/ETL (Python), (3) persistência em banco relacional e DW,

<sup>1</sup><<https://siafi.tesouro.gov.br/senha/public/pages/security/login.jsf>>

(4) semantic layer gestão de dados mestres (glossário, chaves, vocabulários), e (5) camada de consumo (BI, relatórios e serviços).

Como prova de conceito da arquitetura inicial foi desenvolvido um protótipo que foi implementado com suporte da Universidade de Brasília (DAF/UnB) e utiliza um módulo principal de coleta em Python, que organiza as informações em um repositório central e as disponibiliza para análise em *dashboards* desenvolvidos no Power BI. Dessa forma, gestores podem acompanhar a execução orçamentária quase em tempo real, identificar padrões e anomalias e elaborar relatórios de apoio à tomada de decisão.

**Leitura detalhada da Figura 3.1.** Da esquerda para a direita, a figura ilustra a interoperabilidade com sistemas estruturantes e fontes abertas; no bloco central, há o *pipeline* de ingestão e o repositório de dados (DW). Na parte superior, a governança de dados provê o dicionário (MTO), versionamento de esquemas e chaves (UO, UE, UR, DSP, DET). À direita, as superfícies de consumo *dashboards* e APIs habilitam análises descritivas (séries históricas, composição por natureza de despesa, % de RAP etc.) e análises diagnósticas (*drill-down* por UR/UE/DET).

### 3.1.2 Proposta de Arquitetura de Serviços Seguros

A segunda proposta aborda a necessidade de expor os serviços do sistema de forma segura e escalável. Adota-se uma arquitetura em três camadas: (i) **Exposição**, realizada por um *load balancer/reverse proxy* (Nginx), (ii) **Aplicação**, implementada em *FastAPI* com servidor Uvicorn, e (iii) **Persistência**, baseada em *PostgreSQL*.

Neste sentido, a arquitetura proposta na Figura 3.2, contempla ao lado da caixa da aplicação, estão listados os parâmetros de requisição (nível e códigos) e os serviços: (a) *endpoints REST* para consulta histórica e previsão e (b) rotinas de predição de séries temporais, de forma que são coletados os dados de gastos públicos (c) Nível de Organização dos dados e natureza das despesas. As funcionalidades da arquitetura seguem através de (a) Camada de aplicação de consolidado os dados com os dados já processados para a medição de predição na camada superior,(b) Os dados são escalonados e higienizados e assim realizada uma análise histórica dos dados e criado um modelo de predição através de séries temporais (*FastAPI*), em seguida em (c) os dados são armazenados em um sistema de gerenciamento de banco de dados SGBD (*PostgreSQL*), para consumo e utilizações posteriores.

O Nginx desempenha papel central como *reverse proxy*, encaminhando requisições externas, gerenciando certificados SSL/TLS e garantindo comunicação segura via HTTPS. Essa configuração assegura os pilares de confidencialidade, integridade e autenticidade das informações, aderente à LGPD e a normativos de conformidade. Além disso, foram configurados mecanismos de autenticação (básica/JWT) e políticas de CORS para restringir acessos a domínios confiáveis, fortalecendo a governança de acesso. Todo o ambiente é *containerizado* em Docker, o que simplifica a portabilidade e a escalabilidade horizontal do sistema.

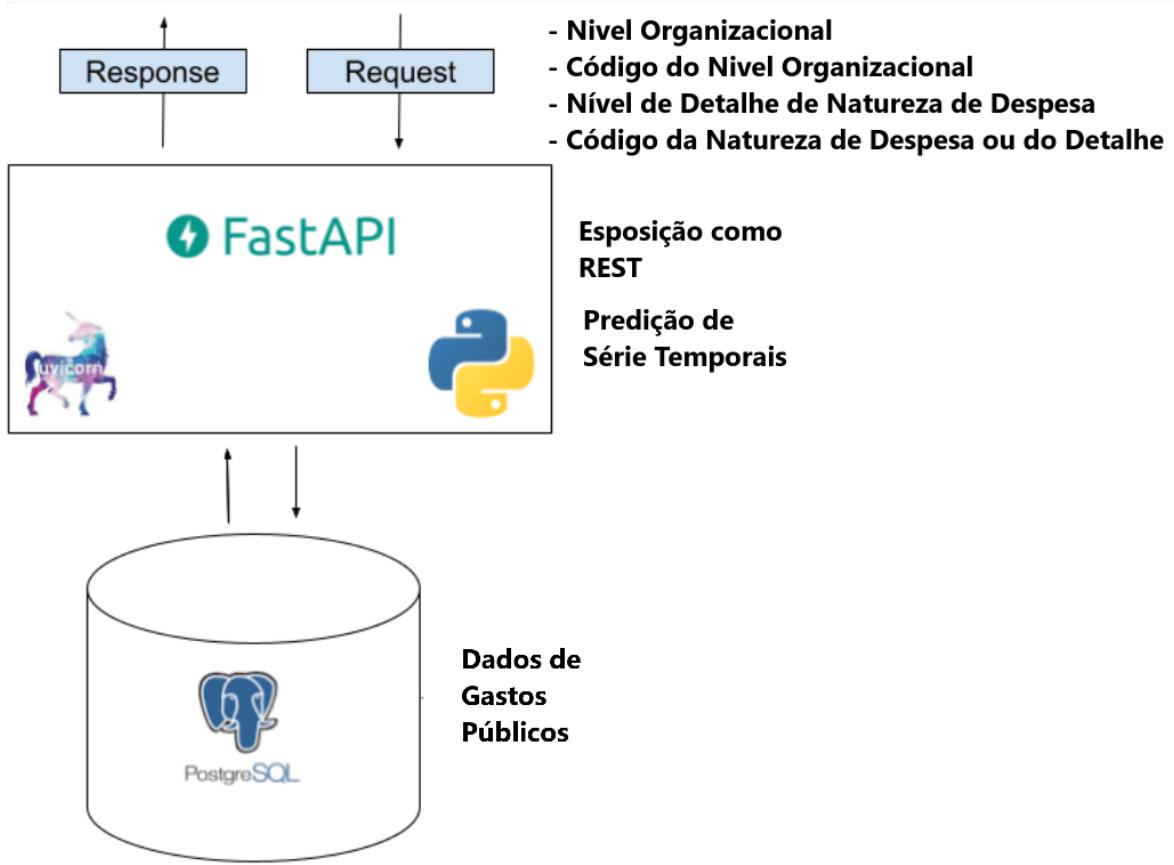


Figura 3.2: Exposição via FastAPI/Uvicorn com Nginx como *reverse proxy*, acessando o banco PostgreSQL.

### Contrato de consumo (exemplo).

```

GET /v1/series?nivel=UE&codigo=154040&tipo=DSP&classe=339014
→ 200 OK
{
  "chave": {"nivel": "UE", "codigo": "154040", "tipo": "DSP", "classe": "339014"},
  "historico": [{"anomes": "2023-01", "valor": ...}, ...],
  "predicao": [{"anomes": "2024-10", "valor": ...}, ...],
  "metadados": {"pct_rap": 0.18, "zeros": 0.22, "origem": "SIAFI"}
}

```

## 3.2 COLETA E PRÉ-PROCESSAMENTO DOS DADOS (MER E MTO)

A coleta foi realizada a partir de fontes governamentais oficiais (SIAFI/datalake institucional), complementadas por bases internas da UnB, com extração e integração em Python e persistência em PostgreSQL. Os dados alimentam tanto as superfícies de BI quanto os serviços REST.

### 3.2.1 Modelo Entidade–Relacionamento (MER)

O Modelo Entidade–Relacionamento (MER) é uma representação conceitual utilizada na modelagem de bancos de dados para descrever as informações de um sistema e a forma como elas se relacionam. Ele é composto por entidades, que representam objetos do mundo real (como pessoas, produtos ou contas), e relacionamentos, que expressam as interações entre essas entidades. Por meio de símbolos gráficos, como retângulos (entidades), losangos (relacionamentos) e elipses (atributos), o MER permite visualizar de forma clara e organizada como os dados estão estruturados antes de serem implementados fisicamente em um banco de dados.

A principal função do MER é servir como uma ponte entre a visão conceitual do problema e o modelo lógico do banco de dados. Ele ajuda analistas e desenvolvedores a compreender o domínio de informação e a garantir que todos os requisitos de dados do sistema sejam representados corretamente. Além disso, o modelo facilita a identificação de chaves primárias, atributos dependentes e cardinalidades (1:1, 1:N, N:M), assegurando a integridade e consistência das informações ao longo de todo o ciclo de vida do sistema.

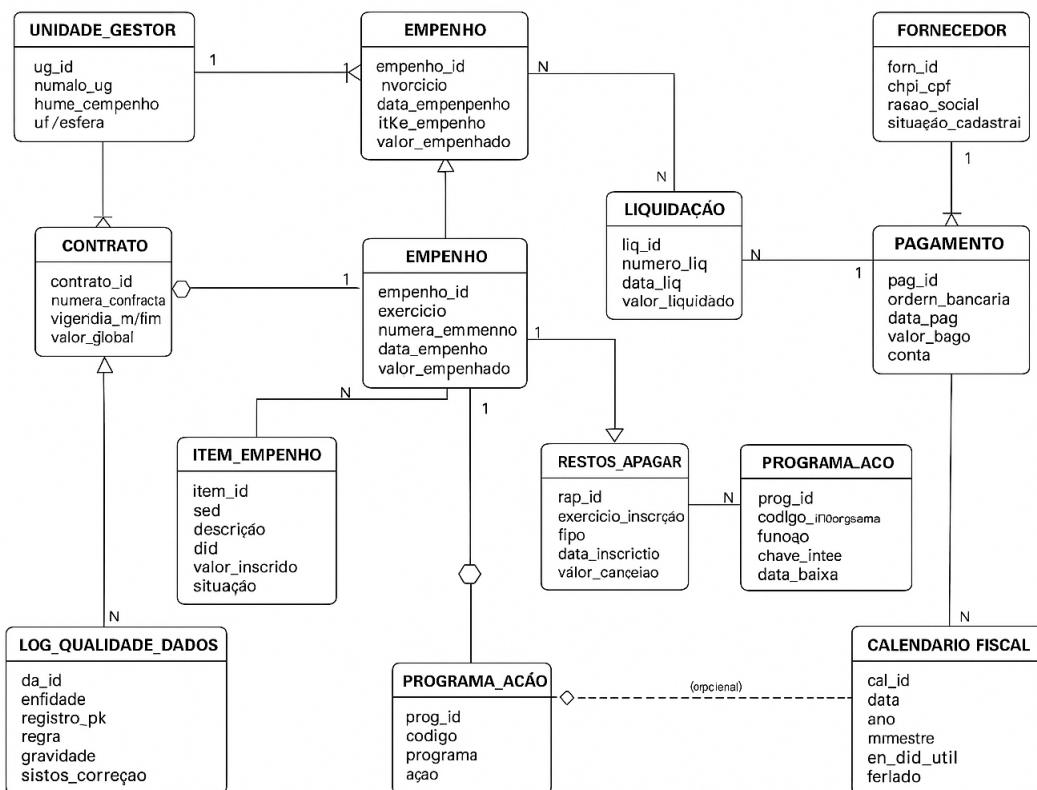


Figura 3.3: Modelo de Entidade e Relacionamento da arquitetura proposta

Fonte: MER da Arquitetura

Em ambientes corporativos e governamentais, o MER é uma ferramenta essencial para projetos que envolvem grande volume de dados, como sistemas orçamentários, financeiros ou de gestão de pessoas. Ele permite documentar o fluxo de informações, reduzir redundâncias, e

oferecer uma base sólida para análises preditivas, auditorias e integração entre sistemas. Assim, o MER não apenas estrutura os dados, mas também viabiliza o controle, a governança e a confiabilidade das informações que sustentam a tomada de decisão organizacional.

O MER lógico descrito na Figura 3.3 organiza as entidades centrais do domínio e seus relacionamentos:

- **UnidadeOrcamentaria (UO), UnidadeExecutora (UE), UnidadeResponsavel (UR);**
- **Despesa (DSP) e DetalheDespesa (DET);**
- **Documento/Lancamento** (empenho, liquidação, pagamento, RAP);
- **ExecucaoMensal** (agregações por (UO/UE/UR, DSP/DET));
- **RestoAPagar** (RPNP e processado);
- **Calendario** (anomesdia, hierarquias de tempo).

### 3.2.2 Glossário/Dicionário de Dados (MTO)

O Manual Técnico Orçamentário (MTO) é um documento elaborado com o objetivo de orientar os órgãos e entidades da administração pública na elaboração, execução e acompanhamento do orçamento público. Ele detalha os procedimentos técnicos, classificações orçamentárias, conceitos e padronizações que devem ser seguidos na construção das peças orçamentárias, como o Plano Plurianual (PPA), a Lei de Diretrizes Orçamentárias (LDO) e a Lei Orçamentária Anual (LOA). O MTO também estabelece diretrizes para a utilização dos códigos orçamentários, a estrutura programática, as fontes de recursos e os critérios de alocação das despesas, garantindo a uniformidade das informações e a transparência no processo de planejamento e execução orçamentária.

Além de sua função normativa, o MTO é uma ferramenta essencial para assegurar a coerência entre o planejamento governamental e a alocação dos recursos públicos. Ele permite que gestores, analistas e técnicos compreendam de forma padronizada como estruturar programas, ações e metas orçamentárias, possibilitando uma gestão mais eficiente e o controle social sobre a aplicação dos recursos. Assim, o MTO contribui para o fortalecimento da governança pública, promovendo maior consistência técnica nas decisões orçamentárias e facilitando a integração entre planejamento estratégico, monitoramento de resultados e prestação de contas à sociedade.

Em uma análise orçamentária, conforme descrita na Figura 3.4 os principais campos do Manual Técnico Orçamentário (MTO) são aqueles que estruturam e organizam as informações que compõem o orçamento público, permitindo a correta identificação, classificação e execução das despesas e receitas. Esses campos são essenciais para garantir a padronização das peças orçamentárias (PPA, LDO e LOA) e para possibilitar o acompanhamento da aplicação dos recursos públicos. A seguir estão os principais campos do MTO, agrupados por natureza e função:

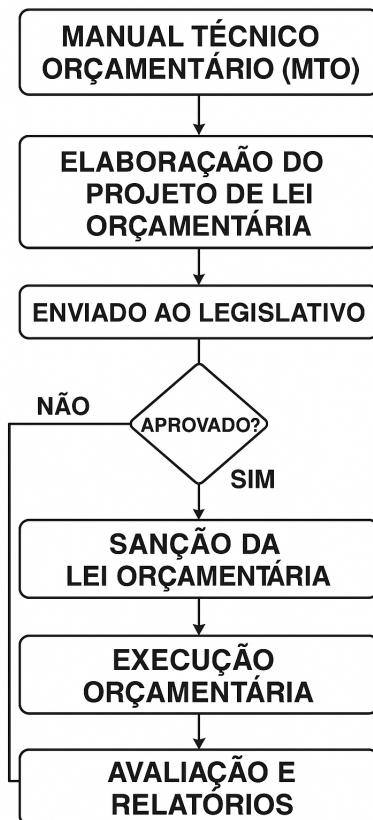


Figura 3.4: Fluxograma de Execução do MTO

Fonte: <https://www.gov.br/dnocs/pt-br/centrais-de-conteudo/documentos/dg-gab-dpo/manuais/guiaorcamento.pdf>

## 1 Identificação e Estrutura Programática

- Órgão e Unidade Orçamentária: identificam o ente responsável pela execução da despesa.
- Função e Subfunção: classificam a área de atuação governamental (ex.: saúde, educação, segurança pública).
- Programa: representa o conjunto de ações voltadas a um objetivo de governo.
- Ação: especifica as atividades, projetos ou operações especiais que concretizam o programa.
- Produto e Unidade de Medida: definem o resultado físico esperado (ex.: “escolas construídas”, “quilômetros pavimentados”).

