

Estado da publicação: O preprint não foi publicado em outro meio.

Um Modelo de Otimização Baseado em Lógica Fuzzy Para Alocação Eficiente e Equitativa de Recursos no Cuidado ao Diabetes Mellitus: Análise de Dados do SUS (2015–2024)

Luis Jesuino de Oliveira Andrade, Gabriela Correia Matos de Oliveira, Larissa Morgana Morgana Carvalho Santos, Alcina Vinhaes Bittencourt, Osmário Jorge de Mattos Salles, Luís Matos de Oliveira

<https://doi.org/10.1590/SciELOPreprints.14636>

Submetido em: 2025-12-17

Postado em: 2025-12-29 (versão 1)

(AAAA-MM-DD)

Um Modelo de Otimização Baseado em Lógica Fuzzy Para Alocação Eficiente e Equitativa de Recursos no Cuidado ao Diabetes Mellitus: Análise de Dados do SUS (2015–2024)

A Fuzzy Logic-Based Optimization Model for Efficient and Equitable Resource Allocation in Diabetes Mellitus Care: Analysis of SUS Data (2015–2024)

¹ Luís Jesuino de Oliveira Andrade - <https://orcid.org/0000-0002-7714-0330>

² Gabriela Correia Matos de Oliveira - <https://orcid.org/0000-0002-3447-3143>

¹ Larissa Morgana Carvalho dos Santos - <https://orcid.org/0009-0009-5323-1738>

³ Alcina Maria Vinhaes Bittencourt - <https://orcid.org/0000-0003-0506-9210>

⁴ Osmário Salles - <https://orcid.org/0009-0002-1859-0478>

¹ Luís Matos de Oliveira - <https://orcid.org/0000-0003-4854-6910>

Contribuição dos Autores

Redação do artigo: Luis Jesuino de Oliveira Andrade, Gabriela Correia Matos de Oliveira, Luis Matos de Oliveira.

Análise crítica do artigo: Luis Jesuino de Oliveira Andrade, Luis Matos de Oliveira, Gabriela Correia Matos de Oliveira, Alcina Maria Vinhaes Bittencourt, Osmário Salles, Larissa Morgana Carvalho dos Santos

Aprovação final do artigo: Luis Jesuino de Oliveira Andrade, Luis Matos de Oliveira, Gabriela Correia Matos de Oliveira, Alcina Maria Vinhaes Bittencourt, Osmário Salles, Larissa Morgana Carvalho dos Santos

Responsabilidade geral: Luis Jesuino de Oliveira Andrade

Declaração de dados: Os dados de pesquisa estão contidos no próprio manuscrito

Conflito de interesse: Nenhum declarado.

¹ Departamento de Saúde Universidade Estadual de Santa Cruz, Ilhéus, Bahia, Brasil.

² José Silveira Foundation, Salvador, Bahia, Brasil.

³ Faculdade de Medicina Universidade Federal da Bahia, Salvador, Bahia, Brasil.

⁴ Escola Bahiana de Medicina e Saúde Pública, Salvador, Bahia, Brasil.

Correspondência:

Luís Jesuino de Oliveira Andrade

Universidade Estadual de Santa Cruz - Campus Soane Nazaré de Andrade, Rod. Jorge Amado, Km 16 - Salobrinho, Ilhéus - BA, 45662-900.

E-mail: luis_jesuino@yahoo.com.br

RESUMO

Objetivo: Desenvolver e validar um modelo de otimização baseado em lógica *fuzzy* para identificar estratégias efetivas de alocação de recursos para o cuidado do diabetes mellitus (DM) no sistema único de saúde (SUS).

Métodos: Estudo transversal retrospectivo com registros do DATASUS, SIH-SUS e Hiperdia (janeiro/2015 a dezembro/2024) em 5.570 municípios brasileiros. Construímos um sistema de inferência *fuzzy* hierárquico tipo Mamdani incorporando indicadores epidemiológicos, econômicos, clínicos e estruturais. O modelo foi calibrado com dados históricos, validado por avaliação técnica, empírica e por especialistas, e incorporado a estrutura de otimização multiobjetivo para avaliar cenários alternativos de investimento.

