

Orçamento inteligente no SUS

Um novo modelo baseado em inteligência artificial para classificação e previsão de gastos hospitalares

Smart budgeting in the SUS (Brazilian Unified Health System)

A new artificial intelligence-based model for classification and forecasting of hospital expenses

Anderson do Nascimento Oliveira*
Maksandro José de Souza**
Ronald dos Santos Oliveira***
José Barbosa de Araújo Neto****
Thiago Vasconcellos Modenesi*****
Wellington Pinheiro dos Santos*****

► DOI: <https://doi.org/10.14295/principios.2675-6609.2026.174.007>

Depositphotos



RESUMO

Este estudo aborda os desafios de gestão orçamentária no Sistema Único de Saúde (SUS), particularmente na previsão e classificação de gastos municipais com internações hospitalares, que impactam a eficiência e equidade do financiamento público em saúde. Propõe-se um modelo de orçamento inteligente baseado em aprendizado de máquina, utilizando dados do Datasus (2022-2024) para treinar algoritmos como Naïve Bayes, Random Forest e Multi-Layer Perceptron (MLP). Os resultados demonstraram que o Naïve Bayes alcançou desempenho superior na classificação dos gastos, com índice Kappa de 0,933 e área sob a curva ROC de 0,992, enquanto o MLP apresentou maior precisão na previsão de custos hospitalares, reduzindo significativamente os erros médios absolutos e percentuais. Conclui-se que o uso de modelos preditivos e classificatórios baseados em inteligência artificial otimiza a alocação de recursos, promovendo transparência, eficiência e sustentabilidade no financiamento da saúde pública e reforçando o papel estratégico do Estado na garantia de serviços universais e equitativos. A principal contribuição deste trabalho é a proposição de um sistema inovador de orçamento inteligente, que se contrapõe a narrativas neoliberais de redução do Estado, ao demonstrar como tecnologias avançadas podem fortalecer a administração pública.

Palavras-chave: Orçamento inteligente. Aprendizado de máquina. SUS. Previsão de gastos hospitalares. Inteligência artificial.

ABSTRACT

This study addresses the challenges of budget management within Brazil's Unified Health System (SUS), particularly regarding the forecasting and classifying of municipal expenditures on hospital admissions, which affect the efficiency and equity of public health financing. It proposes an intelligent budgeting model based on machine learning, using data from Datasus (2022–2024) to train algorithms such as Naïve Bayes, Random Forest, and Multi-Layer Perceptron (MLP). The results show that Naïve Bayes achieved superior performance in expenditure classification, with a Kappa index of 0.933 and an area under the ROC curve of 0.992, while the MLP demonstrated greater accuracy in hospital cost forecasting, significantly reducing absolute and percentage errors. It is concluded that the use of predictive and classificatory models based on artificial intelligence optimizes resource allocation, promoting transparency, efficiency, and sustainability in public health financing, while reinforcing the strategic role of the State in ensuring universal and equitable services. The main contribution of this work lies in the proposal of an innovative intelligent budgeting system, which challenges neoliberal narratives advocating for the reduction of the State by demonstrating how advanced technologies can strengthen public administration.

Keywords: Intelligent budgeting. Machine learning. Brazilian Unified Health System (SUS). Hospital expense forecasting. Artificial intelligence.

1. INTRODUÇÃO

O Sistema Único de Saúde (SUS), regulamentado pela Lei Orgânica da Saúde (lei nº 8.080/1990), enfrenta desafios decorrentes de sua gestão descentralizada e de mudanças demográficas e epidemiológicas. A Constituição Federal de 1988 define a saúde como “direito de todos e dever do Estado” (Brasil, 1988), exigindo uma gestão eficiente dos recursos públicos para garantir sua sustentabilidade, especialmente na Assistência de Internação Hospitalar (AIH).

O financiamento do SUS exige planejamento estratégico, considerando a autonomia estadual e municipal na administração da saúde. Essa descentralização impõe desafios aos gestores, como a expansão de serviços e a organização da rede assistencial (Santos *et al.*, 2020).

A análise de grandes volumes de dados assistenciais permite projetar o financiamento dos gastos e estruturar orçamentos inteligentes. Muitos desses dados estão dispostos no Tabnet, que é uma ferramenta desenvolvida pelo Departamento de Informática do SUS (Datusus), a qual permite aos usuários (profissionais de saúde, pesquisadores, gestores etc.) acessar, tabular e analisar bancos de dados *online* sobre mortalidade, nascimentos, doenças, assistência à saúde e gastos nesse setor. O Datusus (2019) “disponibiliza informações que podem subsidiar análises objetivas da situação sanitária, tomadas de decisão baseadas em evidências e elaboração de programas de ações de saúde”. Além disso, a adoção de soluções inovadoras fortalece o SUS, aprimora a gestão pública e amplia o acesso a serviços gratuitos, promovendo transparência e eficiência.

Assim, este estudo tem como objetivo definir um modelo de orçamento público inteligente baseado em aprendizado de máquina para prever e classificar gastos municipais com AIH. Tem-se como estratégia para atingir a essa finalidade: i) coletar e pré-processar dados históricos de AIH dos municípios brasileiros por via do Tabnet-Datusus (2022-2024); ii) treinar e avaliar algoritmos de aprendizado de máquina para prever e categorizar gastos; iii) definir um modelo de orçamento inteligente agregando conceitos de orçamento público e considerando os resultados das previsões de gastos.

Ao aprimorar o orçamento no SUS, é possível beneficiar diretamente a maioria da população, com a aplicação de recursos que revertem em serviço público gratuito e de qualidade. Albuquerque *et al.* (2017) analisaram a relação entre desenvolvimento socioeconômico e infraestrutura de saúde, classificando 438 regiões de saúde brasileiras em 5 grupos¹. Em 2016, as áreas menos desenvolvidas (grupo 1) tinham 92% dos médicos e 88,8% dos leitos hospitalares vinculados ao SUS, atendendo 45,9 milhões de brasileiros. Apenas 5,4% da população dessas regiões possuía plano de saúde, contrastando com 58,1% no grupo 5, de maior desenvolvimento, predominante no Sul e Sudeste. Ao interpretar esses e muitos outros dados, busca-se identificar características e padrões de saúde, economia e sociedade. É nesse contexto que o aprendizado de máquina surge como apoio estratégico à formulação de políticas públicas mais efetivas.

¹ As regiões de saúde brasileira, categorização adotada por Albuquerque *et al.* (2017), correspondem a recortes territoriais do SUS para fins de planejamento e gestão, agregando municípios segundo características socioeconômicas e de oferta de serviços. Eles analisaram 438 regiões com base em dados secundários do IBGE, Datusus e ANS, classificando-as em 5 grupos por meio de análise fatorial e de *clusters*, de acordo com os seguintes eixos: i) desenvolvimento socioeconômico (renda, PIB, escolaridade e densidade populacional); ii) infraestrutura e complexidade da atenção à saúde (número de leitos, médicos e internações de alta complexidade, grau de cobertura).

2. MODELOS DE ORÇAMENTO PÚBLICO

O orçamento público é essencial para a administração financeira do Estado, prevenindo receitas e despesas em determinado período fiscal. Ele possibilita a execução de políticas públicas, assegurando transparência e responsabilidade na gestão dos recursos.

Abreu e Câmara (2015) adotaram uma perspectiva teórica que considera o orçamento uma instituição técnica e política. Para eles, o orçamento é um instrumento estruturante da ação governamental capaz de tornar factíveis as ações governamentais, um filtro de viabilidade das políticas públicas ao articular, de um lado, a análise estática da disponibilidade de recursos necessários à sua formulação e, de outro, a análise dinâmica das possibilidades de gestão no contexto político-institucional da decisão.

Nessa perspectiva, as escolhas orçamentárias refletem as ideias centrais dos mandatos governamentais e produzem efeitos que se estendem por toda a administração pública. Dessa forma, o orçamento permite ao Estado organizar prioridades, equilibrar contas e avaliar os impactos das decisões e dos resultados das políticas públicas.

A escolha do modelo mais adequado depende das especificidades de cada governo e do contexto institucional. Diante da crescente complexidade administrativa, modernizar os processos orçamentários com tecnologias emergentes, como inteligência artificial, torna-se crucial para garantir eficiência e transparência. Segundo Anessi-Pessina *et al.* (2016), ferramentas tecnológicas podem aprimorar a gestão orçamentária, fortalecer a *accountability* e otimizar a alocação de recursos. Dentre os modelos orçamentários, destacam-se o orçamento incremental, o orçamento-programa, o orçamento base zero e o orçamento participativo, cada um com abordagens específicas para a distribuição de recursos.