## 2 - Classificação da Despesa

- Categoria Econômica: indica se a despesa é corrente (custos operacionais) ou de capital (investimentos).
- Grupo de Natureza da Despesa (GND): detalha o tipo de gasto (ex.: pessoal e encargos, investimentos, outras despesas correntes).

- Elemento de Despesa: identifica com precisão o item de gasto (ex.: material de consumo, serviços de terceiros, equipamentos).
- Modalidade de Aplicação: mostra se o gasto será executado diretamente ou por transferência a outro ente (ex.: convênios, descentralizações).
- Fonte/Destinação de Recursos: informa a origem do dinheiro (ex.: recursos próprios, convênios, operações de crédito).

### **3 - Planejamento, Execução e Controle**

- Meta Física e Meta Financeira: definem o que será entregue (em quantidade) e o valor necessário para a execução.
- Indicador de Resultado: mede o impacto da ação em relação aos objetivos do programa.
- Identificador de Uso: indica se a despesa está vinculada a operações específicas (ex.: contrapartidas de convênios).
- Identificador de Resultado Primário (RP): informa se a despesa afeta o cálculo do resultado primário das contas públicas.
- Esfera Orçamentária: distingue se o gasto pertence ao orçamento fiscal, da seguridade social ou de investimento das estatais.

### **4 - Pré-processamento**

- Normalização de *strings*/códigos e *parsing* de datas (UTC, ISO 8601).
- Construção de anomesdia (YYYY-MM-01) e agregações mensais por chave analítica.
- Conciliação exercício × RAP e formação do *gasto\_total*.
- Deduplicação e preservação de estornos (com *flag*).
- Criação de *features*: comprimento da série, % de zeros, % de RAP, IQR/mediana, *flag\_pandemia*.

A tabela 3.1 descreve os principais campos em uma série de etapas sequenciais que um item percorre para ser processado ou transformado em um resultado final, de forma que os dados brutos são coletados, transformados e carregados, e que o software automatiza e padroniza o desenvolvimento, teste e implantação do código.

Tabela 3.1: MTO — principais campos utilizados no pipeline

Campo	Tipo	Descrição
uo, ue, ur	chave	Códigos institucionais (orçamentária, executora, responsável).
dsp, det	chave	Natureza da despesa e seu detalhamento (classificação econômica).
nivel_organizacional	categ.	Nível analítico adotado (UO/UE/UR).
doc, tipo_lancamento	categ.	Empenho, liquidação, pagamento, RAP etc.
data_emissao, anomesdia	data	Datas de referência; anomesdia = 1º dia do mês.
vl_liquidado, vl_rpnpl	num.	Valores de exercício e restos a pagar (não processados).
gasto_total	num.	Consolidação exercício + RAP após tratamentos.
flags	bool	flag_estorno, flag_evento, flag_imput.

### 3.2.3 Proposta de Arquitetura de Análise Preditiva

Inicialmente, para a definição das técnicas de predições a serem utilizadas, foram gerados gráficos representativos dos dados, de modo a responder alguns questionamentos pertinentes. São eles: “Existem padrões consistentes?”, “Existe uma tendência significativa?”, “A sazonalidade é importante para o modelo?”, “Há evidências da presença de ciclos econômicos (no caso de gastos)?”, “Existem valores discrepantes nos dados que precisam ser explicados por pessoas com conhecimento especializado?”, “Quão fortes são as relações entre as variáveis disponíveis para análise?”. Vale ressaltar que cada modelo é em si uma construção artificial que se baseia num conjunto de pressupostos (explícitos e implícitos) e geralmente envolve um ou mais parâmetros que devem ser estimados utilizando os dados históricos conhecidos. O modelo deve prever mecanismos que permitam a operação de previsão de 12 meses após o mês corrente e de validação dos últimos 12 meses ocorridos.

A Proposta de Arquitetura de Análise Preditiva descrita na figura 3.5, foi pensada para órgãos/empresas que precisam prever indicadores (ex.: arrecadação, inadimplência, demanda, risco operacional) com governança de dados, MLOps e conformidade regulatória (LGPD). Neste sentido a figura foi classificada em 7 grandes fases.

#### 1 - Visão geral e objetivos

- Objetivo: criar uma plataforma escalável para gerar previsões confiáveis, auditáveis e de fácil operação (do dado cru ao insight), habilitando ciclos curtos de experimentação e entrega.
- Resultados esperados: aumento de acurácia das previsões (>10–20 baseline), redução de tempo de modelagem (de semanas para dias), trilha de auditoria ponta a ponta e automação de monitoramento/drift.

#### 2 - Escopo analítico (exemplos)

- Casos de uso: previsão de receitas/despesas, detecção de anomalias em execução orçamentária, previsão de demanda de serviços, propensão a atraso (p. ex., restos a pagar

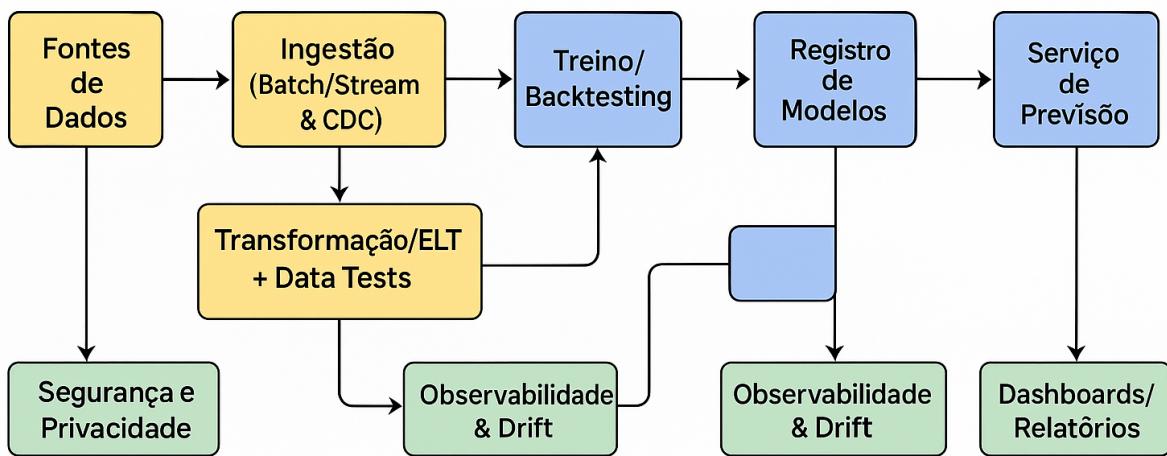


Figura 3.5: Modelo de arquitetura para análise preditiva

não processados), risco de fraude/erro em cadastros e contratos.

- Horizontes: curto (dias–semanas) e médio prazo (meses); granularidade por unidade, centro de custo, programa ou fornecedor.

## 2 - Fontes de dados e qualidade

- Fontes: ERPs(financeiro/contábil), sistemas transacionais (empenho/liquidação/pagamento), planilhas legadas, APIs externas (econômicas), logs de sistemas.
- Qualidade e incongruências: perfilamento (profiling), regras de validação, padronização de chaves, reconciliação contábil (empenho–liquidação–pagamento), imputação controlada, deduplicação e record linkage, checagem de outliers, e catálogo de data quality com SLAs.
- Tratamento de restos a pagar: classificação (processados vs. não processados), vinculação aos eventos de liquidação/pagamento, estorno/cancelamento válido, criação de features temporais (idade do empenho, sazonalidade, histórico de execução por credor/programa).

## 4 - Arquitetura lógica (camadas)

- Ingestão (batch/stream): conectores para bancos relacionais, arquivos e APIs; CDC para tabelas críticas.

- Data Lake/Lakehouse (zona raw → clean → curated): formatos colunares, partições por data/entidade, schema evolution, catálogo de metadados.
- Transformação/ELT: orquestração com DAGs, tests em dados (ex.: Great Expectations), regras de padronização e agregações.
- Feature Store: reuso e versionamento de variáveis (ex.: atraso médio, lags/leads, sazonalidade, indicadores de qualidade).
- Modelagem e Treino: notebooks reproduutíveis + pipelines (AutoML opcional) para séries temporais (ARIMA/SARIMA/Prophet/ETS), ML supervisionado (GBMs, Random Forest, XGBoost, LightGBM) e modelos de classificação de risco.
- Registro de Modelos (Model Registry) e Serviço de Previsão (batch e tempo real via APIs).
- MLOps: CI/CD de dados e modelos, canary/blue-green, rollback, rastreabilidade (dados → código → modelo → previsão).
- Observabilidade: monitor de data quality, métricas de modelo (MAE/MAPE/AUC), drift de dados e concept drift, alarmes.
- Camada de Consumo: dashboards BI, relatórios automatizados, exportações para sistemas legados.

## 5 - Segurança, privacidade e governança

- LGPD: minimização de dados, anonimização/pseudonimização quando aplicável, controle de acesso por papéis (RBAC/ABAC), data masking e lineage completo.
- Governança: catálogo de dados, glossário (ex.: definições de empenho/liquidação/restos a pagar), políticas de retenção e versionamento.

## 6 - Pipeline de ponta a ponta (exemplo)

- Coleta diária + CDC → 2) Validação e reconciliação (incongruências e restos a pagar) → 3) Enriquecimento (indicadores macro, calendário fiscal) → 4) Engenharia de features (lags, rolling windows, encoders categóricos, variáveis de qualidade) → 5) Seleção de modelos e backtesting com validação temporal (expanding/rolling windows) → 6) Champion/Challenger → 7) Publicação de previsões (batch semanal e API para what-if) → 8) Monitoramento e retraining por gatilhos (drift/queda de acurácia).

## 7 - Padrões de modelagem e validação

- Séries temporais: cross-validation temporal, tratamento de feriados/sazonalidade, hierarchical forecasting (agregar/desagregar por órgão, programa).

- Classificação/regressão: stratified split, feature importance e interpretabilidade (SHAP), testes de robustez e stress tests.
- Métricas: MAPE/MAE/RMSE para previsão; AUC/KS/Recall para risco; métricas de estabilidade (PSI) para monitoramento.

Esta proposta foca o uso de modelos estatísticos e de IA para previsão de gastos públicos. A arquitetura está estruturada como um *pipeline* (Figura 3.6) e executa, para cada chave analítica (UE/UR × DSP/DET), um conjunto de tratamentos e um modelo univariado mensal.

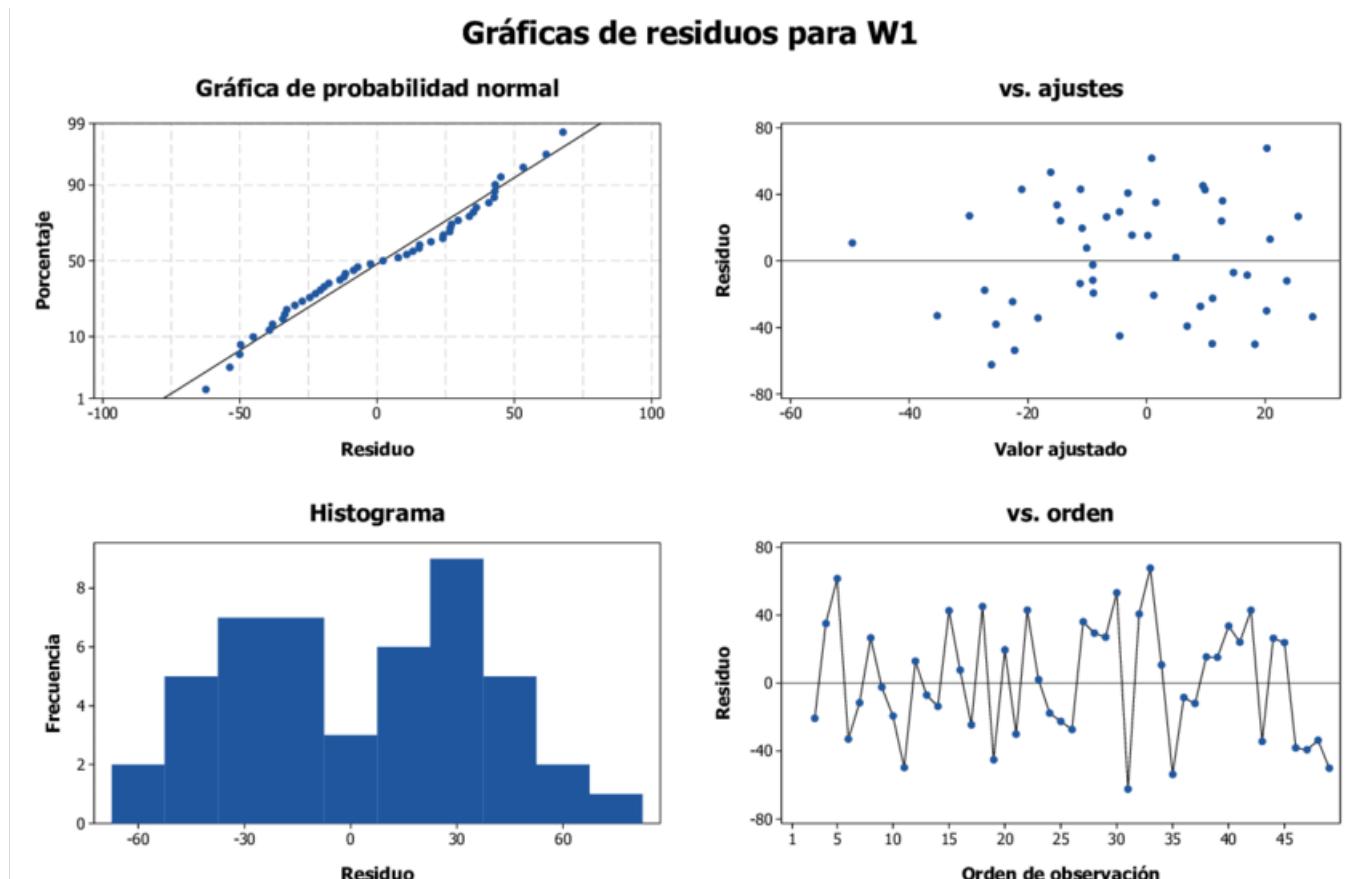


Figura 3.6: Modelo de Séries Temporais (Classificação e Regressão)

Fonte: Resultados Extraídos do Estudo de Caso

### Leitura detalhada do *pipeline*.

- **Entrada** - parâmetros do usuário: nível organizacional, códigos (UE/UR, DSP/DET) e horizonte.
- **Avalia\_entradas** - valida consistência, existência das chaves e suficiência do histórico.
- **Tratamento\_rap** - identifica RPNP/RPP e vincula ao exercício; pode redistribuir temporalmente para reduzir concentração artificial.