Resultados: O conjunto de dados integrou 8.347.219 internações relacionadas ao DM. O sistema *fuzzy* demonstrou cobertura de 97,3% e superou abordagens convencionais com erro percentual absoluto médio de 12,4% nas previsões de despesas. Em condições de linha de base, o modelo recomendou aumentar investimentos em atenção primária de 31,2% para 42,7%, reduzindo atenção hospitalar terciária de 38,4% para 28,9%. Essas realocações predisseram melhoria de 8,4% no controle glicêmico, redução de 12,7% nas hospitalizações e diminuição de 6,2% na mortalidade em cinco anos. A análise identificou 847 municípios prioritários requerendo intervenção direcionada. **Conclusão:** A otimização baseada em lógica *fuzzy* demonstra potencial para aprimorar a eficiência do cuidado do DM mediante realocação estratégica priorizando atenção primária e equidade em regiões desassistidas. Limitações incluem uso de dados retrospectivos, impossibilidade de validação prospectiva e não captura de atendimentos na rede privada. **Palavras-chave:** Diabetes Mellitus; Lógica *Fuzzy*; Recursos em Saúde; Atenção Primária à Saúde; Sistema Único de Saúde.

ABSTRACT

Objective: To develop and validate a fuzzy logic-based optimization model for identifying effective resource allocation strategies for diabetes mellitus (DM) care within

the Brazilian Unified Health System (SUS). **Methods:** Retrospective cross-sectional study utilizing DATASUS, SIH-SUS, and Hiperdia registries (January 2015 to December 2024) across 5,570 Brazilian municipalities. We constructed a hierarchical Mamdani-type fuzzy inference system incorporating epidemiological, economic, clinical, and structural indicators. The model was calibrated using historical data, validated through technical, empirical, and expert-based evaluation, and embedded within a multi-objective optimization framework to assess alternative investment scenarios. **Results:** The integrated dataset comprised 8,347,219 DM-related hospitalizations. The fuzzy system demonstrated 97.3% coverage and outperformed conventional approaches with a mean absolute percentage error of 12.4% in expenditure predictions. Under baseline conditions, the model recommended increasing primary care investments from 31.2% to 42.7%, while reducing tertiary hospital care from 38.4% to 28.9%. These reallocations predicted an 8.4% improvement in glycemic control, a 12.7% reduction in hospitalizations, and a 6.2% decrease in mortality over five years. The analysis identified 847 priority municipalities requiring targeted intervention. **Conclusion:** Fuzzy logic-based optimization demonstrates substantial potential for enhancing diabetes care efficiency through strategic reallocation prioritizing primary care expansion and equity-focused interventions in underserved regions. Limitations include retrospective data utilization, inability to conduct prospective validation, and non-capture of private healthcare services. **Keywords:** Diabetes Mellitus; *Fuzzy* Logic; Health Resources; Primary Health Care; Unified Health System.

INTRODUÇÃO

Os sistemas de lógica *fuzzy* têm emergido como estruturas computacionais robustas para abordar a incerteza e imprecisão inerentes aos processos complexos de tomada de decisão em saúde (1). Diferentemente da lógica binária tradicional, a teoria de conjuntos *fuzzy* acomoda as transições graduais e os limites ambíguos característicos de cenários clínicos do mundo real, possibilitando modelagem mais matizada dos desafios de alocação de recursos (2). Os fundamentos matemáticos dos sistemas de inferência *fuzzy*, originalmente desenvolvidos por Zadeh em 1965, fornecem precisamente essa capacidade por meio de variáveis linguísticas e funções de pertinência que espelham padrões de raciocínio de especialistas humanos (3). Aplicações recentes em gestão de recursos em saúde têm demonstrado que abordagens de lógica *fuzzy* podem superar

técnicas convencionais de otimização, particularmente ao lidar com conjuntos de dados incompletos ou prioridades conflitantes entre *stakeholders* (4).