2.1. ORÇAMENTO INCREMENTAL

O orçamento incremental, também conhecido como tradicional, utiliza dados históricos como base para o orçamento do próximo período, ajustando-os por indicadores financeiros ou análise de variações econômicas (Lima *et al.*, 2023). Ele se fundamenta nos gastos do ano anterior, aplicando ajustes marginais para aumentos ou reduções (Anessi-Pessina *et al.*, 2016).

Originário da administração pública tradicional, esse modelo é amplamente adotado em países desenvolvidos e em desenvolvimento. No Brasil, permanece como o sistema predominante na gestão pública (Anessi-Pessina *et al.*, 2016). Sua principal vantagem é a simplicidade e facilidade de implementação. Contudo, ele pode perpetuar ineficiências ao não promover uma reavaliação crítica das despesas ou do vínculo com o planejamento, baseando-se em parâmetros históricos que frequentemente são questionados (Kreuzberg; Beck; Lavarda, 2016; Lima *et al.*, 2023).

2.2. ORÇAMENTO-PROGRAMA

É responsável por integrar o orçamento ao planejamento (Plano Plurianual), relacionando os programas e projetos com seus respectivos gastos, necessários para alcançar os objetivos predeterminados e avaliar os resultados.

Criado nos Estados Unidos, na década de 1940, para modernizar a administração

pública, foi introduzido no Brasil pelo decreto-lei nº 200/1967, que menciona o orçamento-programa como plano de ação do governo federal, e consolidado pela portaria nº 09/1974 da Secretaria de Planejamento e Coordenação da Presidência da República, que institui a classificação funcional-programática, e pela portaria nº 42/1999, que mantém a classificação funcional e vincula a estrutura programática aos planos plurianuais de cada ente federativo. Destaca-se pela transparência e monitoramento da execução orçamentária. Bezerra Filho (2013, p. 11) define: “O orçamento-programa é um instrumento de planejamento que permite identificar os programas, projetos e atividades que o governo pretende realizar, além de estabelecer objetivos, metas, gastos e resultados esperados, proporcionando maior transparência na execução dos gastos públicos.”

Esse modelo representa um avanço em relação ao orçamento clássico, focado em insumos, e ao orçamento de desempenho, que prioriza realizações de curto prazo sem planejamento de médio prazo (Bezerra Filho, 2013). Sua principal vantagem é a vinculação ao planejamento governamental e à avaliação de resultados.

No entanto, sua implementação exige capacitação técnica e tempo operacional. Abreu e Câmara (2015) destacam que, embora o orçamento-programa possibilite a formulação de políticas públicas, sua execução pode ser influenciada por disputas políticas e decisões arbitrárias, resultando em alocações ineficazes e descontinuadas.

2.3. ORÇAMENTO BASE ZERO

O orçamento base zero exige justificativa para todas as despesas a cada novo ciclo orçamentário. Para Costa, Moritz e Machado (2007), trata-se de um modelo que “exige que se deixe de lado todos os dados históricos das despesas e receitas da organização”. Seu objetivo é revisar criticamente os gastos e receitas a cada exercício fiscal. Diferente dos modelos tradicionais, ele não considera automaticamente os gastos anteriores, exigindo análise detalhada das despesas governamentais (Lima *et al.*, 2023). Segundo Pascoal (2008) *apud* Bezerra Filho (2013), essa metodologia se caracteriza por uma revisão minuciosa de cada item orçamentário, sem compromisso com despesas anteriores, permitindo reavaliação completa das prioridades governamentais.

Desenvolvido nos Estados Unidos pela Texas Instruments Inc. em 1969, foi adotado no governo do estado da Geórgia sob a administração de Jimmy Carter (Bezerra Filho, 2013). No Brasil, começou a ser utilizado nos anos 1980, primeiro no setor privado e depois no público (Lima *et al.*, 2023).

Ao aprimorar o orçamento no SUS, é possível beneficiar diretamente a maioria da população, com a aplicação de recursos que revertem em serviço público gratuito e de qualidade

O orçamento base zero elimina despesas desnecessárias, mas sua implementação demanda tempo e detalhamento (Lima *et al.*, 2023). Além disso, exige rigor técnico e elevado nível de aprendizado organizacional (Costa; Moritz; Machado, 2007). Seu uso é mais comum em empresas estadunidenses, sendo menos frequente na gestão pública devido ao custo operacional e à complexidade.

2.4. ORÇAMENTO PARTICIPATIVO

O orçamento participativo revolucionou a gestão pública ao permitir que a população participe diretamente da definição de prioridades e alocação de recursos. Esse modelo fortalece a transparência, o controle social e a democratização das decisões governamentais (Lopes; Freire, 2012).

Segundo Bezerra Filho (2013), a metodologia possibilita que a sociedade civil, por meio de conselhos, associações e audiências públicas, influencie a formulação orçamentária. Pascoal (2008) *apud* Bezerra Filho (2013) destacou que o modelo estimula a cidadania ativa ao envolver comunidades na elaboração do orçamento.

Aplicado inicialmente em Porto Alegre, em 1989, o orçamento participativo expandiu-se para diversas cidades no Brasil e no mundo, sendo reconhecido como um modelo transparente e inclusivo. Entre suas vantagens estão a maior transparência, a inclusão social e o fortalecimento da cidadania, além de “sinais de possibilidades de construção de um método provedor de democracia” (Lopes; Freire, 2012). No entanto, sua implementação enfrenta desafios, como baixa adesão popular e a necessidade de mudanças culturais e institucionais para garantir-lhe efetividade.

3. ORÇAMENTO DO SUS: GESTÃO DE RECURSOS E IMPACTOS SOCIAIS

A distribuição de recursos no SUS ocorre por meio do limite financeiro da Média e Alta Complexidade (MAC) e do Fundo de Ações Estratégicas e Compensação (Faec), conforme a portaria de consolidação nº 6, de 28 de setembro de 2017 (Brasil, 2022). A descentralização dos recursos, bem como a diversidade populacional, exige aprimoramento contínuo da gestão dos gastos públicos, e a análise detalhada dos gastos contribui para uma alocação mais eficiente desses recursos, reduzindo o número de internações desnecessárias e otimizando o orçamento da saúde.

Otimizar a distribuição de recursos na saúde é essencial para promover melhorias orçamentárias e reduzir desigualdades socioeconômicas no Brasil, considerando o modelo atual de alocação descentralizada e a diversidade de necessidades entre municípios. Albuquerque *et al.* (2017) realizaram um estudo sobre as desigualdades na oferta de serviços de saúde no país. Eles analisaram mudanças socioeconômicas e a evolução da infraestrutura de saúde entre 2000 e 2016, classificando as 438 regiões de saúde em 5 grupos com perfis socioeconômicos e de oferta de serviços específicos, conforme descrito no quadro 1 e detalhado na tabela 1 – elaborados por Albuquerque *et al.* (2017) a partir de dados oficiais extraídos do IBGE e Datasus.



O financiamento, a organização e a expansão do SUS exigem planejamento estratégico, ao passo que a autonomia dos estados e municípios na administração da saúde constitui um desafio à consecução desses objetivos

Quadro 1 — Resumo sobre os agrupamentos de regiões de saúde no Brasil

Grupo	Descrição
1	Baixo desenvolvimento socioeconômico, concentrando-se no Nordeste; composto por 175 regiões e 2.151 municípios, principalmente na região Nordeste, abrangendo 22,5% da população brasileira.
2	Desenvolvimento socioeconômico intermediário, com oferta limitada de serviços de saúde; abrange 47 regiões, 482 municípios e 5,7% da população, principalmente nas macrorregiões Centro-Oeste, Sudeste e Norte.
3	Equilíbrio entre desenvolvimento socioeconômico e disponibilidade de serviços; inclui 129 regiões e 1.891 municípios, representando 20,3% da população e localizando-se majoritariamente nas regiões Sudeste e Sul.
4	Alta renda e oferta média de serviços, englobando 27 regiões, 300 municípios e 10,6% da população, concentrando-se na macrorregião Sudeste.
5	Desenvolvimento socioeconômico mais alto, com maior acesso à saúde suplementar; inclui 60 regiões, 746 municípios e 40,9% da população brasileira, com predominância nas regiões Sudeste e Sul.

Fonte: Albuquerque *et al.* (2017).