- **Tratamento\_ajuste** - resolve incongruências (estornos, duplicatas), aplica transformação (log/Box–Cox) e *flags* de outliers.
- **Retorna\_dados** - retorna série mensal agregada (ano/mes/dia, valor) com metadados (zeros, %RAP, IQR).
- **Gera\_parametros\_predicao** - executa ADF, Mann–Kendall e Kruskal–Wallis para guiar  $d$ ,  $D$  e sazonalidade; roda *auto-ARIMA*.
- **Retorna\_predicao** - projeta próximos meses, recompõe escala e devolve em JSON; registra *logs* de decisão.

**Tempo de resposta e operação:** O tempo médio por série ficou em torno de 10–15 s, variando com o tamanho/qualidade do histórico. Essa latência permite uso interativo em *dashboards* e serviços.

### 3.3 ANÁLISE EXPLORATÓRIA DOS DADOS

Como etapa inicial, é importante selecionar níveis de agregação ou granularidade que permitam uma análise, evitando níveis com pouca informação.

---

#### Algoritmo 1 Aplicar Regras de Negócio

---

```

1  PROCEDURE APPLICAR_REGRAS_NEGOCIO(dados_stg) RETURNS Dict:
2      VAR curated = {}
3
4      // Classificações derivadas
5      curated["despesa_classificada"] = CLASSIFICAR_DESPESAS(
6          base=dados_stg,
7          regras=[
8              MAPEAR_ND_PARA_ECONOMICA(), // Corrente/Capital
9              TAG_OBRIGATORIA_VS_DISCRICIONARIA(),
10             TAG_INVESTIMENTO(), TAG_PESSOAL_BENEFICIOS(), TAG_CUSTEIO()
11         ]
12     )
13
14     // Calendário fiscal e sazonalidade
15     curated["calendario"] = GERAR_DIM_CALENDARIO_FISCAL(ano_min=2000,
16                                         ano_max=ANO(DATA_ATUAL))
17
18     // Rateios/ajustes (ex.: transferências intra-governo)
19     curated["ajustes"] = REGRAS_RATEIO_E_ELIMINACAO_DUPLICIDADE(dados_stg)
20
21     // Histórico para SCD2 (dimensões que mudam com o tempo)
22     curated["dimensoes_scd2"] = PREPARAR_SCD2(dados_stg)
23
24     RETURN curated
25 END PROCEDURE

```

---

No Pseudocódigo *Algoritmo 1 Aplicar Regras de Negócio* descreve um primeiro exemplo de aplicação de predição de dados em que a exploração evidenciou três comportamentos: (i) **sazonalidade** em séries recorrentes; (ii) **esparsidade** em granularidades finas (UR+DET) e (iii) **picos atípicos** (concentração de pagamentos e efeitos contábeis), em podem ser melhor explorado nos resultados do capítulo 4.

Para iniciar as abordagens de verificação de agregação de dados, foi realizada uma análise de suficiência de dados, verificando, assim, o número de pontos de dados (mínimo de 30-50 pontos de dados é geralmente considerado suficiente para aplicar modelos de séries temporais tradicionais (como ARIMA) com maior precisão) e a distribuição temporal dos dados (se os dados em cada nível são distribuídos ao longo do tempo de forma uniforme ou se há lacunas significativas. Séries com muitas lacunas, ou que estejam concentradas em períodos curtos, podem não ser adequadas para modelagem preditiva). Em seguida, foram realizadas as análises de contribuição e variabilidade de cada nível dos dados. Níveis que apresentam pouca variabilidade ou contribuição podem não ser relevantes para uma previsão detalhada e, portanto, podem ser agregados a outros níveis.

**Testes diagnósticos.** Para cada série, aplicamos: ADF (estacionariedade), Mann–Kendall (tendência), Kruskal–Wallis (diferenças por blocos sazonais). Os resultados guiaram a diferenciação  $d$  e  $D$  e o uso de sazonalidade  $s=12$ .

### 3.4 TÉCNICAS DE TRATAMENTO DE DADOS INCONGRUENTES E RESTOS A PAGAR

As técnicas de tratamento de dados incongruentes são essenciais para assegurar a consistência e confiabilidade das informações utilizadas em análises orçamentárias e contábeis. Dados incongruentes são aqueles que apresentam inconsistências, lacunas ou divergências em relação a registros esperados ou padrões de referência. O tratamento envolve etapas como validação, padronização e cruzamento de dados, utilizando ferramentas estatísticas, algoritmos de detecção de anomalias e auditorias automatizadas. Técnicas como imputação de valores ausentes, normalização de formatos, reconciliação contábil e checagem cruzada entre sistemas (por exemplo, SIGA, SIAFI ou SIGPlan) são aplicadas para eliminar erros e garantir integridade. Esse processo é indispensável para tomadas de decisão seguras e para a elaboração de relatórios gerenciais confiáveis.

Já o tratamento dos restos a pagar refere-se à análise e conciliação de despesas empenhadas mas não pagas até o encerramento do exercício financeiro. O controle envolve a verificação da validade dos empenhos, a classificação entre restos processados (já liquidados) e não processados (a liquidar), bem como a reavaliação da pertinência de sua manutenção no exercício seguinte. Técnicas como cruzamento de dados com registros de liquidação, revisão documental,

auditorias contábeis e cancelamento de valores prescritos são aplicadas para evitar distorções nas demonstrações financeiras. O tratamento adequado dos restos a pagar contribui para a transparência fiscal, o equilíbrio das contas públicas e o cumprimento das normas da Lei de Responsabilidade Fiscal (LRF).

### **Restos a Pagar (RAP/RPP)**

- Identificação e vínculo do RP ao exercício de origem; cálculo de %RAP anual.
- Redistribuição temporal opcional (mesma soma anual), reduzindo concentração artificial.
- Sinalização de séries com alta dependência de RP, para leitura cuidadosa da previsão.

### **Lançamentos negativos, estornos e outliers**

- Estornos preservados com `flag` (para auditoria e análises sensíveis).
- Outliers marcados por `flag_evento` (ex.: pandemia, mutirões); três estratégias: manter, winsorizar, excluir do ajuste e reincluir na projeção.
- Zeros estruturais mantidos; sua proporção informa a escolha de modelo/validação.

### **Imputação e lacunas**

Interpolação temporal (linear) é aplicada apenas quando há indício de falha de integração. Ausências por inexistência de execução não são imputadas.

## **3.5 MODELOS PREDITIVOS E SUAS JUSTIFICATIVAS**

Os modelos preditivos são métodos estatísticos e computacionais utilizados para estimar comportamentos futuros com base em dados históricos e padrões observados. Eles são amplamente aplicados em áreas como economia, finanças, gestão pública e ciência de dados para antecipar tendências, prever receitas, despesas, demandas e riscos. Esses modelos permitem transformar grandes volumes de dados em informações estratégicas, apoiando decisões mais precisas e fundamentadas. A base dos modelos preditivos está na identificação de relações entre variáveis, no reconhecimento de padrões temporais e na construção de algoritmos capazes de generalizar o comportamento observado para projeções futuras.

### **3.5.1 ARIMA/SARIMA**

Conforme já descrito no capítulo 2, entre os modelos preditivos mais utilizados estão os modelos de séries temporais, como o ARIMA (AutoRegressive Integrated Moving Average). O

ARIMA combina três componentes principais: A parte autorregressiva (AR), que usa valores passados da série; a parte de médias móveis (MA), que considera erros passados; e a integração (I), que transforma séries não estacionárias em estacionárias. Esse modelo é eficaz para previsões de curto e médio prazo, especialmente quando há uma sequência de observações regulares no tempo, como séries de arrecadação, execução orçamentária ou consumo energético. Sua justificativa de uso se baseia na capacidade de capturar padrões lineares e tendências históricas, fornecendo previsões robustas e interpretáveis.

Para cenários mais complexos que envolvem sazonalidade, ou seja, flutuações periódicas ao longo do tempo, o SARIMA (Seasonal ARIMA) é uma evolução natural do ARIMA. Ele incorpora componentes sazonais adicionais (SAR, SMA e SI) que permitem representar oscilações recorrentes — como variações mensais, trimestrais ou anuais. Essa característica o torna especialmente útil para previsões orçamentárias e econômicas que seguem ciclos fiscais ou comportamentos repetitivos. A justificativa para o uso do SARIMA reside na sua precisão em contextos com padrões sazonais marcantes e na sua flexibilidade para ajustar-se a diferentes frequências de observação, mantendo a interpretabilidade e a confiabilidade típicas dos modelos estatísticos clássicos.

- Transparência e auditabilidade; bom desempenho em séries sazonais.
- Seleção automática (*auto-ARIMA*) por AIC/BIC; sazonalidade  $s=12$ .
- Transformações:  $\log(1+x)$  ou Box–Cox; tratamento de eventos extremos.

### 3.5.2 LLMs como apoio analítico

Os Modelos de Linguagem de Grande Escala (LLMs – Large Language Models) representam um avanço significativo no campo da inteligência artificial, sendo capazes de processar, compreender e gerar linguagem natural de forma contextual e coerente. Quando aplicados como ferramentas de apoio analítico, os LLMs podem interpretar grandes volumes de informações textuais, sintetizar relatórios complexos, gerar resumos executivos e até mesmo auxiliar na elaboração de análises estatísticas ou financeiras. Sua capacidade de reconhecer padrões linguísticos e semânticos torna-os extremamente úteis para automatizar tarefas analíticas que antes exigiam leitura humana detalhada, como a identificação de tendências, a classificação de informações e a geração de insights a partir de dados não estruturados.

Além disso, os LLMs podem ser integrados a sistemas de análise preditiva e business intelligence, funcionando como interfaces inteligentes que traduzem dados técnicos em linguagem acessível para gestores e tomadores de decisão. Eles são capazes de sugerir hipóteses, elaborar diagnósticos e interpretar resultados de modelos quantitativos, como regressões e séries temporais, de forma interativa. Essa integração entre linguagem natural e análise de dados amplia a eficiência dos processos de tomada de decisão, favorecendo a inteligência analítica contextual na qual a compreensão de números, textos e padrões ocorre de forma integrada e dinâmica.

- *PandasAI/LLMs* auxiliam na identificação de padrões irregulares e na explicabilidade.
- Em séries com picos abruptos, LLMs tendem a suavizar; portanto, usados como *assistentes* e não como modelo final.

### 3.5.3 Protocolo de validação temporal

- **Rolling-origin:** treina até  $t$ , prevê  $t+1$ , avança janela.
- **Baselines:** *naïve* ( $\hat{y}_t = y_{t-1}$ ) e *seasonal naïve* ( $\hat{y}_t = y_{t-12}$ ).
- **Horizonte:** até 12 meses para séries com  $\geq 36$  meses.

Uma vez selecionado um modelo e estimados seus parâmetros, o modelo é usado para fazer previsões. O desempenho do modelo só poderá ser devidamente avaliado após a disponibilização dos dados do período de previsão. Para gerar estimadores que permitam comparar a eficácia de diferentes previsões em séries temporais, utilizam-se diversas métricas estatísticas que avaliam a qualidade das previsões em relação aos valores observados. Essas métricas podem ser aplicadas para comparar diferentes modelos e identificar qual deles fornece previsões mais precisas. A seguir estão os principais estimadores (ou métricas de erro) usados para comparar resultados de previsões: (i) Erro Médio Absoluto (MAE - Mean Absolute Error): O MAE mede a magnitude média dos erros em um conjunto de previsões, sem levar em consideração a direção do erro (positivo ou negativo); (ii) Erro Médio Quadrático (MSE - Mean Squared Error): O MSE é uma métrica que penaliza erros maiores mais severamente, já que os erros são elevados ao quadrado; (iii) Raiz do Erro Médio Quadrático (RMSE - Root Mean Squared Error): O RMSE é a raiz quadrada do MSE, trazendo a métrica de volta à unidade original dos dados e; (iv) Erro Percentual Absoluto Médio (MAPE - Mean Absolute Percentage Error): O MAPE calcula o erro em termos percentuais, sendo útil para comparar séries temporais com escalas diferentes.

## Resultados ilustrativos

A Figura 3.7 apresenta um exemplo de resultados da previsão para uma despesa típica da universidade, onde nos períodos de férias escolares há uma redução de gastos e no período letivo há um crescimento da despesa. É possível observar que o modelo obteve uma previsão correta, diferenciando os períodos de férias escolares e períodos letivos, gerando previsões consideráveis da despesa ao longo do ano.

- Em séries agregadas (DSP/UE), as projeções acompanham bem a tendência (Figura 3.7)
- Em granularidades finas (UR+DET), há maior erro em meses com picos Figura 4.6 e 4.7).

**Desempenho operacional.** O tempo médio de processamento é de 10 a 15 segundos por chave analítica, podendo variar conforme o histórico de dados e o volume de tratamentos aplicados,

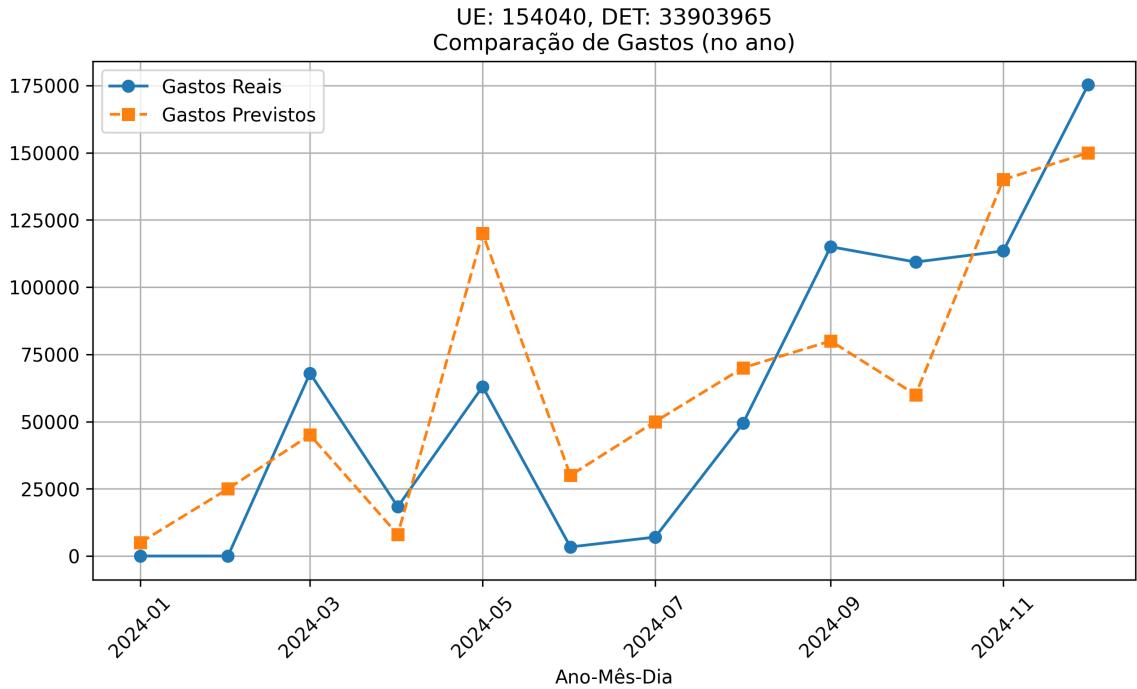


Figura 3.7: Modelos de Séries Temporais

Fonte: Resultados dos Trabalho

como identificação de RAPs e detecção de outliers, que impactam diretamente na complexidade e no tempo de execução das análises.