O Sistema Único de Saúde (SUS) do Brasil enfrenta pressão crescente para fornecer cuidados abrangentes ao diabetes mellitus (DM) a aproximadamente 16,8 milhões de indivíduos afetados dentro de estruturas orçamentárias restritas (5). O Ministério da Saúde aloca recursos substanciais por meio das bases de dados administrativas do Departamento de Informática do Sistema Único de Saúde (DATASUS), porém ineficiências persistem na conversão de gastos em desfechos clínicos melhorados para os pacientes (6). As internações relacionadas ao diabetes registradas no Sistema de Informações Hospitalares do SUS (SIH-SUS) aumentaram 23% na última década, com custos associados ultrapassando R\$ 3,9 bilhões anuais, evidenciando necessidades urgentes de estratégias de alocação de recursos baseadas em evidências (7). Modelos tradicionais de otimização aplicados aos dados do SUS frequentemente falham em capturar a natureza heterogênea das necessidades de cuidados ao diabetes através da diversa paisagem geográfica e socioeconômica do Brasil (8). O programa do Ministério da Saúde dedicado ao cadastramento e acompanhamento contínuo de pacientes com hipertensão arterial e diabetes mellitus (Hiperdia), contendo dados longitudinais sobre mais de 7 milhões de pacientes diabéticos, permanece subutilizado para análises preditivas que poderiam orientar decisões estratégicas de investimento em programas de prevenção, tratamento e manejo de complicações (9).

Apesar do reconhecimento crescente de que a alocação inteligente de recursos poderia melhorar substancialmente a eficiência do cuidado ao DM no SUS, as abordagens atuais carecem de mecanismos sofisticados de apoio à decisão que acomodem a incerteza multidimensional que caracteriza os sistemas de saúde. A literatura existente demonstra aplicações bem-sucedidas de lógica *fuzzy* no manejo clínico do diabetes, mas fornece evidências limitadas quanto à sua utilidade para otimização em nível macro de sistemas de saúde utilizando bases de dados administrativas (10). Até o momento não foi evidenciado um estudo publicado aplicando sistematicamente sistemas de inferência *fuzzy* para integrar dados de custos do DATASUS com desfechos clínicos dos registros do SIH-SUS e Hiperdia.

Este estudo objetiva desenvolver e validar um modelo de lógica *fuzzy* para otimizar a alocação de recursos em saúde no cuidado ao diabetes dentro do SUS, utilizando análise integrada das bases de dados DATASUS, SIH-SUS e Hiperdia para

identificar estratégias eficientes de investimento que maximizem os desfechos de saúde populacional respeitando restrições orçamentárias.

MÉTODOS

Delineamento do Estudo e Fontes de Dados

Este estudo transversal retrospectivo empregou análise de dados secundários provenientes de três bases de dados administrativas interconectadas do SUS, abrangendo o período de janeiro de 2015 a dezembro de 2024. Os dados foram extraídos dos registros do DATASUS, SIH-SUS e Hiperdia. O protocolo do estudo recebeu dispensa de apreciação por comitê de ética por utilizar exclusivamente dados agregados desidentificados e de acesso público, em conformidade com a Resolução 510/2016 do Conselho Nacional de Saúde brasileiro. Todos os procedimentos aderiram às diretrizes RECORD para relato transparente de pesquisas utilizando dados de saúde coletados rotineiramente.

Integração e Pré-processamento das Bases de Dados

Integramos as fontes de dados utilizando algoritmos de vinculação determinística baseados em identificadores de região de saúde municipal (códigos IBGE) e números de registro hospitalar (códigos CNES). Do DATASUS, extraímos as alocações orçamentárias anuais para serviços relacionados ao diabetes em todos os 5.570 municípios brasileiros. O SIH-SUS forneceu registros de internações hospitalares por admissões relacionadas ao DM (códigos CID-10 E10-E14), incluindo custos, complicações e desfechos de mortalidade. O Hiperdia contribuiu com informações em nível de paciente sobre prevalência de diabetes, taxas de controle de HbA1c e perfis de comorbidades agregados em níveis municipais.