Esses agrupamentos destacam as disparidades regionais e apoiam os gestores no planejamento estratégico do SUS. Conforme a tabela 1, em 2016, nas regiões de menor desenvolvimento (grupo 1), 92,2% dos médicos eram do SUS, e 88,8% dos leitos hospitalares pertenciam ao sistema, atendendo cerca de 45,9 milhões de brasileiros. Nesse mesmo período, apenas 5,4% da população do grupo 1 tinha plano de saúde, contrastando com 58,1% no grupo 5, formado por regiões de maior desenvolvimento, predominantemente nas regiões Sul e Sudeste. A tipologia proposta pelo estudo evidencia disparidades regionais, reforçando a necessidade de políticas específicas para cada grupo.

Tabela 1 — Principais características dos agrupamentos de regiões de saúde no Brasil — 2016

Características	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Total
Rendimento domiciliar <i>per capita</i> médio (R\$)	271	484	582	660	895	668
Beneficiários de planos de saúde na população (% do total)	5,4	14,6	25,4	39,5	58,1	35,3
Médicos (por mil habitantes)	0,63	0,90	1,42	1,60	2,61	1,72
Médicos do SUS (% do total)	92,2	86,5	83,3	78,1	70,0	75,4
Leitos (por mil habitantes)	1,7	1,7	2,4	1,9	2,5	2,2
Leitos no SUS (% do total)	88,8	76,6	72,9	68,7	62,5	70,6

Fonte: Albuquerque *et al.* (2017).

A análise mostra que as regiões mais desenvolvidas concentram a maior parte dos beneficiários de planos de saúde e leitos hospitalares, enquanto as menos favorecidas dependem amplamente do SUS. Estratégias inteligentes de alocação podem reduzir desigualdades e melhorar a eficiência do orçamento da saúde pública.

3.1. FINANCIAMENTO DA ASSISTÊNCIA DE INTERNAÇÃO HOSPITALAR (AIH) NO SUS

A AIH é central no SUS, envolvendo hospitais públicos e conveniados. Sua gestão é tripartite (federal, estadual e municipal), coordenando a rede hospitalar e autorizando internações (Datusus, 2019). O financiamento ocorre majoritariamente pelo teto MAC, com transferências automáticas para os fundos de saúde, enquanto cerca de 10% são direcionados ao Faec, para procedimentos estratégicos (Santos *et al.*, 2023).

A aplicação de aprendizado de máquina na análise de AIH pode identificar padrões de gastos e otimizar recursos. Santos *et al.* (2020) questionam, destacando a necessidade de inovações: “O modelo de gestão contratualizada seria realmente favorável à expansão da cobertura assistencial estatal?”. A inteligência artificial (IA) permite prever gastos e identificar ineficiências, promovendo maior eficiência e equidade na alocação de recursos do SUS.

4. MÉTODOS DE APRENDIZADO DE MÁQUINA APLICADOS À GESTÃO DO ORÇAMENTO PÚBLICO

4.1. ALGORITMOS PARA CLASSIFICAÇÃO DOS GASTOS

Algoritmos como Naïve Bayes, SVM e Random Forest são utilizados para categorizar padrões de despesas municipais, auxiliando na gestão eficiente dos recursos públicos (Provost; Fawcett, 2016; Ricciardi *et al.*, 2024):

1. Naïve Bayes: baseado no teorema de Bayes, assume independência condicional entre variáveis e é eficaz para dados categóricos, como classificação de despesas;
2. SVM (Support Vector Machine): utiliza hiperplanos para separar classes, sendo útil para análise financeira e previsão de gastos;
3. Random Forest: conjunto de árvores de decisão que melhora a precisão e reduz o risco de sobreajuste;
4. MLP: redes neurais artificiais que aprendem padrões complexos e são aplicáveis à previsão de custos hospitalares.

Estudos demonstraram que o aprendizado de máquina pode otimizar a gestão hospitalar. O uso do Random Forest para prever tempo de permanência em internações melhorou a alocação de recursos e planejamento de serviços (Couto *et al.*, 2024). Além disso, técnicas como as redes bayesianas permitem identificar padrões ocultos nos gastos públicos, contribuindo para decisões mais informadas (Ricciardi *et al.*, 2024).

Os modelos foram avaliados por métricas como erro percentual absoluto médio (Mape — *mean absolute percentage error*), erro médio absoluto (MAE — *mean absolute error*), índice Kappa e área sob a curva ROC (AUC-ROC — *area under the curve / receiver operating characteristic*) (Hyndman; Athanasopoulos, 2018).

1. Mape: mede o erro médio percentual das previsões em relação aos valores reais.
2. MAE: calcula a diferença absoluta entre valores previstos e observados.
3. Índice Kappa: mede a concordância ajustada entre previsões e valores reais.
4. AUC-ROC: avalia a capacidade do modelo em diferenciar classes corretamente.

Essas métricas são essenciais para validar ou não a precisão dos modelos e garantir a confiabilidade dos dados na tomada de decisões financeiras.

4.2. MODELOS DE REGRESSÃO PARA PREDIÇÃO DE GASTOS

Algoritmos como Decision Tree, Random Forest e MLP são amplamente utilizados para análise de dados financeiros e previsão de despesas (Castro; Ferrari, 2016; Grus, 2016). No contexto do orçamento público, esses modelos permitem antecipar gastos em diferentes categorias, reduzindo incertezas e otimizando a alocação de recursos. A escolha do algoritmo ideal é baseada na minimização dos erros médios, como Mape e MAE.

O Decision Tree segmenta os dados em hierarquias, tornando sua interpretação intuitiva, embora suscetível a sobreajuste (Provost; Fawcett, 2016). O Random Forest, por sua vez, mitiga esse problema ao combinar múltiplas árvores de decisão, aumentando a precisão preditiva (Grus, 2016). O KNN (K-Nearest Neighbors) baseia suas previsões na proximidade entre os dados, sendo eficaz para relações não lineares (Castro; Ferrari, 2016). Já o MLP (Multi-Layer Perceptron), composto por múltiplas camadas de neurônios, resolve problemas mais complexos com aprendizado profundo, utilizando retropropagação do erro para ajuste de pesos (Castro; Ferrari, 2016). O quadro 2 sintetiza as vantagens e desvantagens de cada modelo.

Quadro 2 — Comparação entre características dos algoritmos

Modelo	Vantagens	Desvantagens	Aplicação
Decision Tree (Árvore de Decisão)	Fácil de interpretar, não precisa de muita preparação dos dados.	Sujeito a sobreajuste, especialmente em dados ruidosos.	Previsão de dados com baixa complexidade.
Random Forest (Conjunto de Árvores de Decisão)	Robusto contra sobreajuste, apresenta boa precisão em dados complexos.	Mais lento e menos interpretável.	Previsão de preços, análise de risco.
SVC (modelos baseados em vetores de suporte)	Eficaz em separação não linear, tem bom desempenho em alta dimensionalidade.	Sensível à escolha do <i>kernel</i> e dos parâmetros, pode ser lento.	Previsão de valores de mercado, análise de dados financeiros.
KNN (baseado em vizinhos mais próximos)	Simples, fácil de entender e implementar.	Computacionalmente caro, sensível a ruídos e ao valor de <i>k</i> .	Análise de tendências, predição de valores contínuos com base em padrões.
MLP (Perceptron de Múltiplas Camadas)	Capaz de resolver problemas mais complexos e com redes de múltiplas camadas.	Seu processo de ajuste de pesos durante o treinamento não é conhecido.	Resolução de problemas não lineares, com algoritmo de treinamento mais sofisticado e capaz de definir de forma automática os pesos.

Fonte: elaboração própria.

5. METODOLOGIA

A metodologia adotada neste estudo é composta por três etapas principais: 1) coleta e pré-processamento dos dados: dados históricos de internação hospitalar (AIH) dos municípios brasileiros foram extraídos do Tabnet-Datasus, abrangendo o período de janeiro de 2022 a julho de 2024); 2) treinamento de modelos de aprendizado de máquina: algoritmos

de regressão e classificação foram testados para prever e categorizar os gastos com AIH; 3) definição de um orçamento inteligente: com base na literatura sobre orçamento público e nos resultados das previsões, foi elaborado um modelo para otimizar a alocação de recursos.

5.1. BASE DE DADOS DE AIH NO TABNET-DATASUS

Os atributos utilizados neste estudo foram extraídos do *dataset* disponível no Tabnet-Datasus². Das 17 variáveis (ou atributos) disponibilizadas na base de dados sobre AIH, foram selecionadas inicialmente 8 delas para o pré-processamento, conforme o quadro 3. A exclusão de variáveis ocorreu devido à sua baixa relevância estatística, falta de relação teórica com o objetivo do estudo ou por serem menos explicativas que outras variáveis.