### 3.6 CRITÉRIOS DE AVALIAÇÃO DO MODELO

Sejam  $y_t$  os valores observados e  $\hat{y}_t$  as previsões, para  $t = 1, \dots, n$ :

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|, \quad (3.1)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}, \quad (3.2)$$

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t + \epsilon} \right|, \quad \epsilon > 0, \quad (3.3)$$

$$\text{sMAPE} = \frac{100}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{(|y_t| + |\hat{y}_t|)/2}, \quad (3.4)$$

$$\text{MASE} = \frac{\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{1}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|}. \quad (3.5)$$

Estratégias de leitura:

- **Planejamento macro (DSP/UE):** priorizar MAPE/sMAPE pela interpretabilidade percentual.
- **Auditoria (DET/UR):** observar RMSE e inspeção visual de resíduos para identificar meses críticos.
- **Esparsidade alta:** preferir MASE e comparar com a *seasonal naïve*.

### 3.7 GOVERNANÇA, SEGURANÇA, MLOPS E OBSERVABILIDADE

A Governança, segurança, MLOps e observabilidade são pilares interdependentes que sustentam a confiabilidade e o controle dos sistemas baseados em inteligência artificial. A governança estabelece políticas, processos e responsabilidades que asseguram o uso ético, transparente e auditável dos dados e modelos. A segurança garante a proteção das informações e dos pipelines contra acessos indevidos, manipulações e vulnerabilidades, mantendo a integridade e a confidencialidade. O MLOps (Machine Learning Operations) integra práticas de DevOps ao ciclo de vida dos modelos de aprendizado de máquina, promovendo automação, versionamento, monitoramento e reproduzibilidade desde o treinamento até a implantação. Já a observabilidade oferece visibilidade contínua sobre o comportamento dos sistemas, permitindo detectar falhas, analisar métricas de desempenho e otimizar os modelos em produção, assegurando eficiência, confiabilidade e conformidade em ambientes complexos.

#### Segurança e conformidade

- **Transporte:** HTTPS (TLS 1.2+), cabeçalhos de segurança (HSTS, CSP), CORS restritivo.
- **Acesso:** autenticação (básica/JWT), escopos por *role* (leitura, predição).
- **LGPD:** minimização de dados pessoais (INEXISTENTES na base de gastos), *logs* de acesso e trilhas de auditoria.

#### MLOps e reproduzibilidade

- **Empacotamento:** Docker com *pin* de dependências.
- **Versionamento:** Git para código e migrações de esquema; *tags* de modelos e hiperparâmetros.
- **Observabilidade:** métricas de latência/erros (Prometheus/Grafana), *healthcheck* e *circuit breaker* no Nginx.

## Custo, escalabilidade e papéis

- **Escala:** instâncias FastAPI escaladas horizontalmente; DB com réplicas de leitura.
- **Papéis:** Eng. de Dados (ETL/DW), Cientista de Dados (modelagem), Eng. de *Machine Learning* (MLOps), Gestor (uso/validação).

## 3.8 DISCUSSÃO CRÍTICA E LIMITAÇÕES

- **Dependência de histórico:** séries com < 24 meses geram previsões mais incertas.
- **Picos excepcionais:** modelos tendem a subestimar valores concentrados (ex.: mutirões, grandes contratos).
- **RAP:** mesmo tratado, pode induzir deslocamentos temporais; a leitura gerencial deve considerar o indicador %RAP.
- **LLMs:** úteis como apoio, mas não substituem a modelagem estatística para séries orçamentárias.

## 3.9 SÍNTESE DO CAPÍTULO

A arquitetura do *ACCOUNTABILITY* integra (i) uma base interoperável e governada, (ii) uma camada segura de serviços e (iii) um *pipeline* preditivo auditável (ARIMA/SARIMA com apoio de LLMs), operacionalizado por FastAPI/Uvicorn e PostgreSQL sob Nginx/HTTPS. Os estudos de caso mostram boa aderência em níveis agregados (DSP/UE) e expõem os limites em granularidades finas (UR/DET), onde a variabilidade e a esparsidade são maiores. Como resultado, a solução habilita tanto o planejamento macro (previsões percentualmente interpretáveis) quanto o *drill-down* para auditoria e detecção de anomalias, reforçando os princípios de transparência, governança e *accountability* na gestão pública.

## 4 ANÁLISE E RESULTADOS

Este capítulo apresenta os resultados deste trabalho através da validação da arquitetura proposta, além de uma avaliação empírica da arquitetura e dos modelos de previsão implementados no *ACCOUNTABILITY*. O objetivo é demonstrar, com base em evidências quantitativas e qualitativas, em que medida a solução proposta é capaz de apoiar a gestão orçamentária, identificar padrões e sinalizar anomalias em diferentes níveis de granularidade. A análise combina métricas de erro (MAE, RMSE, MAPE, sMAPE e MASE) com interpretações visuais e gerenciais das séries históricas e previsões, conforme proposto na literatura de séries temporais [18].

Para validar a arquitetura a proposta, foram desenvolvidos dashboards no Power BI para atender às demandas recorrentes dos usuários ao longo dos anos, apresentando os dados mais solicitados de forma clara e concisa. Esses painéis foram projetados com base na análise das necessidades dos usuários e na experiência acumulada, identificando os principais recortes informacionais para fornecer insights valiosos para a tomada de decisões.

Os dashboards proporcionam acesso rápido às informações mais relevantes, facilitando a análise eficaz dos dados e contribuindo para uma tomada de decisão mais informada. Ao atender às demandas específicas dos usuários, essa ferramenta aumenta a satisfação e a eficiência no uso das informações, promovendo uma gestão mais eficaz e orientada por dados.

Assim como primeira parte dos resultados da arquitetura foi projetado e prototipado um modelo de sistema com um conjunto de Software composto por um módulo principal de coleta dos dados, que utiliza diversas fontes de informações, gerada a partir de dados abertos e de um modelo de interoperabilidade de dados gerencias. Tais informações são processadas, através um DW e disponibilizadas através de uma ferramenta de BI, consequentemente produzindo relatórios gerenciais para toda de descrição, conforme pode se observar na figura 4.1.

Esse modelo da figura 4.1 é controlado por um módulo de coleta desenvolvido em linguagem de programação Python, visando a coleta dos dados de diversas fontes de dados, sendo organizado e disponibilizado através de ferramentas de BI, onde o usuário visualiza as informações por meio de *dashboards* construídos com a utilização da ferramenta Power BI. Entretanto, já vem sendo desenvolvido funcionalidade que conduz o gestor a acompanhar o orçamento identificando quando e como utilizar os recursos disponíveis. Todas as informações são disponibilizadas por meio de um servidor principal, estando disponível em: <https://app.powerbi.com/view?r=eyJrIjoiNjljMD>

Os resultados da arquitetura proposta, foram realizados a partir da seleção de informações em fontes com dados abertos inicialmente da Universidade de Brasília. No segundo momento, esses dados são minerados e extraídos para uma base multidimensional a partir daí os dados são

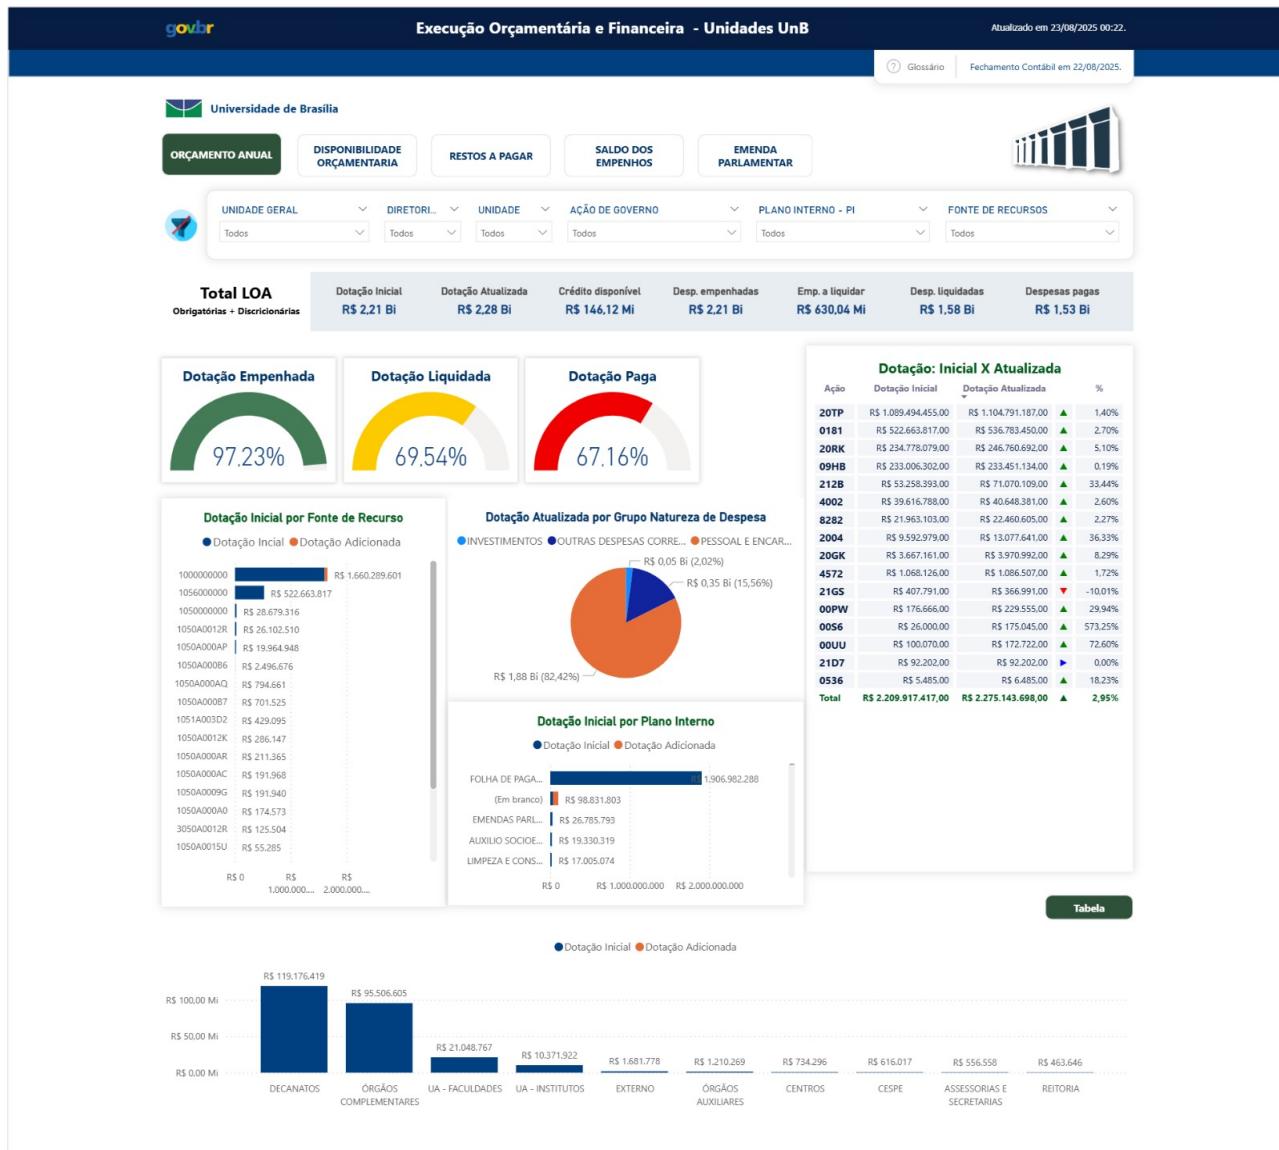


Figura 4.1: Painel Geral de Resultados da Arquitetura Proposta

Fonte: Painel de Resultado - BI

coletados e processados por meio de ferramentas de ETL - Extract Transform Load. Em seguida, foi utilizado modelos estatísticos, identificado os dados necessários para tomadas de decisão, como mostra na figura 4.2

Nesta tela, os usuários podem acessar informações detalhadas sobre a dotação orçamentária atualizada, incluindo todas as fases da despesa: empenho, liquidação e pagamento. Além disso, são apresentadas as contas gerenciais do orçamento, como o crédito disponível, indicando os recursos ainda disponíveis para utilização, e o crédito indisponível (bloqueado), que representa os recursos que não podem ser utilizados por restrições orçamentárias.

Também são destacados os saldos a liquidar dos empenhos, fornecendo uma visão clara do comprometimento dos recursos e das obrigações financeiras pendentes das unidades da UNB. Essa tela proporciona uma análise abrangente e detalhada da execução financeira das

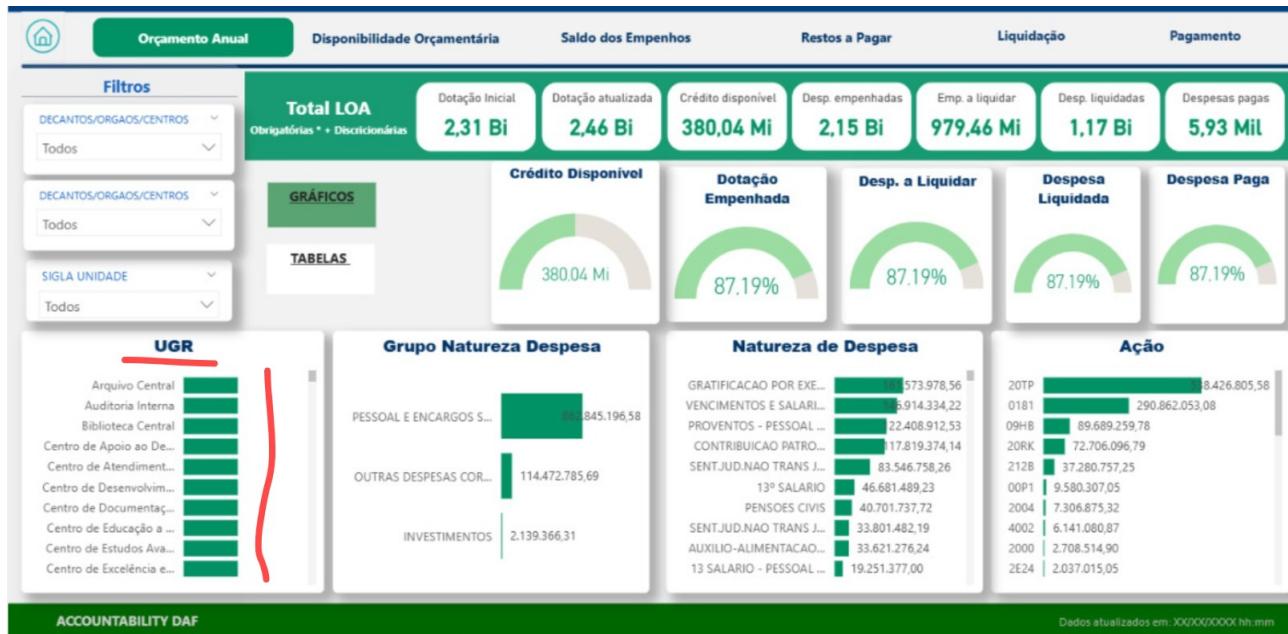


Figura 4.2: Painel de resultados de restos a pagar

Fonte: Painel de Resultados - BI

unidades, auxiliando na tomada de decisões estratégicas e no monitoramento eficaz dos recursos orçamentários.