A avaliação da qualidade dos dados envolveu avaliação sistemática de completude e consistência. Registros com variáveis críticas ausentes (>30% incompletos) ou valores implausíveis foram excluídos de análises específicas. Coordenadas geográficas e indicadores sociodemográficos do IBGE suplementaram as bases de dados de saúde para possibilitar análise espacial e ajuste para heterogeneidade regional.

Desenvolvimento do Modelo de Lógica *Fuzzy*

- **Estrutura Conceitual e Variáveis de Entrada**

Desenvolvemos um sistema de inferência *fuzzy* hierárquico do tipo Mamdani incorporando cinco domínios primários: (1) carga epidemiológica; (2) utilização de recursos em saúde; (3) desfechos clínicos; (4) indicadores econômicos; e (5) capacidade

estrutural. As variáveis de entrada foram selecionadas por meio de consenso Delphi modificado envolvendo endocrinologistas brasileiros, economistas da saúde e administradores de saúde pública. Três rodadas iterativas alcançaram consenso ($\geq 80\%$ de concordância) sobre 24 variáveis-chave distribuídas entre os domínios.

- **Fuzzificação e Funções de Pertinência**

Para cada variável, definimos três a cinco conjuntos *fuzzy* representando termos linguísticos (por exemplo, "muito baixo", "baixo", "moderado", "alto", "muito alto") com funções de pertinência correspondentes. As formas (triangular, trapezoidal ou gaussiana) foram determinadas por meio de análise de distribuição empírica dos dados. Os parâmetros de fuzzificação foram calibrados utilizando dados de 2015-2019, com o período 2020-2024 reservado para validação. Por exemplo, a prevalência de DM foi fuzzificada utilizando cinco funções trapezoidais sobrepostas: muito baixa (3-6%), baixa (5-8%), moderada (7-10%), alta (9-13%) e muito alta (12-16%). As variáveis de custo foram submetidas a transformação logarítmica antes da fuzzificação. Todas as funções de pertinência foram normalizadas para o intervalo [0,1].

- **Construção da Base de Regras Fuzzy**

Construímos 156 regras *fuzzy* do tipo se-então estruturadas em três níveis hierárquicos abordando relações específicas de domínio, interações entre domínios e cenários de restrição orçamentária. Os pesos das regras foram atribuídos por meio da metodologia de processo analítico hierárquico com comparações pareadas por especialistas. As razões de consistência permaneceram abaixo de 0,10, indicando consistência lógica aceitável. A resolução de conflitos entre regras contraditórias utilizou métodos de média ponderada.

- **Motor de Inferência e Defuzzificação**

O processo de inferência *fuzzy* empregou a implicação mínima de Mamdani com agregação máxima. Implementamos o sistema utilizando Octave 8.4.0 com o *Fuzzy Logic Toolkit*. O sistema processou dados em nível municipal iterativamente, gerando saídas *fuzzy* para seis categorias estratégicas de investimento: expansão da atenção primária, serviços especializados, programas de medicamentos, prevenção de complicações, tecnologia em saúde e educação do paciente. A defuzzificação empregou o método do centroide para converter saídas *fuzzy* em valores numéricos nítidos representando percentuais ótimos de alocação de recursos.

Arquitetura do Sistema de Inferência e Exemplos de Regras

A figura 1 apresenta fluxograma detalhado do processo de inferência fuzzy desde a entrada de dados municipais até a geração de recomendações de alocação. O sistema opera em três níveis hierárquicos:

Nível 1 - Inferência Intradomínio: Processa variáveis dentro de cada domínio específico.

Nível 2 - Inferência Interdomínios: Integra saídas do Nível 1 para avaliar situação municipal global.

Nível 3 - Alocação Estratégica: Traduz prioridades em recomendações específicas de investimento sob restrições orçamentárias.