Quadro 3 — Descrição dos atributos: resumo das variáveis do *dataset*

Atributo	Descrição	Tipo	Domínio
Município	Nome do município onde as internações hospitalares foram realizadas ou registradas	Localidade	<i>Strings</i> compostas por caracteres alfabéticos
Internações	Quantidade de internações do período	Quantidade	Números inteiros não negativos
Valor total	Valor monetário total pago	Valor monetário	Números reais não negativos
Valor médio de internação	Média do valor pago por cada internação realizada	Valor monetário	Números reais não negativos
Dias de permanência	Número total de dias em que os pacientes permaneceram internados	Quantidade	Números inteiros não negativos
Média de permanência	Média de dias em que os pacientes permaneceram internados por internação	Quantidade proporcional	Números reais não negativos
Óbitos	Número total de óbitos ocorridos durante as internações	Quantidade	Números inteiros não negativos
Taxa de mortalidade	Porcentagem de óbitos em relação ao número total de internações	Percentual	Números reais entre 0 e 100

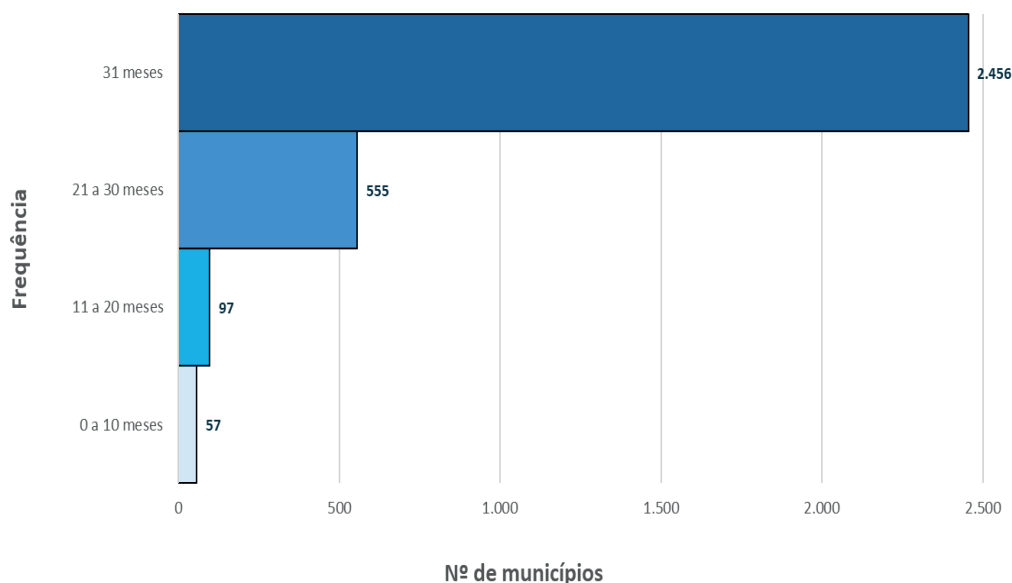
Fonte: elaboração própria.

² Atributos são características ou propriedades de cada registro individual em um *dataset*, correspondendo às colunas de uma tabela. *Dataset* (ou conjunto de dados) é uma coleção organizada de dados relacionados, que serve como matéria-prima para os processos de análise ou treinamento de modelos de aprendizado de máquina. O Tabnet, gerido pelo Datasus, disponibiliza dados do Sistema de Informações Hospitalares do SUS (SIH-SUS), coletados diariamente pela rede credenciada (Datasus, 2019).

5.2. ANÁLISE DESCRITIVA DOS DADOS

Foram aplicadas estatísticas descritivas e matriz de correlação para avaliar padrões nos dados (Kimura *et al.*, 2023). O gráfico 1 ilustra a distribuição da frequência dos municípios no *dataset* do Tabnet-Datasus, abrangendo dados mensais de janeiro de 2022 a julho de 2024. Do total de 3.165 municípios analisados, tem-se a quantidade desses municípios (eixo vertical) distribuída segundo o número de meses (de 1 a 31, eixo horizontal) em que eles são identificados no *dataset* quando do recebimento de parcela dos recursos para AIH. Destaca-se que 2.456 municípios receberam regularmente recursos mensais no período considerado, enquanto 57 municípios receberam recursos apenas em 1 a 10 meses de toda a série.


Gráfico 1 — Distribuição dos municípios segundo a quantidade de meses em que receberam recursos para AIH — janeiro/2022-julho/2024



Fonte: elaboração própria.

O gráfico 2 compara os 10 municípios com maiores valores registrados em um único mês para o gasto médio de internação, no período de janeiro de 2022 a julho de 2024, sendo eles: Bezerros (PE), Bom Jesus do Itabapoana (RJ), Charqueadas (RS), Guaíba (RS), Itaperuna (RJ), Jaci (SP), Remanso (BA), Santa Rita (PB), Timbaúba (PE) e Trombudo Central (SC).

Gráfico 2 — Frequência dos 10 municípios com maiores valores médios mensais de AIH por internação e média e mediana gerais (em R\$) – janeiro/2022-julho/2024




Fonte: elaboração própria.

No conjunto selecionado, é possível identificar uma diferença significativa entre valores médios de AIH gastos pelos municípios no período de janeiro 2022 a julho de 2024: de R\$ 8.333,29, em Bom Jesus do Itabapoana (RJ), a R\$ 19.750,15, em Jaci (SP). A discrepância fica ainda mais evidente quando comparada com a média e a mediana dos valores de todos os municípios: R\$ 687,02 e R\$ 482,50, respectivamente.

O gráfico 3 destaca a tendência de alta do município de Santa Rita, do estado da Paraíba, finalizando a trajetória como maior valor no 1º semestre de 2024, ultrapassando inclusive o município de Jaci, do estado de São Paulo, que obteve os maiores gastos de internação hospitalar da série histórica semestral entre 2022 e 2023. Importante ressaltar a evidência de que o tamanho do município não é condição para obter maior gasto médio de internação.

Gráfico 3 — Evolução semestral dos 10 maiores gastos médios de internação por município — janeiro/2002-julho/2024



Fonte: elaboração própria.

5.3. PRÉ-PROCESSAMENTO DOS DADOS

Foram aplicadas técnicas de limpeza e transformação dos dados para adequação à modelagem preditiva. As etapas envolveram:

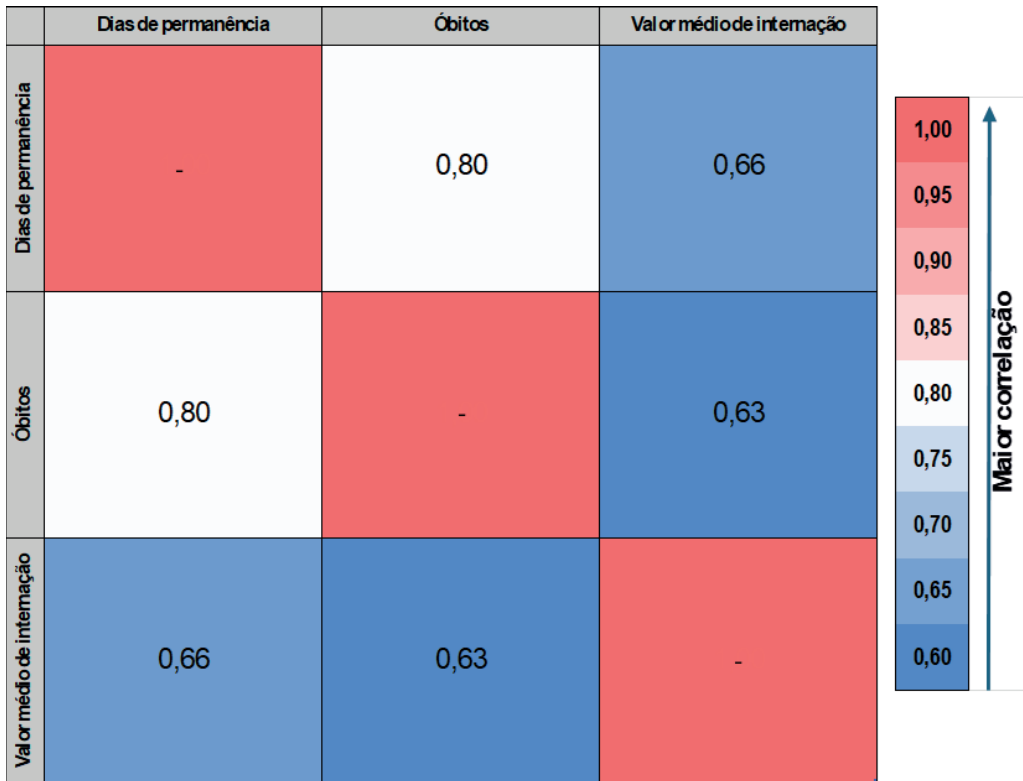
1. Consolidação dos dados: unificação dos *datasets* mensais de 2022 a 2024.
2. Tratamento de caracteres: substituição de travessões por zero, conforme orientação do Tabnet.
3. Remoção de inconsistências: exclusão de registros duplicados e irrelevantes.
4. Análise de lacunas: identificação de valores ausentes.
5. Uso de matriz de correlação: seleção de variáveis relevantes para modelagem preditiva.