#### 4.1 ANÁLISE COMPARATIVA DOS MODELOS

Nesta seção, foi comparado o desempenho de três abordagens: os modelos estatísticos clássicos (ARIMA/SARIMA), os baselines temporais (Naïve e Seasonal Naïve) e o apoio analítico de LLMs. Conforme discutido na literatura [34], os modelos SARIMA são particularmente adequados para séries com sazonalidade anual, como as despesas governamentais, enquanto baselines são importantes para avaliar se a sofisticação do modelo de fato gera ganhos.

Durante os testes, foi observado que, ao se acionar um prompt para o modelo GPT solicitando predição com base em aspectos como estacionalidade e sazonalidade, o modelo frequentemente recomendava o uso da função ExponentialSmoothing da biblioteca statsmodels, especificamente com o modelo Holt-Winters, conforme exemplificado na Figura 4.3

O modelo Holt-Winters, embora seja uma das técnicas de previsão mais populares para séries temporais, comumente aplicado em problemas como detecção de anomalias e previsão meteorológica, demonstrou limitações para este estudo. Esse modelo é uma extensão do modelo de Holt, desenvolvido por Winter e, sua lógica baseada em suavização exponencial tende a amortecer picos de gastos, o que compromete a acurácia das previsões em contextos onde essas

```

# Criando a série temporal
dates = pd.date_range(start="2021-01-01", periods=36, freq='MS')
values = [
    0.00, 0.00, 0.00, 0.00, 49126.79, 700.15, 295968.75, 201518.40, 11762.15, 713815.75, 269079.71, 308341.91,
    0.00, 0.00, 10281.93, 10531.00, 207287.00, 493906.01, 99067.86, 279138.27, 336258.60, 511359.65, 293863.37, 355836.01,
    0.00, 0.00, 111999.58, 547936.24, 97344.27, 341436.87, 322296.96, 336232.90, 163373.13, 574823.29, 601538.49, 83515.88
]

# Criando um DataFrame
df = pd.DataFrame({'Date': dates, 'Value': values})
df.set_index('Date', inplace=True)

# Aplicando Holt-Winters para previsão
model = ExponentialSmoothing(df['Value'], trend='add', seasonal='add', seasonal_periods=12)
fit = model.fit()
forecast = fit.forecast(steps=12)

# Exibindo a previsão
forecast_df = forecast.to_frame(name="Forecast")
import ace_tools as tools
tools.display_dataframe_to_user(name="Previsão para 2024", dataframe=forecast_df)

```

Figura 4.3: Modelo Holt-Winters

Fonte: Pesquisa do autor

variações são relevantes. Para contornar essa limitação, foi incluída no prompt uma instrução explícita: "..., porém sem usar nenhum processo de suavização, isto é, mantendo os picos de valores de gastos". Com esses ajustes, foram realizadas previsões de despesas para o ano de 2024, posteriormente comparadas com os valores reais observados.

### Modelos e *baselines* avaliados

Foram comparados três blocos de abordagens:

1. **Modelos estatísticos clássicos** (ARIMA/SARIMA), robustos para séries com dependência temporal e sazonalidade.
2. **Baselines** temporais, incluindo *Naïve* ( $\hat{y}_t = y_{t-1}$ ) e *Seasonal Naïve* ( $\hat{y}_t = y_{t-12}$ ), usados como linhas de base [18].
3. **LLMs como apoio analítico**, empregados para sugerir parâmetros, gerar explicações e identificar regimes. A literatura aponta limitações quando usados como preditores diretos de séries numéricas [42].

#### 4.1.1 Protocolo de validação e estratificações

A validação dos modelos seguiu o protocolo de **rolling-origin**, em que a série é treinada até o tempo  $t$  e projetada para  $t+1$ , avançando a janela ao longo do horizonte. Esse método é recomendado por Hyndman e Athanasopoulos [18] para contextos em que as séries são atualizadas continuamente. As métricas avaliadas foram MAE, RMSE, MAPE, sMAPE e MASE, cada uma oferecendo diferentes perspectivas de erro.

## Principais resultados comparativos

A Tabela 4.1 sintetiza os resultados comparativos entre SARIMA e *Seasonal Naïve*, em dois estratos representativos: **DSP/UE com séries longas e UR/DET com alta esparsidade**.

Observa-se que, em **DSP/UE**, o SARIMA reduziu o MAPE de 42,0% (baseline) para 36,3%, além de apresentar menor RMSE (910k contra 782k). Isso demonstra que a modelagem capturou com mais eficiência as sazonalidades anuais. Já em **UR/DET**, a vantagem é menos expressiva: embora o RMSE do SARIMA (9,5k) seja ligeiramente menor que o da baseline (10,8k), os valores de sMAPE permanecem elevados (acima de 100%), indicando grande dificuldade de previsão em séries muito esparsas.

Tabela 4.1: Comparativo agregado por estrato (valores medianos).

Estrato	Modelo	MAE	RMSE	MAPE	sMAPE	MASE
DSP/UE, > 36m	SARIMA	52.9k	782k	36.3%	47.2%	1.04
DSP/UE, > 36m	S.Naïve	65.0k	910k	42.0%	55.0%	1.20
UR/DET, alta esparsidade	SARIMA	6.4k	9.5k	—	112.7%	1.86
UR/DET, alta esparsidade	S.Naïve	7.2k	10.8k	—	130.0%	2.10

Esses resultados corroboram a literatura: quanto mais longa e menos esparsa a série, maior a vantagem de modelos estatísticos avançados sobre previsões ingênuas.

## 4.2 AVALIAÇÃO DE PREVISÕES PARA DESPESAS TÍPICAS

As despesas típicas exibem sazonalidade estável, como contratos de custeio educacional. As Figuras 4.4 e 4.5 mostram a série da UE 154040, tanto em horizonte longo quanto anualizado. Nota-se que o modelo SARIMA conseguiu capturar os padrões recorrentes, com pequenas discrepâncias em meses de maior execução.

UE: 154040, DET: 33901414  
Comparação de Gastos (na predição)

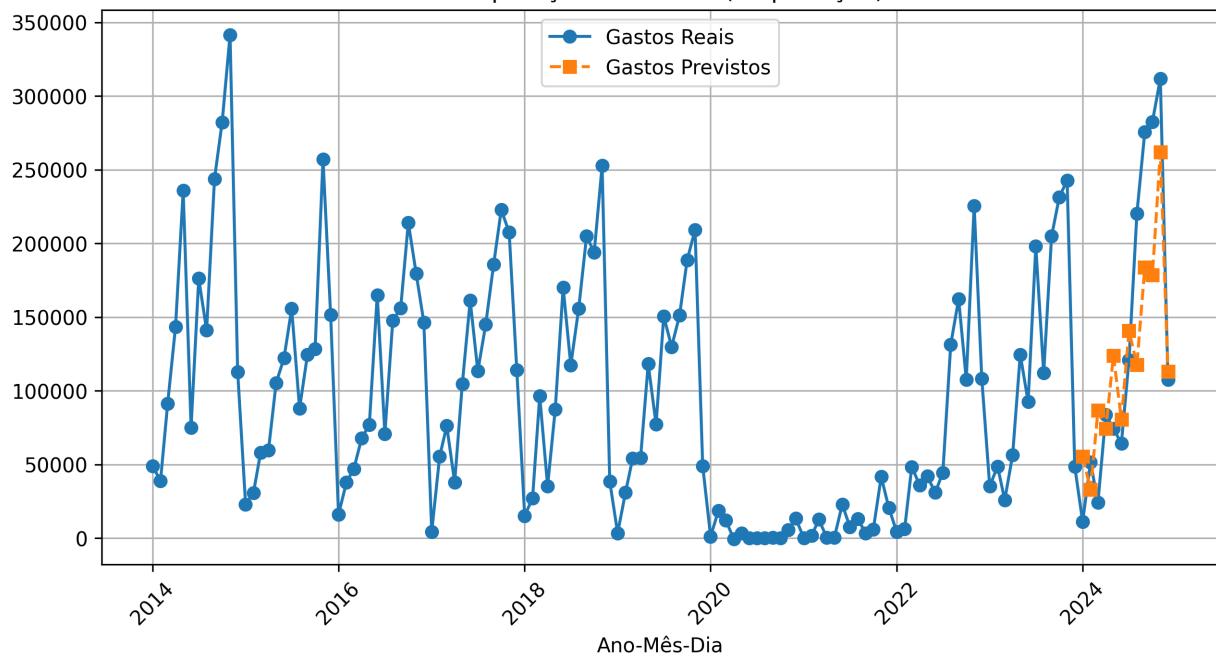


Figura 4.4: UE 154040, DET 33901414 longo histórico (2014–2024)

Fonte: Resultados da Pesquisa

A Figura 4.4 apresenta os resultados da predição para uma despesa típica da universidade, em que com os picos anuais; os pontos laranja mostram a faixa prevista no fim da série, onde nos períodos de férias escolares há uma redução de gastos e no período letivo há um crescimento da despesa. É possível observar que o modelo obteve uma previsão correta, diferenciando os períodos de férias escolares e períodos letivos, gerando previsões consideráveis da despesa ao longo do ano.

Para as despesas de natureza discricionária, sua demanda é intempestiva junto a diversos anos de análise, provocando uma previsão que pode ficar inadequada, não em valor, mas em momento junto aos meses, a projeção (tracejado laranja) acompanha a tendência de alta com *lags* pontuais. Esse comportamento foi claramente identificado nos resultados, conforme Figura 4.5. Além disso, foram identificadas ocorrências de deslocamento (entre o mês 1 e o mês 7). Isto ocorre dada a natureza específica da Unidade Executora específica, que tende a utilizar seus recursos associados à abertura de períodos letivos de ensino. Dessa forma, a "natureza" da unidade, tal como a citada, pode influir em aspectos "negativos" na capacidade de previsão de uso de recursos ("gastos"). Esse tipo de deslocamento impede uma simples verificação de erro por MSRE (Mean Square Root Error).

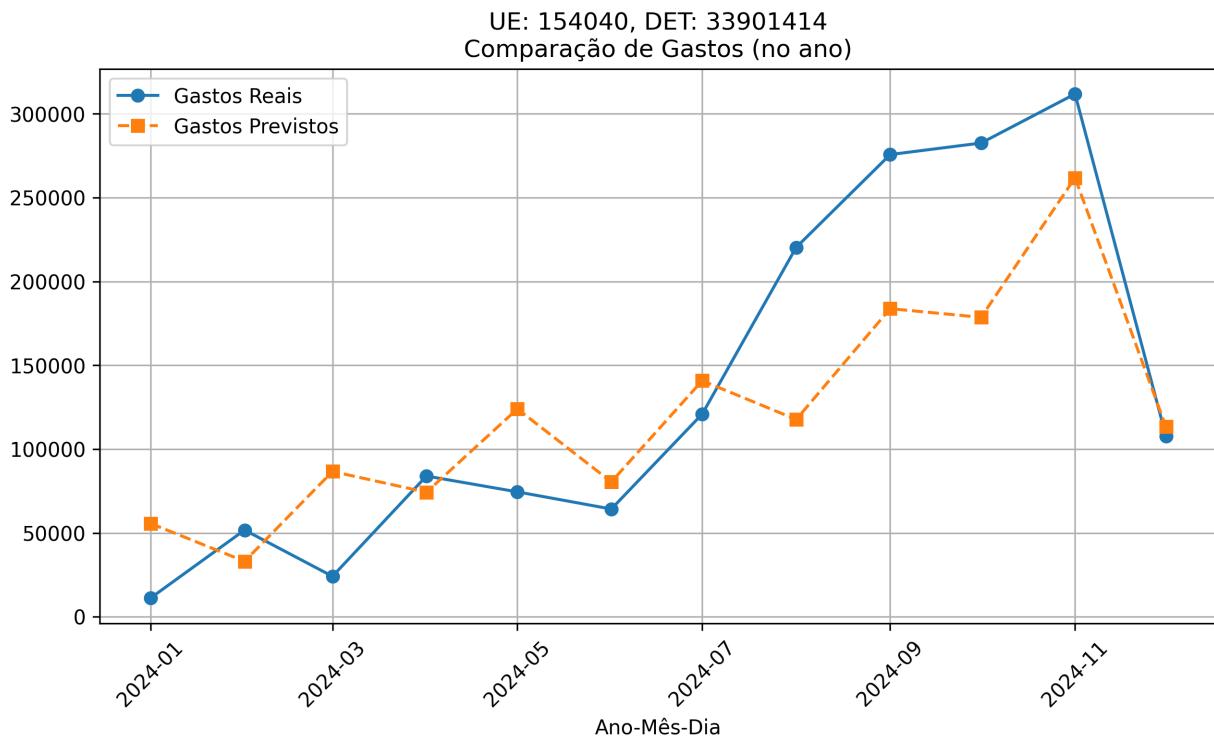


Figura 4.5: UE 154040, DET 33901414 recorte de 2024: Painel Geral de Resultados Preditiva Mês a Mês  
Fonte: Resultados da Pesquisa

Na Tabela 4.2, consolidamos os indicadores para DSP/UE e DET/UE. O SARIMA apresentou MAPE de 36,3% em DSP/UE, valor significativamente menor que os observados em granularidades mais finas. Em DET/UE, o MAPE subiu para 79,1%, reflexo da maior variabilidade, mas o RMSE caiu para 59k, coerente com valores absolutos menores de gasto.

Tabela 4.2: Indicadores — despesas típicas (valores medianos).

Estrato	MAPE	sMAPE	RMSE
DSP/UE, > 36m	36.3%	47.2%	782k
DET/UE, > 36m	79.1%	58.7%	59k

Esses achados confirmam que previsões em nível agregado são mais úteis para planejamento macro, enquanto granularidades finas funcionam melhor para análise local e auditoria.

### 4.3 AVALIAÇÃO DE PREVISÕES PARA DESPESAS DISCRICIONÁRIAS

Na Tabela 4.3, vemos que o sMAPE em UR/DET ultrapassa 110%, enquanto o MASE é 1.86, indicando que até previsões ingênuas podem ser competitivas em tais cenários. Em UR/DSP, os valores melhoraram um pouco (sMAPE de 95,4%), mas ainda indicam baixa previsibilidade.

Portanto, as previsões em despesas discricionárias devem ser vistas como linha de base para

Tabela 4.3: Indicadores — despesas discricionárias (valores medianos).

Estrato	MASE	sMAPE	RMSE
UR/DET, alta esparsidade	1.86	112.7%	9.5k
UR/DSP, alta esparsidade	1.32	95.4%	2.9k

monitoramento, e não como valores determinísticos.

As despesas discricionárias evidenciam um padrão temporal marcado por elevada volatilidade, caracterizado por picos abruptos e intervalos prolongados sem execução, o que denota comportamento não estacionário e de difícil modelagem. A Figura 4.6 ilustra esse padrão, mostrando que o modelo SARIMA apresentou limitações na previsão de valores extremos, possivelmente em função da natureza intermitente e da ocorrência de choques idiossincráticos que comprometem sua capacidade de capturar dinâmicas de curto prazo. Esses resultados sugerem a pertinência da adoção de abordagens híbridas, combinando técnicas econometrísticas tradicionais com métodos de aprendizado de máquina, de modo a aprimorar a detecção de não linearidades e a previsão de eventos extremos.