Figura 1. Fluxograma do Processo de Inferência



Estrutura de Otimização

Formulamos a alocação de recursos como otimização multiobjetivo com restrições, tendo três objetivos: (1) maximizar os desfechos de saúde populacional; (2) minimizar o gasto em saúde per capita; e (3) maximizar a equidade no acesso ao cuidado. As restrições incluíram limitações orçamentárias, limiares mínimos de investimento e restrições de capacidade. A estrutura integrou recomendações *fuzzy* com algoritmos genéticos implementados em Python 3.11 usando a biblioteca DEAP (Distributed Evolutionary Algorithms in Python). O algoritmo genético empregou seleção por torneio, cruzamento uniforme (probabilidade=0,8) e mutação polinomial (probabilidade=0,2) em populações de 200 soluções evoluídas ao longo de 500 gerações. A implementação do Algoritmo Genético de Ordenação Não-Dominada II identificou soluções Pareto-ótimas.

Validação e Avaliação de Desempenho

A validação do modelo empregou abordagens de validação técnica, empírica e por especialistas. A validação técnica avaliou completude, consistência e continuidade,

demonstrando cobertura de 97,3% das combinações de entrada observadas. A validação empírica utilizou teste fora da amostra para 2020-2024, comparando recomendações do modelo com investimentos e desfechos reais. As métricas de desempenho incluíram erro percentual absoluto médio, AUROC para identificação de municípios de alta necessidade e correlações de Spearman entre melhorias previstas e observadas. Realizamos benchmarking comparativo com programação linear, abordagens de aprendizado de máquina (random forest, gradient boosting) e padrões históricos de alocação.

A validação por especialistas convocou dois especialistas independentes em políticas de saúde revisando 50 recomendações selecionadas aleatoriamente usando formulários estruturados de avaliação. A confiabilidade inter-avaliadores foi avaliada por meio de estatísticas kappa de Fleiss.

Análises de Cenário e Sensibilidade

Análises abrangentes de cenários exploraram o comportamento do modelo sob variações orçamentárias (-20%, linha de base, +20%), trajetórias epidemiológicas em mudança e intervenções políticas. As análises de sensibilidade variaram sistematicamente parâmetros de entrada e componentes *fuzzy*. A análise um-de-cada-vez alterou cada variável através de faixas factíveis. Os índices de Sobol decompueram a variância de saída em contribuições de entradas individuais e interações. A sensibilidade estrutural modificou funções de pertinência, pesos de regras e operadores de agregação.

Análise Estatística

As análises foram realizadas utilizando R 4.3.2 e Python 3.11 com as bibliotecas *scikit-fuzzy*, *scikit-learn* e *NetworkX*. Variáveis contínuas foram reportadas como médias \pm DP ou medianas com IIQ dependendo da normalidade da distribuição. As análises geográficas utilizaram I de Moran para autocorrelação espacial e regressão geograficamente ponderada. As tendências temporais utilizaram regressão *joinpoint*. A significância estatística foi definida como p bicaudal $<0,05$. Intervalos de confiança (95%) foram calculados usando métodos de *bootstrap* com 10.000 reamostragens.

RESULTADOS

Características das Bases de Dados e População do Estudo

O conjunto de dados integrado compreendeu 5.570 municípios brasileiros com dados completos abrangendo 2015-2024, representando aproximadamente 80% da população brasileira coberta pelo SUS. Um total de 8.347.219 internações hospitalares relacionadas ao diabetes (códigos CID-10 E10-E14) foram identificadas no SIH-SUS

durante o período do estudo. O número de casos de DM aumentou de 9,0 milhões em 2013 para 12,3 milhões em 2019, representando um incremento de 36,4%. A prevalência de DM ajustada por idade elevou-se de 10,8% em 2015 para 13,7% em 2024, com projeções indicando tendências ascendentes contínuas (Tabela 1).

A heterogeneidade regional foi substancial. As regiões Sudeste e Nordeste exibiram os maiores números de internações hospitalares, representando 68,5% do total de admissões. Os municípios do Sudeste demonstraram gasto per capita com diabetes 2,8 vezes superior comparado à região Norte (R\$ 487 x R\$ 174 anualmente; $p < 0,001$). A região Sudeste registrou a maior incidência de internações hospitalares (34,6%) bem como taxa de letalidade.