O gráfico 4 exibe a matriz de correlação entre as variáveis-chave. A matriz de correlação é uma ferramenta estatística que organiza e resume as relações lineares entre pares de variáveis em uma base de dados, indicando a direção e a intensidade dessas associações. Ela permite compreender como as variáveis se comportam conjuntamente, fornecendo uma visão objetiva da estrutura dos dados.

Suas principais finalidades incluem: identificar relacionamentos, o que ajuda a determinar rapidamente quais variáveis estão relacionadas entre si e quais não estão; realizar análise exploratória dos dados, fornecendo respostas iniciais sobre a estrutura dos dados antes da modelagem; selecionar variáveis preditoras estatisticamente relevantes; e detectar multicolinearidade — quando variáveis independentes estão fortemente correlacionadas em um modelo, enviesando ou dificultando a interpretação dos resultados com problemas de *overfitting* (ou sobreajuste).

O gráfico 4 apresenta 3 variáveis-chaves selecionadas nessa fase de pré-processamento, remanescentes da análise exploratória dos dados contidos nas 8 variáveis descritas no quadro 3. São elas: valor médio de internação, óbitos e dias de permanência.

Gráfico 4 — Matriz de correlação entre as variáveis



Fonte: elaboração própria.

As variáveis com alta correlação são boas candidatas a preditores, enquanto variáveis preditoras exageradamente correlacionadas entre si podem indicar multicolinearidade. A matriz acima ilustra forte correlação entre as três variáveis, com valores de 0,63 a 0,80, indicando um bom poder explicativo entre elas, o que as qualifica para serem utilizadas no treinamento dos modelos de aprendizado de máquina e no estabelecimento de uma relação teórica capaz de responder ao problema de pesquisa.

5.4. CLASSIFICAÇÃO DOS GASTOS COM AIH

Os municípios foram categorizados em 6 faixas, conforme os valores médios de internação registrados. A tabela 2 apresenta essa classificação.

Tabela 2 — Faixas de classificação dos municípios segundo o valor médio de interação – janeiro/2022-julho/2024

Faixa	Valor (R\$)
1 Muito baixa	43,26 – 219,23
2 Baixa	219,24 – 438,85
3 Intermediária	438,86 – 535,76
4 Alta	535,77 – 909,37
5 Muito alta	909,38 – 1.129,73
6 Excedente	> 1.129,73

Fonte: elaboração própria

5.5. AMOSTRAGEM E SUBAMOSTRAGEM

Para diminuir o ruído dos dados, foi realizado o balanceamento da base com o uso do *software* Weka³ (Waikato Environment for Knowledge Analysis), criando uma subamostragem através da função de filtro (*distribution-based balance*). O arquivo da base de dados foi aberto no módulo Explorer do Weka e o parâmetro (quantidade de amostras para a subamostragem) foi ajustado considerando o comportamento gaussiano dos dados. Essa subamostragem permitiu a geração de uma base de dados mais equilibrada e adequada para as etapas subsequentes, evitando vieses.

Na sequência, foi realizada a seleção dos atributos, utilizando-se algoritmos genéticos com a função “Evolutionary search” no Weka, aplicada para selecionar os atributos mais relevantes para a classificação dos gastos, descrita na seção 5.4. Esse procedimento resultou em uma base de dados reduzida, contendo apenas os atributos mais significativos para a classificação. A nova base de dados foi salva em um arquivo separado.

Ao final, a base de dados reduzida foi dividida em dois subconjuntos: conjunto de treino (80% da base) e conjunto de teste (20% da base). Cada subconjunto foi salvo em arquivos distintos, garantindo-se que os dados de teste permanecessem completamente independentes durante o treinamento dos modelos. Após o reconhecimento do padrão de normalidade dos dados, foi retirada uma amostragem definitiva do conjunto de treino.

5.6. APLICAÇÃO DOS ALGORITMOS DE CLASSIFICAÇÃO E AVALIAÇÃO DO DESEMPENHO

Os modelos testados incluíram: Naïve Bayes, redes bayesianas, SVM (com diferentes configurações de *kernel*), MLP (redes neurais), Random Tree, Árvore de Decisão J48 e

3 O Weka é um pacote licenciado pela General Public License e utilizado para fins acadêmicos, sendo possível alterar seu código-fonte. Tem como objetivo agregar algoritmos provenientes de diferentes abordagens no estudo de aprendizagem de máquina, e permite a análise computacional e estatística dos dados fornecidos, recorrendo a técnicas de mineração de dados. Está disponível em: <<https://ml.cms.waikato.ac.nz/weka>>.

Random Forest. Cada classificador foi validado utilizando-se validação cruzada de 10 *folds*, com 30 repetições. Existem outros algoritmos de aprendizado de máquina disponíveis, a depender do tipo de problema (classificação, regressão, clusterização etc.). Para este estudo, optou-se pelos modelos mais usuais na literatura. A avaliação dos modelos foi baseada nas métricas descritas no quadro 4.

Quadro 4 — Métrica de avaliação do desempenho dos algoritmos

Métrica	Descrição
Índice Kappa	Mede a concordância ajustada.
Acurácia	Corresponde ao percentual de predições corretas.
Sensibilidade e especificidade	Avalia a taxa de verdadeiros positivos e negativos.
Área sob a curva ROC (AUC-ROC)	Mede a capacidade discriminativa do modelo.

Fonte: elaboração própria.

Os modelos foram treinados e testados para que se pudesse identificar o mais eficiente na predição e categorização dos gastos hospitalares.

6. ORÇAMENTO INTELIGENTE: PREVISÃO E CLASSIFICAÇÃO DE GASTOS

Este estudo propõe um modelo de orçamento inteligente como aprimoramento das práticas de orçamentação pública no Brasil. Utilizando algoritmos de aprendizado de máquina e dados de AIH dos municípios, desenvolve-se um modelo capaz de prever valores, classificar informações e otimizar cenários com base em dados históricos e atributos estatisticamente relevantes.

O uso de inteligência computacional deve complementar, e não substituir, as decisões políticas sobre a alocação de recursos estratégicos. O orçamento inteligente busca modernizar as práticas orçamentárias, tornando-as mais analíticas e eficientes, promovendo um debate fundamentado sobre o papel do Estado e sua capacidade de gerar bem-estar social.

6.1. DEFINIÇÃO DE ORÇAMENTO INTELIGENTE

O orçamento inteligente combina planejamento público com aprendizado de máquina para classificar e prever gastos. Inspirado no orçamento-programa, prioriza eficiência e impacto com base em evidências preditivas. Supera limitações do orçamento base zero ao automatizar a análise histórica e identificar padrões dinâmicos. Diferencia-se do orçamento incremental ao evitar ajustes automáticos, utilizando algoritmos como Naïve Bayes, Random Forest e SVM para otimizar a distribuição de recursos. Além disso, os avanços proporcionados pela implementação do orçamento inteligente, ao incorporar aspectos da participação social na definição das prioridades orçamentárias, promovem transparência e apoio à decisão estratégica, contribuindo para a sustentabilidade fiscal e maximização dos benefícios sociais, como demonstrado na gestão dos gastos da AIH no SUS.