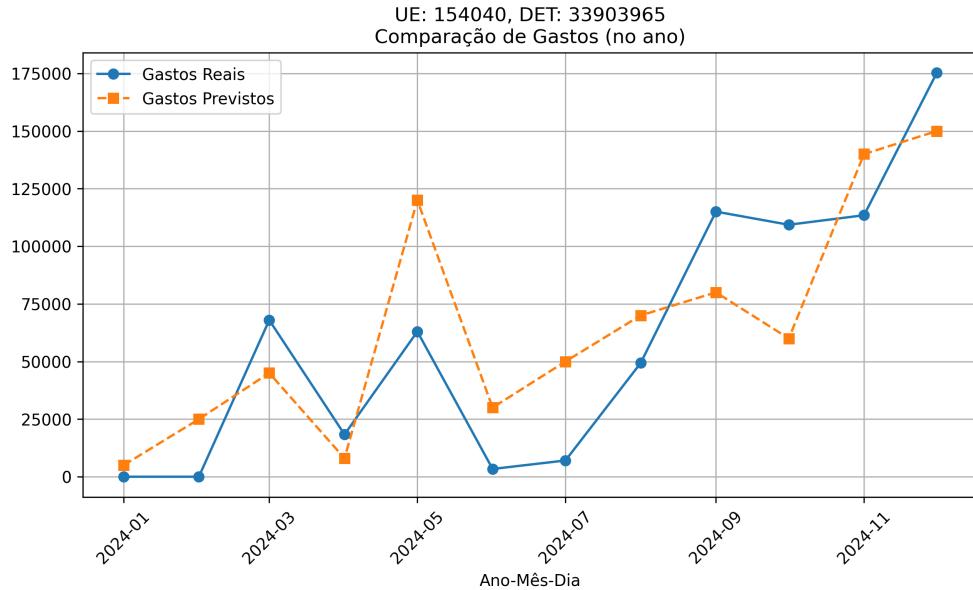


Figura 4.6: Despesas discricionárias modelo SARIMA

Fonte: Resultados da Pesquisa

A Figura 4.7, No âmbito da UR+DSP, verifica-se que o processo de agregação exerce um efeito mitigador sobre o ruído, promovendo uma suavização parcial dos sinais. Todavia, a presença de picos residuais ainda compromete a acurácia das estimativas, indicando a necessidade de técnicas adicionais de filtragem ou refinamento para aprimorar a qualidade dos resultados.

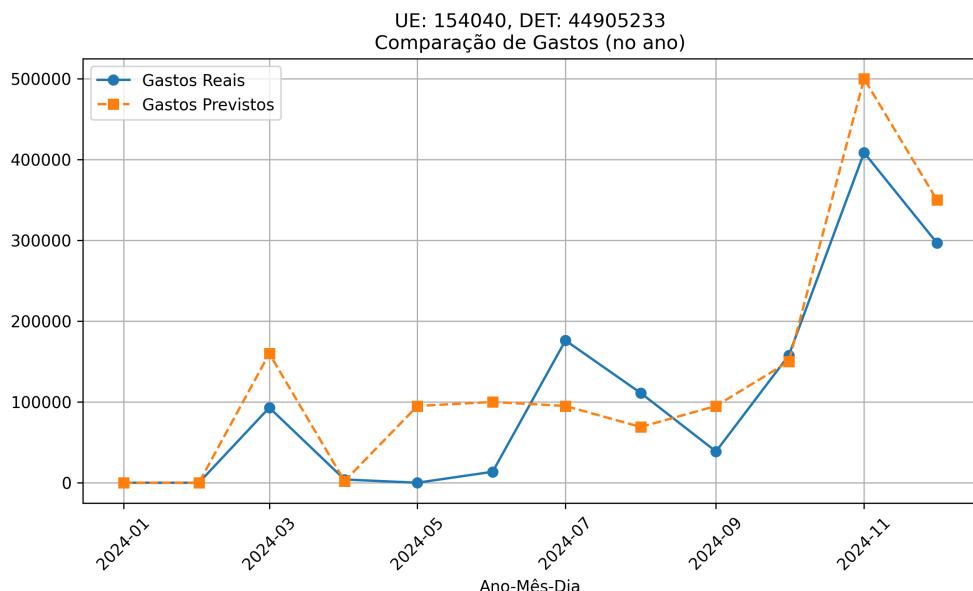


Figura 4.7: Agregação Suaviza

Fonte: Resultados da Pesquisa

#### 4.4 OCORRÊNCIAS DE DESLOCAMENTO TEMPORAL E SUAS IMPLICAÇÕES

Algumas séries apresentaram **deslocamento temporal**, em que o pico previsto ocorre em meses próximos, mas não exatamente no mês real. Isso é visível em Figuras como 4.8, onde há sobreposição parcial entre valores reais e previstos. As causas incluem registros de RAP, execução concentrada no fim do ano e sazonalidade imperfeita.

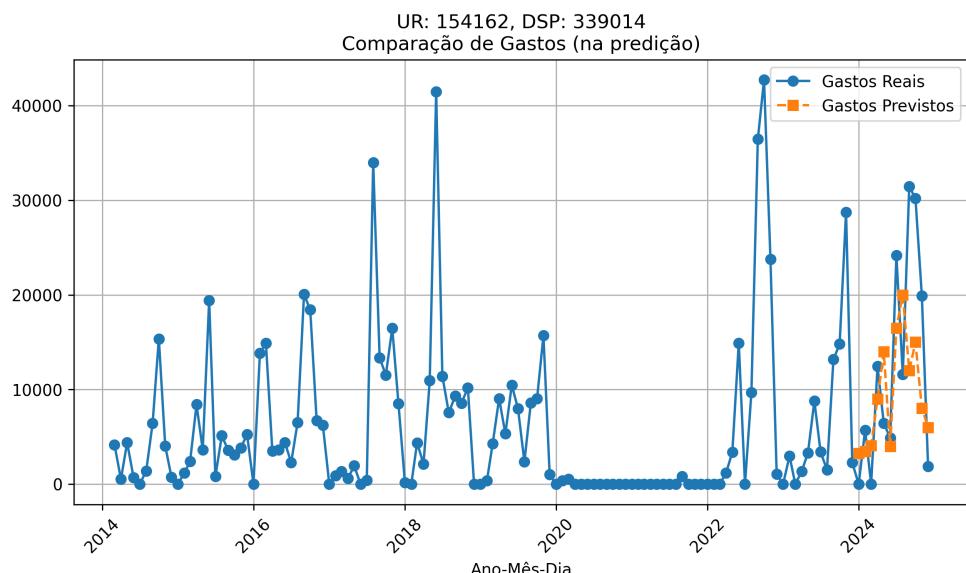


Figura 4.8: Deslocamento Temporal de RAP

Fonte: Resultados da Pesquisa

Esse fenômeno tem implicações práticas: no curto prazo, pode gerar sobre ou subalocação de recursos; no médio prazo, os totais anuais permanecem relativamente bem estimados. Mitigações incluem redistribuição de RAP, uso de termos de Fourier para sazonalidades móveis e relatórios trimestrais, que suavizam deslocamentos intra-trimestre. **Limitações e Desafios Identificados**

A análise revelou limitações tanto nos dados quanto na modelagem:

- **Dados:** séries curtas e esparsas reduzem robustez, e RAP distorce registros.
- **Modelagem:** ARIMA/SARIMA subestimam picos, enquanto LLMs suavizam em excesso.
- **Operação:** latência de 10–15s por série é viável, mas requer orquestração em lote para escala massiva.

Caminhos futuros incluem explorar ARIMAX com regressores externos (ex.: calendário acadêmico), modelagem hierárquica e detecção de anomalias em resíduos.

## 4.5 SÍNTESE QUANTITATIVA POR GRANULARIDADE

Os boxplots das Figuras 4.9 e 4.10 resumem a distribuição de erros por estrato. Em MAPE (Fig. 4.9), DSP/UE apresenta menores medianas e dispersão, enquanto UR/DET mostra grande variabilidade e outliers. Em RMSE (Fig. 4.10), o padrão se repete: níveis agregados concentram erros menores, enquanto granularidades finas apresentam caudas longas. DSP/UE apresenta menor erro percentual e maior estabilidade, enquanto UR/DET evidencia variabilidade extrema.

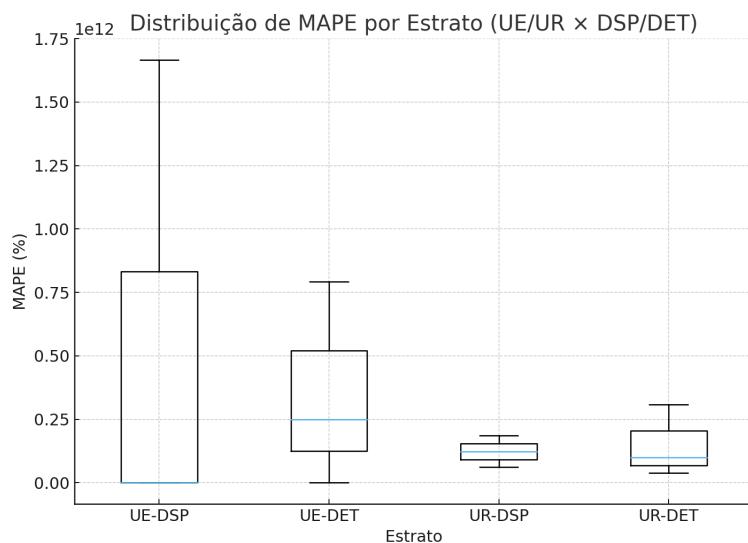


Figura 4.9: Distribuição do MAPE (%) por estrato (UE/UR x DSP/DET)

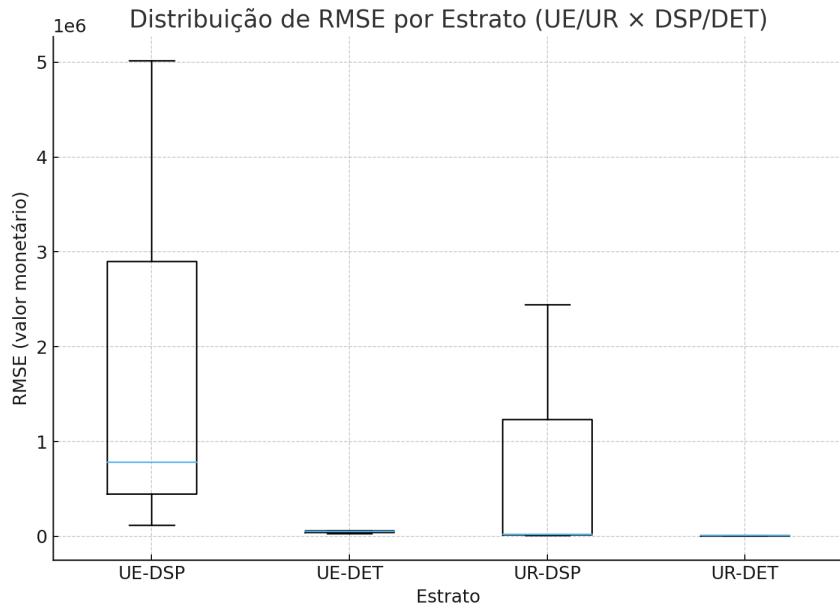


Figura 4.10: Distribuição do RMSE por estrato.

Essas evidências visuais confirmam os resultados numéricos das Tabelas 4.1, 4.2 e 4.3: previsões em níveis agregados são mais acuradas e estáveis, enquanto granularidades finas introduzem alta incerteza. O RMSE absoluto é maior em DSP/UE devido ao volume financeiro, mas proporcionalmente apresenta menor dispersão que nas granularidades finas.

## SÍNTESE DO CAPÍTULO

O Capítulo 4 consolidou a avaliação da arquitetura *ACCOUNTABILITY* em múltiplas dimensões. Os resultados mostram que:

1. Em **despesas típicas**, SARIMA superou os baselines, com previsões úteis para planejamento macro.
2. Em **despesas discricionárias**, as previsões funcionaram como linha de base, mas exigem supervisão analítica.
3. O **tratamento de RAP** e a análise de **deslocamentos temporais** são cruciais para interpretação correta.
4. Os **boxplots** confirmam quantitativamente as diferenças de desempenho por granularidade.

Assim, este capítulo demonstra a viabilidade da arquitetura proposta e seus limites práticos, reforçando a necessidade de uso combinado de granularidades: previsões agregadas para planejamento macro e séries detalhadas para auditoria e *accountability*.

# 5 CONCLUSÃO

Este capítulo apresenta as considerações finais da pesquisa, sintetizando os principais achados e implicações do estudo. São discutidas as conclusões gerais, as contribuições práticas e teóricas, as limitações identificadas e as recomendações para trabalhos futuros.

## 5.1 CONCLUSÃO DA PESQUISA

Os resultados obtidos confirmam a capacidade da arquitetura em fornecer previsões valiosas. Para despesas de natureza típica e em níveis agregados, os modelos SARIMA demonstraram alta acurácia, superando baselines ingênuas e oferecendo subsídios concretos para o planejamento orçamentário estratégico. Essa performance valida a aplicação da inteligência artificial como um instrumento poderoso para antecipar cenários e otimizar a alocação de recursos em grande escala. Embora a previsão de despesas discricionárias e em granularidades mais finas ainda apresente desafios inerentes à alta volatilidade e esparsidade dos dados, mesmo nesses contextos, a arquitetura oferece uma linha de base essencial para o monitoramento contínuo e a detecção precoce de anomalias, reforçando a capacidade de auditoria e controle.

As contribuições deste trabalho são duplas e complementares. No âmbito acadêmico, ele preenche uma lacuna metodológica crucial ao integrar inteligência artificial, estatística e governança de dados em uma arquitetura sistêmica para o setor público, oferecendo evidências empíricas valiosas sobre a aplicação de SARIMA e o papel emergente dos LLMs como apoio analítico. No plano prático, a "ACCOUNTABILITY" provou ser uma prova de conceito funcional, materializada em dashboards interativos e APIs, que capacita gestores públicos a visualizar, analisar e prever gastos, promovendo maior accountability e transparência no uso dos recursos.

Dessa forma, a pesquisa alcançou seus objetivos ao fornecer uma solução tecnológica inovadora que alia interoperabilidade, segurança da informação, análise exploratória e previsão estatística no contexto da gestão pública.

É fundamental reconhecer as limitações intrínsecas ao uso de dados históricos por vezes curtos ou inconsistentes e a complexidade de despesas discricionárias, que demandam cautela na interpretação dos resultados. No entanto, estas limitações não diminuem o mérito da proposta, mas sim apontam para direções frutíferas para investigações futuras. A exploração de modelos multivariados, o aprimoramento da escalabilidade em ambientes de big data, o desenvolvimento de ferramentas avançadas de detecção de anomalias e aprofundamento na integração de LLMs, bem como estudos de impacto em diferentes contextos governamentais, prometem consolidar a "ACCOUNTABILITY" como uma solução de referência.