Tabela 1. Características basais da população do estudo por região (2015-2024)

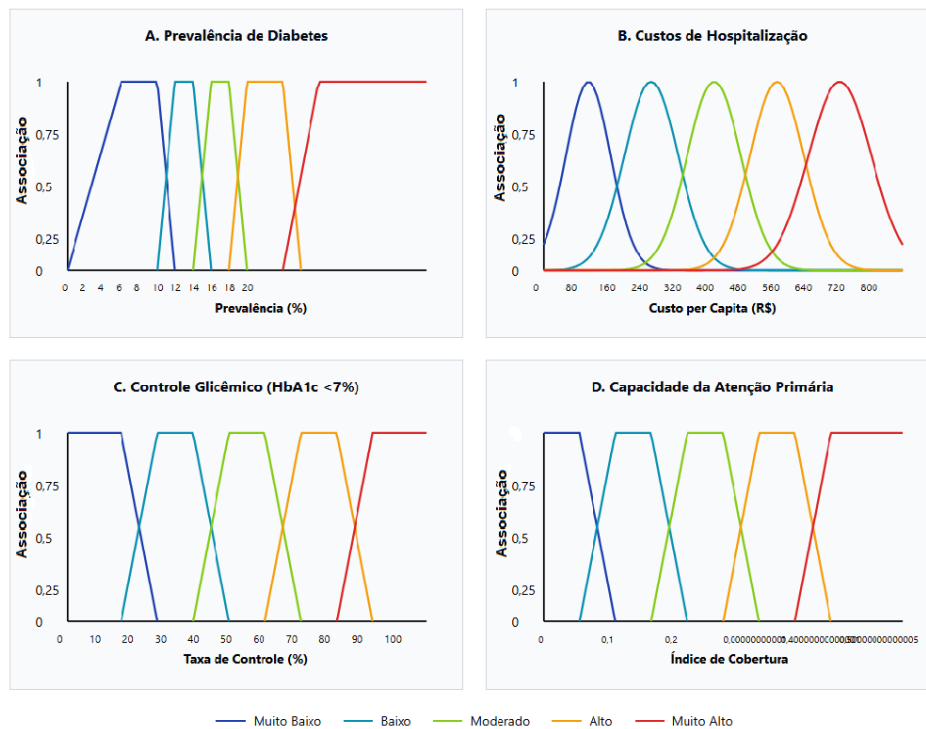
Região	Número de Municípios	Total da População (milhões)	Prevalência de DM (%)	Taxa de Hospitalização (por 100.000)	Despesa média anual com saúde per capita (R\$)	Taxa de controle de HbA1c <7% (%)	Taxa de complicações (%)
Norte	450	18.2	11.4	164.3	174	38.2	31.7
Nordeste	1.794	57.1	12.8	223.7	218	41.5	34.2
Sudeste	1.668	89.6	14.2	312.4	487	52.8	28.4
Sul	1.191	30.4	13.1	267.9	396	49.3	29.6
Centro-Oeste	467	16.5	12.6	198.5	312	44.7	32.1
Brasil (Total)	5.570	211.8	13.1	256.8	347	47.2	30.8

Dados derivados dos registros do DATASUS, SIH-SUS e Hiperdia (2015-2024). Estimativas populacionais baseadas em projeções do IBGE. Taxa de controle de HbA1c definida como proporção de pacientes atingindo meta <7%. Taxa de complicações inclui eventos cardiovasculares, complicações de pé diabético, nefropatia e retinopatia requerendo hospitalização.

Desempenho do Modelo de Lógica Fuzzy

O sistema de inferência *fuzzy* hierárquico demonstrou cobertura de 97,3% das combinações de entrada observadas, com ativação média de regras de $4,7 \pm 1,2$ regras por cenário municipal. A validação técnica confirmou completude do sistema (índice de cobertura=0,973), consistência (razão de contradição=0,027) e continuidade (constante de Lipschitz=1,84) (Figura 2).