Este estudo propõe um modelo de orçamento inteligente como aprimoramento das práticas de orçamentação pública no Brasil. Utilizando algoritmos de aprendizado de máquina e dados de AIH dos municípios, desenvolve-se um modelo capaz de prever valores, classificar informações e otimizar cenários com base em dados históricos e atributos estatisticamente relevantes

6.2. REGRESSÃO E AVALIAÇÃO DOS MODELOS

Foram testados os modelos Random Forest, Decision Tree, MLP, SVC e KNN para aplicação em problemas de regressão. Os três primeiros foram selecionados, com base na acurácia e menor erro médio percentual (Mape) e absoluto (MAE). As etapas incluíram: 1) ajuste de hiperparâmetros; 2) avaliação final no conjunto de testes. As variáveis utilizadas foram *valor médio de internação*, *dias de permanência hospitalar* e *óbitos*. A tabela 3 apresenta os resultados.

Tabela 3 — Análise descritiva das variáveis *valor médio de internação*, *dias de permanência hospitalar* e *óbitos*: avaliação no conjunto de teste


Método	Random Forest	Decision Tree	MLP
Mape (%)	32,145	34,557	28,345
MAE	194.549	216.191	183.076

Fonte: elaboração própria.

O MLP apresentou o melhor desempenho, ajustando-se eficientemente aos dados da AIH. O gráfico 5 ilustra a curva de aprendizado do modelo. Isso significa que a regressão baseada no Multi-Layer Perceptron, dentre os demais modelos, ofereceu as melhores condições de resposta à base de dados do Datasus referentemente à AIH, conseguindo aprender de forma mais eficaz ao realizar processo de ajustes automáticos dos pesos durante o treinamento, o que resultou em menores erros médios percentual (Mape) e absoluto (MAE) nas previsões: 28,345% e 183.076, respectivamente.

A redução progressiva dos erros indica que o modelo se estabiliza a partir da época 60, evidenciando-se sua capacidade preditiva. Para ilustrar essa curva de aprendizado do MLP, utiliza-se a função de perda (MAE), que detalha o comportamento do treino e da validação do modelo.

Gráfico 5 — Função de perda do MAE, conforme o treino e a validação do modelo MLP



Fonte: elaboração própria.

Pode-se observar no gráfico 5 que os erros médios no treinamento diminuem de forma acentuada nas primeiras épocas, de 0 a 10, significando intervalo de maior velocidade de aprendizado sobre os dados do treinamento e validação. Eles atingem uma condição de estabilidade no avançar das épocas, obtendo-se os menores erros entre as épocas 60 e 70. A partir desse intervalo, alguns picos de aumento nos erros médios começam a ser identificados, o que significa que o modelo não precisa avançar mais no treinamento e na validação por ter atingido a melhor condição de treinamento, de modo a não comprometer seu MAE.


Com os achados apresentados nesta seção, entende-se que o MLP surge como a melhor alternativa de aprendizado de máquina para responder ao objetivo deste trabalho.

6.2.1. AVALIAÇÃO DOS GASTOS MÉDIOS DE INTERNAÇÃO HOSPITALAR DO SUS NOS MUNICÍPIOS

Após se identificar o MLP como o modelo mais eficiente de aprendizado de máquina, aplicaram-se os resultados da regressão para avaliar os gastos médios com AIH em 5 municípios brasileiros: Brasília (DF), Recife (PE), Vitória (ES), São Paulo (SP) e Curitiba (PR). Esses municípios foram selecionados aleatoriamente entre as capitais.

O gráfico 6 compara gastos médios reais e estimados com internações hospitalares nos municípios e no período selecionados aleatoriamente. A consulta buscou valores relativos aos 5 municípios considerados, entre os meses de janeiro e fevereiro de 2022. Essa análise oferece uma visão clara da situação atual dos gastos médios, servindo como ferramenta gerencial para apoiar decisões sobre a alocação de recursos e medidas de controle. O gráfico ilustra uma idealização deste estudo para aplicação, em algumas das finalidades possíveis, do algoritmo de regressão linear selecionado nesta seção, propiciando uma comparação do custo médio de internação praticado entre municípios e entre os diferentes períodos e valores de previsão com base no aprendizado do modelo.

Gráfico 6 — Custo médio (R\$) previsto e real das internações hospitalares no SUS em municípios selecionados — janeiro-fevereiro de 2022



Fonte: elaboração própria.

Na comparação entre os valores previstos e os reais, observa-se que Brasília, Vitória, Curitiba e São Paulo apresentam gastos médios reais inferiores aos previstos, o que sugere uma possível economia ou indicativo de subfinanciamento, nesse último caso, pela possibilidade de os gastos reais executados a menor ameaçarem a realização de melhores resultados assistenciais. Em contrapartida, Recife exibe um valor médio real superior ao previsto, indicando potencial uso excessivo de recursos. Esses *insights* permitem identificar padrões e ajustar estratégias de gestão, indicando maior objetividade nas análises. Porém, é recomendável que a ferramenta apenas apoie as decisões dos gestores, necessitando-se complementar a avaliação em cada caso concreto.

O orçamento inteligente combina planejamento público com aprendizado de máquina para classificar e prever gastos. Inspirado no orçamento-programa, prioriza eficiência e impacto com base em evidências preditivas. Supera limitações do orçamento base zero ao automatizar a análise histórica e identificar padrões dinâmicos. Diferencia-se do orçamento incremental ao evitar ajustes automáticos

Os gestores podem utilizar essas informações sob diferentes perspectivas: *local*, ao avaliarem os municípios como centro dos gastos hospitalares; *estadual*, ao compararem dados municipais de um mesmo estado, promovendo maior equidade na distribuição de recursos e melhorias nos gastos; e *regional/nacional*, ao utilizarem os dados para apoiar o planejamento de metas, estratégias e orçamentos em políticas públicas de saúde, garantindo assistência hospitalar eficiente. Essa abordagem fornece subsídios objetivos para otimizar a alocação de recursos e maximizar a eficiência dos gastos com AIH no SUS.

6.3. CLASSIFICAÇÃO E AVALIAÇÃO DOS MODELOS


Na fase de classificação dos gastos médios de internação (tabela 2), os modelos utilizados foram: Naïve Bayes, redes bayesianas, SVM (com diferentes configurações de *kernel*), MLP (redes neurais), Random Tree, Árvore de Decisão J48 e Random Forest. Cada classificador usou como configuração de treinamento no *software* Weka a validação cruzada de 10 *folds*, com 30 repetições. Em cada modelo os resultados foram comparados por meio do índice Kappa, da área sob a curva ROC (*area under ROC*), da taxa de verdadeiros positivos (*true positive rate*) e da porcentagem de classificações corretas (*percent correct*). A análise inicial dos *boxplots*, especialmente os do índice Kappa, sugere que o Naïve Bayes e o Random Forest têm potencial para serem considerados classificadores de alta confiabilidade devido à combinação de consistência e bom desempenho, que serão examinados nas seções seguintes.

6.3.1. ANÁLISE DOS RESULTADOS PELO ÍNDICE KAPPA

Os resultados do índice Kappa foram os principais parâmetros avaliados sobre o aprendizado dos algoritmos de classificação deste estudo. Os gráficos 7 a 10 ilustram, através dos *boxplots*, as variações de desempenho entre os modelos treinados. O Naïve Bayes destacou-se pela menor dispersão nos resultados do índice Kappa, indicando consistência nos

desempenhos. Em contraste, os modelos MLP (com diferentes configurações de neurônios) apresentaram maior variabilidade, sugerindo que a complexidade do modelo impacta a estabilidade dos resultados. O Random Forest mostrou-se robusto, com resultados concentrados em regiões de alto desempenho, enquanto o SVM apresentou ampla variabilidade, especialmente em configurações de *kernel* polinomial e RBF.


Gráfico 7 — Índice Kappa dos algoritmos de redes neurais e Naïve Bayes



Fonte: elaboração própria.

Notas: MLP: Multi-Layer Perceptron; J48: árvore de decisão J48.

Gráfico 8 — Índice Kappa dos algoritmos Random Forest e Random Tree



Fonte: elaboração própria.


Notas: RF: Random Forest.

Gustavo Garbino / PMPA



Assembleia do Orçamento Participativo (OP) de Porto Alegre na região da Restinga em agosto de 2025

Gráfico 9 — Índice Kappa do algoritmo SVM (1 a 9)




Fonte: elaboração própria.

Nota: SVM 1: C:1.0 - RBF: 0.01 - Grau: 2; SVM 2: C:1.0 - RBF: 0.01 - Grau: 3; SVM 3: C:0.1 - RBF: 0.01 - Grau: 2; SVM 4: C:0.1 - RBF: 0.01 - Grau: 3; SVM 5: C:0.01 - RBF: 0.01 - Grau: 3; SVM 6: C:0.01 - RBF: 0.01 - Grau: 2; SVM 7: C:0.01 - RBF: 0.25 - Grau: 2; SVM 8: C:0.1 - RBF:0.25 - Grau: 2; SVM 9: C:1.0 - RBF: 0.25 - Grau: 2.