## 5.2 CONTRIBUIÇÕES DO ESTUDO

Este trabalho apresenta contribuições relevantes tanto no campo acadêmico quanto prático:

### 5.2.1 Contribuições acadêmicas

- Proposição de uma **arquitetura integrada** que combina coleta, pré-processamento, análise exploratória e previsão de gastos, alinhada à literatura em governança de dados e séries temporais.
- Evidência empírica sobre a aplicação de **modelos SARIMA** em dados de execução orçamentária brasileira, destacando vantagens e limitações em diferentes granularidades.
- Discussão sobre o papel emergente de **LLMs** como ferramentas de apoio explicativo em análises financeiras, ampliando a agenda de pesquisa em ciência de dados aplicada ao setor público.

### 5.2.2 Contribuições práticas

- Desenvolvimento de um **prova de conceito funcional** (dashboard e APIs) que pode ser utilizado por órgãos públicos para monitoramento de execução orçamentária.
- Apoio à **accountability** e à transparência governamental, oferecendo instrumentos que podem ser incorporados por controladorias, tribunais de contas e universidades.
- Fornecimento de evidências para **gestores públicos** sobre quais níveis de granularidade são mais adequados para diferentes finalidades: planejamento estratégico (DSP/UE) ou auditoria e fiscalização (UR/DET).

## 5.3 RECOMENDAÇÕES E TRABALHOS FUTUROS

Com base nas limitações e nos resultados obtidos, recomenda-se a continuidade da pesquisa em quatro frentes principais:

1. **Aprimoramento da modelagem preditiva:** explorar modelos multivariados (ARIMAX, Prophet, redes neurais recorrentes), considerando variáveis explicativas adicionais e efeitos externos (ex.: PIB, inflação, calendário fiscal).
2. **Escalabilidade da arquitetura:** expandir a solução para ambientes de *big data*, utilizando ferramentas distribuídas e pipelines de integração contínua.
3. **Detecção de anomalias:** integrar técnicas específicas para identificar outliers e padrões suspeitos em tempo real, apoiando auditorias automáticas.

4. **Avaliação de impacto:** conduzir estudos de caso em órgãos governamentais, medindo o efeito do uso da arquitetura na tomada de decisão, na transparência e no controle social.

Essas direções podem consolidar a arquitetura *ACCOUNTABILITY* como uma solução de referência para análise de qualidade de gastos públicos, ampliando sua relevância acadêmica e prática.

# REFERÊNCIAS BIBLIOGRÁFICAS

- 1 VIGNOLI, F. H. *PLANEJAMENTO E ORÇAMENTO PÚBLICO ED. 1.* [S.I.]: Editora FGV, 2015.
- 2 ABREU, W. M. d.; GOMES, R. C. O orçamento público brasileiro e a perspectiva emancipatória: existem evidências empíricas que sustentam esta aproximação? *Revista de Administração Pública*, SciELO Brasil, v. 47, p. 515–540, 2013.
- 3 MATIAS-PEREIRA, J. Defesa da concorrência e regulação econômica no brasil. *RAM. Revista de Administração Mackenzie*, SciELO Brasil, v. 5, p. 35–55, 2022.
- 4 ALVES, M. L. F. *Qualidade dos gastos públicos em saúde e educação: uma análise sistemática da literatura.* Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2023.
- 5 DIAS, F. M. d. S. A.; OLIVEIRA, V. B. S. D.; SARAIVA, T. A. N.; NASCIMENTO, J. C. H. B. D. A qualidade do gasto público no brasil: Uma revisão narrativa sobre desafios, avanços e perspectivas futuras. *Revista Multidisciplinar do Nordeste Mineiro*, v. 14, n. 1, p. 1–21, 2025.
- 6 SOARES, J. R.; RAUPP, F. M.; TEZZA, R. Qualidade do gasto público nos municípios de santa catarina. *Contabilidade Vista & Revista*, v. 32, n. 3, p. 165–194, 2021.
- 7 MARTIN, L. M. Ética em pesquisa: uma perspectiva brasileira. *Mundo saúde (Impr.)*, p. 85–100, 2002.
- 8 PEREIRA, G. G.; MARTINS, H. A.; SANTOS, N. M. d. *Automatização de reconhecimento de notas fiscais para gastos públicos utilizando OCR e aprendizado de máquina.* [S.I.]: Universidade Presbiteriana Mackenzie, 2023.
- 9 ANDRADE, B. H. S.; SERRANO, A. L. M.; BASTOS, R. F. S.; FRANCO, V. R. Eficiência do gasto público no âmbito da saúde: uma análise do desempenho das capitais brasileiras. *Revista Paranaense de Desenvolvimento*, Instituto Paranaense de Desenvolvimento Econômico e Social, v. 38, n. 132, p. 163–179, 2017.
- 10 MALENA, D. C. d. C. Q.; OLIVEIRA, J. H. d.; CASTRO, D. T. et al. *Análise situacional da eficiência do gasto público com despesas administrativas no Governo do Estado do Tocantins.* 2013.
- 11 OSBORNE, D.; HUTCHINSON, P. *The price of government: Getting the results we need in an age of permanent fiscal crisis.* [S.I.]: Basic Books (AZ), 2006.
- 12 SHMUELI, G.; KOPPIUS, O. R. Predictive analytics in information systems research. *MIS quarterly*, JSTOR, p. 553–572, 2011.
- 13 CAVALCANTE, P.; LARIÚ, C. I. *Orçamento e desempenho municipal: uma análise comparada da qualidade do gasto público nas políticas sociais.* [S.I.]: Escola nacional de administração pública (Enap), 2012.
- 14 GIL, A. C. *Métodos e técnicas de pesquisa social.* [S.I.]: 6. ed. Editora Atlas SA, 2008.
- 15 SILVA, K. A.; OLIVEIRA, C. A. R. d. Método científico: o conhecimento como uma unidade em que todos os saberes estão conectados. *Revista Educação, Gestão e Sociedade, Jandira*, v. 12, n. 25, p. 1–5, 2017.
- 16 YIN, R. K. *Estudo de Caso-: Planejamento e métodos.* [S.I.]: Bookman editora, 2015.

- 17 BUTTOW, C. V.; WEERTS, S. Managing public sector data: National challenges in the context of the european union's new data governance models. *Information Polity*, SAGE Publications Sage UK: London, England, v. 29, n. 3, p. 261–276, 2024.
- 18 HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.I.]: OTexts, 2018.
- 19 CHASTON, I. *Strategy for sustainable competitive advantage: surviving declining demand and China's global development*. [S.I.]: Routledge, 2012.
- 20 INMON, J. James inmon art399 portfolio. 2020.
- 21 CARMO, J. B. do; GONÇALVES, J. de S. Controle de custos como instrumento de avaliação da eficiência dos gastos públicos. *Revista Multidisciplinar do Sertão*, v. 5, n. 1, p. 12–19, 2023.
- 22 MESQUITA, A. M. de; WANDER, A. E. et al. Avaliação da qualidade dos gastos públicos em educação e saúde nos municípios mato-grossenses, brasil. *Revista Capital Científico-Volume*, v. 19, n. 2, 2021.
- 23 AFONSO, A.; SCHUKNECHT, L.; TANZI, V. Public sector efficiency: an international comparison. *Public choice*, Springer, v. 123, n. 3, p. 321–347, 2005.
- 24 ROCHA, F.; GIUBERTI, A. C. Composição do gasto público e crescimento econômico: uma avaliação macroeconômica da qualidade dos gastos dos estados brasileiros. *Economia Aplicada*, SciELO Brasil, v. 11, p. 463–485, 2007.
- 25 SOARES, J. R.; RAUPP, F. M.; TEZZA, R. Análise do índice de qualidade do gasto público nos municípios de santa catarina/analysis of the quality index of public expenditure in the municipalities of santa catarina. *Revista FSA (Centro Universitário Santo Agostinho)*, v. 16, n. 4, p. 110–137, 2019.
- 26 CUNHA, P. R. da; LEITE, M.; MORAS, V. R. Efeito da troca da firma de auditoria no gerenciamento de resultados das companhias abertas brasileiras. *Contabilidad y Negocios: Revista del Departamento Académico de Ciencias Administrativas*, Pontificia Universidad Católica del Perú, v. 14, n. 28, p. 70–87, 2019.
- 27 ALONSO, M. Custos no serviço público. *Revista do Serviço Público - RSP (Especial 85 Anos)*, Escola Nacional de Administração Pública (Enap), <https://doi.org/10.21874/rsp.v73.ib.8726>, v. 50, p. 127–152, 2022.
- 28 CAVALCANTE, S.; ELALI, G. A. *Temas básicos em psicologia ambiental*. [S.I.]: Editora Vozes Limitada, 2017.
- 29 MALENA, D. C. d. C. Q.; OLIVEIRA, J. H. d.; CASTRO, D. T. et al. Análise situacional da eficiência do gasto público com despesas administrativas no governo do estado do tocantins. *VI Congresso de Gestão Pública (CONSAD)*, 2013.
- 30 MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, p. 32, 2003.
- 31 PEREIRA, G. G.; MARTINS, H. A.; SANTOS, N. M. d. Automatização de reconhecimento de notas fiscais para gastos públicos utilizando ocr e aprendizado de máquina. *Universidade Presbiteriana Mackenzie*, Universidade Presbiteriana Mackenzie, 2023. Disponível em: <<https://adelpha-api.mackenzie.br/server/api/core/bitstreams/ab38f3c3-c28d-470e-87f1-7ffd0b23224d/content>>.

- 32 SANTOS, R.; ARAÚJO, R.; REGO, P.; FILHO, J. M.; FILHO, J. S.; NETO, J. C.; FREITAS, N.; RODRIGUES, E. Arquitetura de tempo real e modelo de aprendizado de máquina para detecção de fraudes de cartão de crédito. In: *Anais do XXIII Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais*. Porto Alegre, RS, Brasil: SBC, 2023. p. 265–278. ISSN 0000-0000. Disponível em: <<https://sol.sbc.org.br/index.php/sbseg/article/view/27212>>.
- 33 OKAMURA, A. B.; ZANELLO, C. R. d. P.; GONÇALVES, W. T.; SBRUZZI, E. F. Análise e projeção de séries temporais de despesas da agência brasileira de promoção de exportação e investimentos. In: EDITORA CIENTÍFICA DIGITAL. *PROJETOS DE PESQUISA EM DATA SCIENCE: ESTUDO DE CASO SOBRE A APEXBRASIL-INSTITUTO TECNOLÓGICO DE AERONÁUTICA (ITA), TURMA APEXBRASIL*. [S.I.], 2024. v. 1, p. 40–58.
- 34 SHUMWAY, R. H.; STOFFER, D. S. Arima models. In: *Time series analysis and its applications: with R examples*. [S.I.]: Springer, 2017. p. 75–163.
- 35 QUEIROZ, Z. C. O uso de modelos de séries temporais para previsão orçamentária: um estudo na área da tecnologia da informação. *Revista de Administração, Contabilidade e Economia da Fundace*, v. 11, n. 3, 2020.
- 36 HAN, J.; LU, J.; XU, Y.; YOU, J.; WU, B. Intelligent practices of large language models in digital government services. *IEEE Access*, v. 12, p. 8633–8640, 2024. Disponível em: <<https://doi.org/10.1109/ACCESS.2024.3349969>>.
- 37 KADDOUR, J.; HARRIS, J.; MOZES, M.; BRADLEY, H.; RAILEANU, R.; MCHARDY, R. Challenges and applications of large language models. *CoRR*, abs/2307.10169, 2023. Disponível em: <<https://doi.org/10.48550/arXiv.2307.10169>>.
- 38 BERNHARD, P. V. Estudo comparativo de large language models aplicados à classificação de documentos de prestação de contas públicas. *Ciência da Computação da Universidade Federal do Maranhão*, Universidade Federal do Maranhão, 2023.
- 39 RUAN, Q.; KUZNETSOV, I.; GUREVYCH, I. Are large language models good classifiers? A study on edit intent classification in scientific document revisions. In: AL-ONAIZAN, Y.; BANSAL, M.; CHEN, Y. (Ed.). *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing, EMNLP 2024, Miami, FL, USA, November 12-16, 2024*. Association for Computational Linguistics, 2024. p. 15049–15067. Disponível em: <<https://doi.org/10.18653/v1/2024.emnlp-main.839>>.
- 40 KHURANA, D.; KOLI, A.; KHATTER, K.; SINGH, S. Natural language processing: state of the art, current trends and challenges. *Multim. Tools Appl.*, v. 82, n. 3, p. 3713–3744, 2023. Disponível em: <<https://doi.org/10.1007/s11042-022-13428-4>>.
- 41 HAGOS, D. H.; BATTLE, R.; RAWAT, D. B. Recent advances in generative AI and large language models: Current status, challenges, and perspectives. *IEEE Trans. Artif. Intell.*, v. 5, n. 12, p. 5873–5893, 2024. Disponível em: <<https://doi.org/10.1109/TAI.2024.3444742>>.
- 42 BELARMINO, M.; COELHO, R.; LOTUFO, R.; PEREIRA, J. Aplicação de large language models na análise e síntese de documentos jurídicos: Uma revisão de literatura. In: *Anais do XIII Latin American Symposium on Digital Government*. Porto Alegre, RS, Brasil: SBC, 2025. p. 193–202. ISSN 2763-8723. Disponível em: <<https://sol.sbc.org.br/index.php/wcge/article/view/36331>>.
- 43 RELLA, B. P. R. Comparative analysis of data lakes and data warehouses for machine learning. *International Journal for Multidisciplinary Research*, v. 7, n. 2, 2025.
- 44 JAMEEL, K.; ADIL, A.; BAHJAT, M. Analyses the performance of data warehouse architecture types. *Journal of Soft Computing and Data Mining*, v. 3, n. 1, p. 45–57, 2022.

- 45 JI, M.; GU, X.; GUO, Q.; DING, X. Research on government data governance in the era of large language model. In: *9th IEEE International Conference on Data Science in Cyberspace, DSC 2024, Jinan, China, August 23-26, 2024*. IEEE, 2024. p. 668–671. Disponível em: <<https://doi.org/10.1109/DSC63484.2024.00099>>.