“Ferramentas tecnológicas podem aprimorar a gestão orçamentária, fortalecer a accountability e otimizar a alocação de recursos”

Gráfico 10 — Índice Kappa do algoritmo SVM (10 a 18)



Fonte: elaboração própria.

Nota: SVM 10: C:1.0 - RBF: 0.25 - Grau: 3; SVM 11: C:0.1 - RBF: 0.25 - Grau: 3; SVM 12: C:0.01 - RBF: 0.25 - Grau: 3; SVM 13: C:0.01 - RBF: 0.5 - Grau: 3; SVM 14: C:0.1 - RBF: 0.5 - Grau: 3; SVM 15: C:1.0 - RBF: 0.5 - Grau: 3; SVM 16: C:1.0 - RBF: 0.5 - Grau: 2; SVM 17: C:0.1 - RBF: 0.5 - Grau: 2; SVM 18: C:0.01 - RBF: 0.5 - Grau: 2.

O índice Kappa (ou coeficiente Kappa) foi utilizado para medir o quão confiáveis são os modelos testados neste estudo. Os resultados dessa métrica são amplamente utilizados para medir a concordância entre previsões e valores reais, ajustando-os pela concordância

O diálogo entre tecnologia, gestão pública e participação social fortalece não apenas a eficiência técnica do orçamento, mas também seu caráter democrático e transformador, promovendo maior equidade na alocação de recursos e otimizando o impacto das decisões governamentais

ao acaso. Ou seja, após a execução dos modelos para a classificação, é necessário comparar o que o modelo previu com o que realmente aconteceu.

O índice Kappa fornece um número que indica o nível de semelhança entre a previsão do modelo e a realidade observada. A diferença dele em relação a outras métricas mais simples, como a acurácia (porcentagem de acertos), é que, muitas vezes, outro modelo pode acertar uma parte dos resultados puramente por coincidência (ao acaso), ao passo que a estatística Kappa “desconta” esses acertos aleatórios do resultado final, fornecendo uma medida de concordância mais rigorosa e realista.

No contexto deste estudo, essa estatística permitiu avaliar a confiabilidade dos modelos testados. O Naïve Bayes obteve o maior valor de Kappa (0,933), destacando-se pela alta precisão na classificação dos gastos. Esse desempenho se deve à sua capacidade de lidar com suposições de independência condicional entre variáveis, além de ser computacionalmente eficiente, facilitando sua aplicação em grandes volumes de dados.

Os modelos Random Forest também apresentaram desempenho consistente, com Kappa entre 0,922 e 0,925, especialmente nas configurações com 100, 150 e 200 árvores. Embora eficaz na captura de padrões, seu desempenho inferior ao Naïve Bayes pode estar relacionado à sensibilidade na escolha de hiperparâmetros. O BayesNet (Kappa 0,921) mostrou-se alternativa viável em cenários que exigem modelagem explícita das relações probabilísticas. O SVM obteve Kappa inferior (0,136 a 0,526), indicando dificuldades na captura de padrões nos dados utilizados. A necessidade de ajuste criterioso de hiperparâmetros pode ter comprometido seu desempenho.

A seleção do melhor classificador baseou-se na análise do índice Kappa e da área sob a curva ROC. O Naïve Bayes apresentou o maior Kappa (0,933) e o menor desvio-padrão (0,0176), além de um alto desempenho na área ROC (0,992), reforçando sua confiabilidade. Já o Random Forest obteve resultados próximos, mas com maior variação nos indicadores. Modelos baseados em SVM e MLP demonstraram inconsistências, o que compromete sua aplicabilidade em cenários que exigem estabilidade. Assim, o Naïve Bayes foi selecionado como o modelo mais adequado para classificar os gastos médios de internação, devido ao alto índice Kappa e à precisão na distinção entre classes.



Unidades de Pronto Atendimento (UPAs) da Rocinha (esq.) no Rio de Janeiro e de Santa Cruz do Sul (RS)

6.3.2. NAÏVE BAYES

O Naïve Bayes demonstrou excelente desempenho no conjunto de teste (tabela 4), com acurácia de 93,079%, índice Kappa de 0,916, sensibilidade de 0,931, especificidade de 0,987 e área ROC de 0,993. Esses resultados indicam que o modelo não apenas classifica com alta precisão, mas também minimiza falsos positivos e falsos negativos, sendo altamente eficiente para o objetivo proposto. O conjunto de teste foi constituído de 354 instâncias.

Tabela 4 — Resultados do classificador Naïve Bayes

Conjunto	Acurácia	Kappa	Sensibilidade	Especificidade	Área ROC
Teste	93,079	0,916	0,931	0,987	0,993

Fonte: elaboração própria.

Além disso, a simplicidade computacional do Naïve Bayes o torna uma escolha estratégica para classificações rápidas em bases de dados extensas, como é o caso das informações oriundas do Datasus. A capacidade de trabalhar com dados categóricos e numéricos reforça sua versatilidade na análise de gastos hospitalares, contribuindo diretamente para a elaboração de orçamentos inteligentes.

6.4. ORÇAMENTO INTELIGENTE: BENEFÍCIOS PARA A GESTÃO PÚBLICA

Os resultados confirmam a eficácia do aprendizado de máquina na classificação dos gastos municipais com AIH, destacando o Naïve Bayes como ferramenta precisa para identificar padrões e categorizar despesas. Esse modelo facilita a compreensão dos investimentos, permitindo aos gestores avaliar os resultados dos programas governamentais de forma objetiva.

O MLP, por sua vez, aprimora a projeção orçamentária ao prever gastos médios de internação com alta precisão. Essa abordagem possibilita a identificação antecipada de necessidades financeiras e o direcionamento de recursos de maneira otimizada. A comparação entre valores projetados e executados auxilia na detecção de ineficiências, orientando gestores para ajustes estratégicos.

A implementação de orçamentos inteligentes baseados em aprendizado de máquina fortalece a transparência, eficiência e equidade na alocação de recursos, ampliando a confiança da sociedade na gestão da saúde pública.

6.5. LIMITAÇÕES DO ESTUDO

Esta pesquisa utilizou exclusivamente dados assistenciais do SUS (AIH), descartando a inclusão de atributos adicionais que poderiam aprimorar a predição. Além disso, o estudo se restringiu ao período de 2022 a 2024, conforme informações do Tabnet-Datusus. Embora essas limitações não comprometam a definição do orçamento inteligente, futuras análises devem integrar bases de dados mais abrangentes e considerar variáveis adicionais para ampliar a precisão da modelagem e a eficácia na gestão da assistência hospitalar no SUS.

7. CONCLUSÃO

Este estudo propôs o conceito de orçamento inteligente, que aplica o aprendizado de máquina à gestão pública para prever e classificar gastos municipais com Assistência de Internação Hospitalar (AIH). A aplicação de algoritmos como Naïve Bayes e Multi-Layer Perceptron (MLP) demonstrou melhorias significativas na eficiência orçamentária, fornecendo subsídios objetivos para decisões informadas. O Naïve Bayes destacou-se na classificação dos gastos, enquanto o MLP apresentou maior precisão preditiva, reduzindo erros e otimizando a alocação de recursos hospitalares.

O orçamento inteligente supera limitações de modelos tradicionais, como o orçamento-programa, o base zero e o incremental, que frequentemente perpetuam ineficiências ou demandam processos burocráticos. Ao incorporar análises automatizadas e baseadas em evidências, ele oferece maior flexibilidade e adaptação às realidades fiscais locais, promovendo transparência, eficiência e redução de desperdícios. Essa abordagem contribui diretamente para a qualidade dos serviços de saúde prestados à população.

Além dos avanços proporcionados pelo orçamento inteligente, é fundamental destacar a importância da participação popular por meio das entidades da sociedade civil organizada e movimentos sociais e populares na definição das demandas orçamentárias. Essa participação ativa, exercida principalmente por meio de conselhos e instâncias democráticas, permite que as prioridades locais sejam incorporadas ao planejamento, complementando o piso orçamentário previsto pelo método de orçamento inteligente. Ao integrar a perspectiva da população diretamente afetada pelas políticas públicas, o processo orçamentário torna-se mais inclusivo, transparente e alinhado com as necessidades reais da sociedade. O diálogo entre tecnologia, gestão pública e participação social fortalece não apenas a eficiência técnica do orçamento, mas também seu caráter democrático e transformador, promovendo maior equidade na alocação de recursos e otimizando o impacto das decisões governamentais.