# APÊNDICES

## .1 PSEUDOCODIGO: BI ORCAMENTARIO – BLUEPRINT END-TO-END

```
1
2 // =====
3 // BI ORCAMENTARIO -- Blueprint de Pseudocodigo End-to-End
4 // =====
5
6 // ----- 0) PARAMETROS E METADADOS -----
7 CONST AMBIENTE = "PROD"
8 CONST DATA_ATUAL = TODAY()
9 CONST ORGAO_PADRAO = "Administracao Publica Federal"
10 CONST FONTE_DADOS = ["SIAFI", "PortalTransparencia", "MPO", "SIGA/UG",
11                         "CNEST/IBGE (auxiliares)"]
12 CONST ZONAS = { RAW:"dl_raw", STG:"dl_stg", CURATED:"dl_curated", DW:"dw" }
13 CONST ALERTAS = {EMAIL:"orcamento-bi@org.gov.br", TEAMS:
14                         "canal-bi-orcamento" }
15
16 STRUCT JanelaCarga { inicio: DATE, fim: DATE }
17 VAR janela_execucao = JanelaCarga(
18     inicio = PRIMEIRO_DIA_DO_ANO(DATA_ATUAL),
19     fim     = DATA_ATUAL
20 )
21
22 // ----- 1) ORQUESTRACAO -----
23 PROCEDURE PIPELINE_BI_ORCAMENTARIO(janela_execucao):
24     TRY
25         LOG("Inicio pipeline", DATA_ATUAL, AMBIENTE)
26         dados_raw = INGESTAO_MULTIFONTE(janela_execucao)
27         dados_stg = TRATAMENTO_PADRONIZACAO(dados_raw)
28         ASSERT_QUALIDADE(dados_stg)
29         CONCILIAR_TOTALIZADORES(dados_stg)
30         dados_curated = APPLICAR_REGRAS_NEGOCIO(dados_stg)
31         LOAD_DW(dados_curated)
32         BUILD_SEMANTIC_LAYER_E_CUBOS()
33         PUBLICAR_DASHBOARDS()
34         ATUALIZAR_LINHAGEM_CATALOGO()
35         LOG("Fim pipeline com sucesso", DATA_ATUAL, AMBIENTE)
36     CATCH erro
37         LOG_ERRO("Falha pipeline", erro)
38         NOTIFICAR(ALERTAS, "Falha no BI Orcamentario", erro)
39         ABORTAR()
```

```

40     END TRY
41 END PROCEDURE
42
43 // ----- 2) INGESTAO (RAW) -----
44 PROCEDURE INGESTAO_MULTIFONTE(janela_execucao) RETURNS Dict:
45     VAR res = {}
46     PARALLEL:
47         res["ppa"] = INGESTAO_API_OU_CSV("MPO/PPA", janela_execucao, ZONAS.RAW)
48         res["ldo"] = INGESTAO_API_OU_CSV("MPO/LDO", janela_execucao, ZONAS.RAW)
49         res["loa"] = INGESTAO_API_OU_CSV("MPO/LOA", janela_execucao, ZONAS.RAW)
50         res["empenhos"] = INGESTAO_API_OU_CSV("SIAFI/Empenhos",
51                                         janela_execucao, ZONAS.RAW)
52         res["liquidacoes"] = INGESTAO_API_OU_CSV("SIAFI/Liquidacoes",
53                                         janela_execucao, ZONAS.RAW)
54         res["pagamentos"] = INGESTAO_API_OU_CSV("SIAFI/Pagamentos",
55                                         janela_execucao, ZONAS.RAW)
56         res["restos_pagar"] = INGESTAO_API_OU_CSV("SIAFI/RestosPagar",
57                                         janela_execucao, ZONAS.RAW)
58         res["creditos_adicionais"] = INGESTAO_API_OU_CSV("SIAFI/Creditos",
59                                         janela_execucao, ZONAS.RAW)
60         res["tabelas_auxiliares"] = INGESTAO_DIM_AUXILIARES() // IBGE (UF,
61                                         // municipio), CNAE,
62                                         // natureza de despesa,
63                                         // fonte de recurso,
64                                         // UO/UG, programa, acao,
65                                         // subtítulo
66     END PARALLEL
67     RETURN res
68 END PROCEDURE
69
70 PROCEDURE INGESTAO_API_OU_CSV(fonte, janela_execucao, zona_destino):
71     CONFIG = CARREGAR_CONFIG_FONTE(fonte)
72     IF CONFIG.tipo == "API":
73         PAGINAR_E_PUXAR_API(CONFIG.endpoint, janela_execucao, zona_destino)
74     ELSE IF CONFIG.tipo == "CSV" OR CONFIG.tipo == "PARQUET":
75         LER_ARQUIVOS_BATCH(CONFIG.path, janela_execucao, zona_destino)
76     END IF
77     REGISTRAR_CHECKSUM_E_CONTAGEM(fonte, zona_destino)
78     RETURN REFERENCIA(zona_destino, fonte)
79 END PROCEDURE
80
81 // ----- 3) TRATAMENTO E PADRONIZACAO (STG) -----
82 PROCEDURE TRATAMENTO_PADRONIZACAO(dados_raw) RETURNS Dict:
83     VAR stg = {}
84     FOR cada_tabela IN dados_raw:
85         df = LER(cada_tabela)
86         df = NORMALIZAR_SCHEMA(df,

```

```

87     padrao = ["ano", "mes", "dia", "orgao", "uo", "ug", "funcao",
88             "subfuncao", "programa", "acao", "subtitulo", "nd",
89             "fonte_recurso", "pi", "empenho", "liquidacao",
90             "pagamento", "valor", "id_lancamento", "chave_natural",
91             "data_registro"])
92     df = TRATAR_DATAS(df, tz="America/Sao_Paulo")
93     df = PADRONIZAR_CODIGOS(df, zero_fill=[uo, ug, funcao, subfuncao, nd,
94                                         fonte_recurso])
95     df = LIMPAR_TEXTO(df, campos_texto=[orgao, programa, acao])
96     df = DEDUPLICAR(df, chave=["chave_natural", "id_lancamento"])
97     df = MARCAR_REGISTROS_INCONSISTENTES(df)
98     SALVAR(df, ZONAS.STG, NOME(cada_tabela))
99     stg[NOME(cada_tabela)] = REFERENCIA(ZONAS.STG, NOME(cada_tabela))
100    END FOR
101    RETURN stg
102  END PROCEDURE
103
104 // ----- 4) QUALIDADE E CONCILIACAO -----
105 PROCEDURE ASSERT_QUALIDADE(dados_stg):
106     REGRAS = [
107         REGRA_NOT_NULL(["ano", "orgao", "nd", "valor"]),
108         REGRA_DOMINIO("ano", intervalo=[2000..ANO(DATA_ATUAL)]),
109         REGRA_VALOR_NAO_NEGATIVO("valor"),
110         REGRA_CHAVE_UNICA(["id_lancamento"]),
111         REGRA_REFERENCIAL(["uo", "ug"] -> DIM_UO_UG),
112         REGRA_CICLO_ORCAMENTARIO(ppa, ldo, loa)
113     ]
114     APPLICAR_REGRAS(REGRAS, dados_stg)
115     SE houver_eros_criticos() ENTAO
116         NOTIFICAR(ALERTAS, "Qualidade: erros criticos", LISTAR_ERROS())
117         ABORTAR()
118     FIM
119  END PROCEDURE
120
121 // ----- 5) REGRAS DE NEGOCIO (CURATED) -----
122 PROCEDURE APPLICAR_REGRAS_NEGOCIO(dados_stg) RETURNS Dict:
123     VAR curated = {}
124     curated["despesa_classificada"] = CLASSIFICAR_DESPESAS(
125         base=dados_stg,
126         regras=[
127             MAPEAR_ND_PARA_ECONOMICA(),
128             TAG_OBRIGATORIA_VS_DISCRICIONARIA(),
129             TAG_INVESTIMENTO(), TAG_PESSOAL_BENEFICIOS(), TAG_CUSTEIO()
130         ]
131     )
132     curated["calendario"] = GERAR_DIMCALENDARIO_FISCAL(ano_min=2000,
133                                         ano_max=ANO(DATA_ATUAL) )

```

```

134     curated["ajustes"] = REGRAS_RATEIO_E_ELIMINACAO_DUPLICIDADE(dados_stg)
135     curated["dimensoes_scd2"] = PREPARAR_SCD2(dados_stg)
136     RETURN curated
137 END PROCEDURE
138
139 // ----- 6) DATA WAREHOUSE -----
140 PROCEDURE LOAD_DW(dados_curated):
141     UPSERT_DIM("DIM_ORGAO", FONTE=dados_curated["despesa_classificada"],
142                 CHAVE=[ "orgao" ])
143     UPSERT_DIM("DIM_UO", FONTE=dados_curated["despesa_classificada"],
144                 CHAVE=[ "uo" ])
145     UPSERT_DIM("DIM_UG", FONTE=dados_curated["despesa_classificada"],
146                 CHAVE=[ "ug" ])
147     UPSERT_DIM("DIM_FUNCAO", FONTE=dados_curated["despesa_classificada"],
148                 CHAVE=[ "funcao", "subfuncao" ])
149     UPSERT_DIM("DIM_PROGRAMA", FONTE=dados_curated["despesa_classificada"],
150                 CHAVE=[ "programa" ])
151     UPSERT_DIM("DIM_ACAO", FONTE=dados_curated["despesa_classificada"],
152                 CHAVE=[ "acao", "subtitulo" ])
153     UPSERT_DIM("DIM_ND", FONTE=dados_curated["despesa_classificada"],
154                 CHAVE=[ "nd" ])
155     UPSERT_DIM("DIM_FONTE_REC", FONTE=dados_curated["despesa_classificada"],
156                 CHAVE=[ "fonte_recurso" ])
157     UPSERT_DIM("DIM_CALENDARIO", FONTE=dados_curated["calendario"],
158                 CHAVE=[ "data" ])
159     APPLICAR_SCD2("DIM_ORGAO", HIST=dados_curated["dimensoes_scd2"])
160     APPLICAR_SCD2("DIM_UO")
161     APPLICAR_SCD2("DIM_UG")
162     APPEND_FATO("FATO_EMPENHO", SELECT_STG("empenhos"),
163                 grain=[ "data", "ug", "nd", "acao" ])
164     APPEND_FATO("FATO_LIQUIDACAO", SELECT_STG("liquidacoes"),
165                 grain=[ "data", "ug", "nd", "acao" ])
166     APPEND_FATO("FATO_PAGAMENTO", SELECT_STG("pagamentos"),
167                 grain=[ "data", "ug", "nd", "acao" ])
168     MERGE_FATO("FATO_RESTOS_PAGAR", SELECT_STG("restos_pagar"),
169                 grain=[ "ano_base", "ug", "nd", "acao" ])
170     CRIAR_VISTA("VW_EXECUCAO_CONSOLIDADA",
171                 SQL="
172                     SELECT cal.ano, cal.mes, org.orgao, ug.ug, nd.nd, aacao,
173                         SUM(e.valor) AS valor_empenhado,
174                         SUM(l.valor) AS valor_liquidado,
175                         SUM(p.valor) AS valor_pago
176                     FROM FATO_EMPENHO e
177                     LEFT JOIN FATO_LIQUIDACAO l USING (data, ug, nd, aacao)
178                     LEFT JOIN FATO_PAGAMENTO p USING (data, ug, nd, aacao)
179                     JOIN DIM_CALENDARIO cal ON e.data = cal.data
180                     JOIN DIM_UG ug ON e.ug = ug.ug

```

```

181      JOIN DIM_ORGAO org ON ug.orgao_id = org.id
182      JOIN DIM_ND nd ON e.nd = nd.nd
183      JOIN DIM_ACAO a ON e.acao = a.acao
184      GROUP BY 1,2,3,4,5,6
185      "
186  )
187 END PROCEDURE
188
189 // ----- 7) SEMANTIC LAYER, KPIs E CUBOS -----
190 PROCEDURE BUILD_SEMANTIC_LAYER_E_CUBOS():
191   KPI dotacao_inicial = SUM(LOA.dotacao_inicial)
192   KPI dotacao_atualizada = SUM(LOA.dotacao_inicial + creditos - anulacoes)
193   KPI empenhado = SUM(FATO_EMPENHO.valor)
194   KPI liquidado = SUM(FATO_LIQUIDACAO.valor)
195   KPI pago = SUM(FATO_PAGAMENTO.valor)
196   KPI saldo_disponivel = dotacao_atualizada - empenhado
197   KPI restos_pagar_proc = SUM(RESTOS.processados)
198   KPI restos_pagar_nproc = SUM(RESTOS.nao_processados)
199   KPI execucao_pct = pago / NULLIF(dotacao_atualizada,0)
200   METRICA lead_time_empenho_pagamento = DIAS_MEDIOS(data_pagamento -
201                                         data_empenho)
202   METRICA previsao_sazonal = SARIMA(VW_EXECUCAO_CONSOLIDADA, chave=[orgao,
203                                         nd], horizonte=6_meses)
204   METRICA risco_subjecucao = CLASSIFICADOR(saldo_disponivel,sazonalidade,
205                                         historico)
206   CUBO "Cubo Execucao" DIMENSOES=[Orgao,UO,UG,Programa,Acao,ND,Fonte,
207                                         Calendario]
208                                         MEDIDAS=[dotacao_inicial,dotacao_atualizada,empenhado,
209                                         liquidado,pago,saldo_disponivel,execucao_pct]
210   CUBO "Cubo Restos" DIMENSOES=[Orgao,UG,ND,AnoBase]
211                                         MEDIDAS=[restos_pagar_proc,restos_pagar_nproc,
212                                         pago_no_ano_corrente]
213 END PROCEDURE
214
215 // ----- 8) DASHBOARDS E PUBLICACAO -----
216 PROCEDURE PUBLICAR_DASHBOARDS():
217   EXPORTAR_PAINEL("Painel_Execucao_Geral", fonte="VW_EXECUCAO_CONSOLIDADA",
218                                         destino="BI-Server")
219   PUBLICAR_DATASET_SEMANTICO("Orcamento_SemanticModel")
220   ATUALIZAR_PERMISSOES(grupos=["Planejamento","Controle Interno",
221                                         "Gestores UO/UG"])
222 END PROCEDURE
223
224 // ----- 9) GOVERNANCA, AUDITORIA E LINHAGEM -----
225 PROCEDURE ATUALIZAR_LINHAGEM_CATALOGO():
226   REGISTRAR_LINHAGEM(de=ZONAS.RAW, para=ZONAS.DW,
227                                         entidades=["empenhos","liquidacoes","pagamentos",

```

```

228                     "loa", "restos_pagar"])
229
230     AUDITAR_ACESSOS_DATASETS()
231
232     ATUALIZAR_DICIONARIO_DADOS(campos_chave=[
233         ("nd", "Natureza de Despesa"), ("fonte_recurso", "Fonte de Recurso"),
234         ("acao", "Acao Orcamentaria"), ("subtitulo", "Subtitulo")
235     ])
236
237 END PROCEDURE
238
239
240 // ----- 10) INCREMENTAL, REPROCESSO E AGENDAMENTO -----
241
242 SCHEDULE DIARIO as 05:00:
243     PIPELINE_BI_ORCAMENTARIO(janela_execucao = JanelaCarga(inicio=ONTEM(),
244                                         fim=HOJE()))
245
246 SCHEDULE MENSAL_D0 as 06:00:
247     REPROCESSAR_FECHAMENTO_MENSAL(competencia=MES_ANTERIOR())
248
249
250 PROCEDURE REPROCESSAR_FECHAMENTO_MENSAL(competencia):
251     DEFINIR_JANELA(competencia.inicio, competencia.fim)
252     PIPELINE_BI_ORCAMENTARIO(janela_execucao)
253
254 // ----- 11) ALERTAS E EXCECOES DE NEGOCIO -----
255
256 RULE ALERTA_SUBEJECAO:
257     IF execucao_pct < 0.60 E MES_ATUAL >= SETEMBRO THEN
258         NOTIFICAR(ALERTAS, "Risco de Subexecucao",
259                     DETALHAR_POR(UG, ND, Programa))
260
261
262 RULE ALERTA_PICOS_DISCRICIONARIAS:
263     IF DESVIO_PADRAO(mensal_discrpcionarias) > LIMIAR THEN
264         ABRIR INCIDENTE("Volatilidade Discrpcionaria", anexo=serie_temporal)
265
266 // ----- 12) BACKUP E RECUPERACAO -----
267
268 SCHEDULE SEMANAL_DOMINGO 02:00:
269     BACKUP(areas=[ZONAS.RAW, ZONAS.STG, ZONAS.DW], retention="90 dias",
270             offsite=true)

```

Listing 1: Algoritmo 1 – BI Orcamentario: Blueprint de Pseudocodigo End-to-End