Além dos ganhos operacionais, o orçamento inteligente reforça o papel estratégico do Estado na gestão de recursos públicos. Contraindo-se a narrativas neoliberais, que defendem a redução do Estado, essa ferramenta demonstra como a tecnologia pode fortalecer a capacidade governamental de planejar e investir de forma inclusiva e democrática. A modernização orçamentária por meio da inteligência artificial não apenas maximiza a eficiência dos gastos em saúde, mas também consolida um modelo equitativo de gestão, priorizando o fortalecimento do SUS e o interesse social.

Como sugestão para futuras pesquisas, recomenda-se integrar bases de dados adicionais do SUS e outras fontes de informações socioeconômicas para avaliar cenários, padrões de gastos e seus impactos na economia e na sociedade.

* Doutorando em Engenharia da Computação pela Universidade de Pernambuco (UPE). Mestre em Ciências Contábeis pela Universidade Federal de Pernambuco (UFPE). Servidor técnico-administrativo e pesquisador do Departamento de Engenharia Biomédica da UFPE.

** Doutorando em Engenharia da Computação pela UPE. Mestre em Economia pela Universidade Federal de Sergipe (UFS). Gerente da URB Recife.

*** Doutor em Sociologia pela UFPE. Pesquisador do Departamento de Engenharia Biomédica da UFPE.

**** Mestrando em Engenharia Biomédica pela UFPE. Bacharel em Análise e Desenvolvimento de Sistemas pela Uninassau.

***** Doutor em Educação pela UFPE. Professor do Departamento de Ciências Farmacêuticas da UFPE.

***** Doutor em Engenharia Elétrica pela Universidade Federal de Campina Grande (UFCG). Professor associado do Departamento de Engenharia Biomédica da UFPE. Bolsista de Produtividade de Desenvolvimento Tecnológico e Extensão Inovadora do CNPq, nível 2.

► Texto recebido em 9 de fevereiro de 2025; aprovado em 18 de agosto de 2025.

ABREU, Cilair Rodrigues de; CÂMARA, Leonor Moreira. O orçamento público como instrumento de ação governamental: uma análise de suas redefinições no contexto da formulação de políticas públicas de infraestrutura. **Revista de Administração Pública**, v. 49, n. 1, p. 73-90, jan.-mar. 2015. DOI: <<https://doi.org/10.1590/0034-76121776>>.

ALBUQUERQUE, Mariana Vercesi de et al. Desigualdades regionais na saúde: mudanças observadas no Brasil de 2000 a 2016. **Ciência & Saúde Coletiva**, v. 22, p. 1055-1064, abr. 2017. DOI: <<https://doi.org/10.1590/1413-81232017224.26862016>>.

ANESSI-PESSINA, Eugenio et al. Public sector budgeting: a European review of accounting and public management journals. **Accounting, Auditing & Accountability Journal**, v. 29, n. 3, p. 491-519, 2016. DOI: <<https://doi.org/10.1108/AAAJ-11-2013-1532>>.

AZEVEDO, Ricardo Rocha de et al. Participatory budgeting and budget dynamics in the public sector. **Revista de Contabilidade e Organizações**, v. 16, 2022. Disponível em: <www.redalyc.org/journal/2352/235272781008/235272781008.pdf>. Acesso em: 23 dez. 2025.

BEZERRA FILHO, João Eudes. **Orçamento aplicado ao setor público**: abordagem simples e objetiva. 2. ed. São Paulo: Atlas, 2013.

BRASIL. Constituição (1988). **Constituição da República Federativa do Brasil**. Brasília: Senado Federal, 1988.

_____. Ministério da Saúde. **Financiamento da Média e Alta Complexidades** — MAC. Brasília: Ministério da Saúde, nov. 2022. Disponível em: <www.gov.br/saude/pt-br/aceso-a-informacao/gestao-do-sus/progrmaacao-regulacao-controle-e-financiamento-da-mac/financiamento-da-media-e-alta-complexidades-mac>. Acesso em: 23 dez. 2025.

CASTRO, Leandro Nunes de; FERRARI, Daniel Gomes. **Introdução à mineração de dados**: conceitos básicos, algoritmos e aplicações. São Paulo: Saraiva Educação, 2016.

COSTA, Alexandre Marino; MORITZ, Gilberto de Oliveira; MACHADO, Filipe Menezes Vasconcellos. Contribuições do Orçamento Base Zero (OBZ) no planejamento e controle de resultados em organizações empresariais. **Revista Contemporânea de Contabilidade**, v. 4, n. 8, p. 85-98, 2007. Disponível em: <www.redalyc.org/pdf/762/76240806.pdf>. Acesso em: 23 dez. 2025.

COUTO, Renato Camargos et al. Development of a machine learning model to estimate length of stay in coronary artery bypass grafting. **Revista de Saúde Pública**, v. 58, p. 41, 2024. DOI: <<https://doi.org/10.11606/s1518-8787.2024058006161>>.

DATASUS. **Tabnet**. Brasília: Ministério da Saúde, 2019. Disponível em: <<https://datasus.saude.gov.br/informacoes-de-saude-tabnet>>. Acesso em: 23 dez. 2025.

GRUS, Joel. **Data science do zero**. Rio de Janeiro: Alta Books, 2016.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting**: principles and practice. 3. ed. Melbourne: Monash University, 2018.

KIMURA, Amanda Evangelista et al. Gastos por internações hospitalares por condições sensíveis à atenção básica relacionadas ao sexo feminino e masculino no estado do Paraná de 2010 a 2021. **Brazilian Journal of Health Review**, v. 6, n. 3, p. 9369-9385, 2023. DOI: <<https://doi.org/10.34119/bjhrv6n3-078>>.

KREUZBERG, Fernanda; BECK, Franciele; LAVARDA, Carlos Eduardo Facin. Orçamento base zero: um estudo de caso sob a perspectiva da teoria institucional. **Contabilidade Vista & Revista**, v. 27, n. 3, p. 32-60, 2016. Disponível em: <www.redalyc.org/pdf/1970/197047686003.pdf>. Acesso em: 23 dez. 2025.

LIMA, Maria Luiza et al. Análise do desempenho do orçamento base zero como ferramenta de orçamentação em uma empresa de economia mista. **Revista de Gestão e Secretariado**, v. 14, n. 4, p. 6620-6635, 2023. Disponível em: <<https://ojs.revistagesec.org.br/secretariado/article/view/2069>>. Acesso em: 23 dez. 2025.

LOPES, Alex de Araujo; FREIRE, Isa Maria. Orçamento participativo: uma abordagem na perspectiva da ciência da informação. **Transinformação**, v. 24, p. 19-25, 2012.

OCKÉ-REIS, Carlos Octávio (Org.). **SUS**: avaliação da eficiência do gasto público em saúde. Brasília: Repositório do Conhecimento do Ipea, 2023. Disponível em: <<https://repositorio.ipea.gov.br/handle/11058/12029>>. Acesso em: 23 dez. 2025.

PROVOST, Foster; FAWCETT, Tom. **Data science para negócios**. Rio de Janeiro: Alta Books, 2016.

RICCIARDI, Carlo et al. Evaluation of different machine learning algorithms for predicting the length of stay in the emergency departments: a single-centre study. **Frontiers in Digital Health**, v. 5, p. 1323849, 2024. DOI: <<https://doi.org/10.3389/fdgth.2023.1323849>>.

SANTOS, Maria Angelica Borges dos et al. **A remuneração de internações e a tabela de procedimentos do SUS**: uma análise a partir do SIH e SIGTAP. Brasília: Ipea, 2023. (Texto para Discussão n. 2925). Disponível em: <www.econstor.eu/handle/10419/285047>. Acesso em: 23 dez. 2025.

SANTOS, Thadeu Borges Souza et al. Gestão hospitalar no Sistema Único de Saúde: problemáticas de estu-

dos em política, planejamento e gestão em saúde. **Ciência & Saúde Coletiva**, v. 25, p. 3597-3609, 2020. DOI: <<https://doi.org/10.1590/1413-81232020259.33962018>>.

SANTSCHI, Dominic *et al.* Artificial intelligence to improve public budgeting. **ICIS**, December 2024. Disponível em: <https://aisel.aisnet.org/icis2024/iot_smartcity/iot_smartcity/1>. Acesso em: 23 dez. 2025.

Referências bibliográficas