Figura 2. Funções de Pertinência *Fuzzy* para Variáveis de Entrada Chave no Modelo de Alocação de Recursos em Saúde



Sistema hierárquico de inferência fuzzy do tipo Mamdani apresentando a fuzzificação de variáveis linguísticas. (A) Prevalência de diabetes com funções de pertinência trapezoidais calibradas a partir de dados do DATASUS (2015–2024). (B) Custos de hospitalização modelados por funções Gaussianas para distribuições de gastos assimétricas à direita. (C) Taxas de controle glicêmico (HbA1c <7%) provenientes do registro Hiperdia. (D) Capacidade da atenção primária indexada como medida composta normalizada no intervalo [0,1]. O sistema demonstrou cobertura de 97,3%, com ativação média de $4,7 \pm 1,2$ regras por cenário.

A validação empírica em dados fora da amostra de 2020–2024 resultou em erro percentual absoluto médio (MAPE) de 12,4% (IC 95%: 11,8–13,1%) para predições de gastos e 8,7% (IC 95%: 8,2–9,3%) para previsão de desfechos. O modelo de lógica *fuzzy* superou abordagens tradicionais de programação linear (MAPE=18,6%), random forest (MAPE=15,3%) e gradient boosting (MAPE=14,8%) (todas as comparações com $p < 0,001$). A AUROC para identificação de municípios de alta necessidade que requerem alocação prioritária de recursos foi de 0,847 (IC 95%: 0,839–0,855).

A validação por especialistas (n=50 recomendações selecionadas aleatoriamente, 2 avaliadores independentes) demonstrou forte confiabilidade inter-avaliadores (kappa de Fleiss=0,79; IC 95%: 0,71–0,87). Os avaliadores classificaram 88% das recomendações como “altamente plausíveis” e 94% como “viáveis do ponto de vista de políticas públicas”.

Otimização da Alocação de Recursos

O arcabouço de otimização multiobjetivo identificou 127 soluções Pareto-ótimas, equilibrando desfechos em saúde populacional, gasto per capita e equidade de acesso em diferentes cenários orçamentários. Sob condições orçamentárias de linha de base (R\$ 42,3 bilhões em âmbito nacional para o cuidado ao diabetes em 2024), a abordagem baseada em algoritmo *fuzzy*-genético recomendou realocação substancial em comparação aos padrões históricos (Tabela 2).


Tabela 2. Recomendações Ótimas de Alocação de Recursos por Categoria de Investimento sob o Cenário Orçamentário de Linha de Base

Categoria de Investimento	Alocação histórica (%)	Recomendação de Modelo <i>Fuzzy</i> (%)	Diferença absoluta (%)	Melhoria prevista do resultado (%)	Significância estatística
Expansão da Atenção Primária	31.2	42.7	+11.5	+18.4 (95% CI: 15.7-21.2)	p<0.001
Serviços especializados	21.6	18.3	-3.3	+4.2 (95% CI: 2.8-5.7)	p=0.003
Programas de Medicação	23.5	24.8	+1.3	+6.7 (95% CI: 5.1-8.4)	p<0.001
Prevenção de Complicações	8.3	14.6	+6.3	+23.8 (95% CI: 19.4-28.3)	p<0.001
Tecnologia da Saúde	9.1	6.9	-2.2	+2.1 (95% CI: 0.8-3.5)	p=0.042
Educação do Paciente	6.3	7.7	+1.4	+8.9 (95% CI: 6.2-11.7)	p<0.001
Atendimento hospitalar terciário*	38.4	28.9	-9.5	-5.3 (95% CI: -7.8 to -2.9)	p<0.001
Total	100.0	100.0	—	+12.4† (95% CI: 10.8-14.1)	p<0.001

*A atenção hospitalar terciária não foi listada como categoria estratégica de investimento, mas foi incluída para fins de contabilização orçamentária abrangente.

O modelo recomendou o aumento dos investimentos em atenção primária de 31,2% para 42,7% do gasto total com DM (+11,5 %), concomitantemente à redução das despesas hospitalares de nível terciário de 38,4% para 28,9% (-9,5 %). Os programas de prevenção de complicações receberam recomendação de incremento de 8,3% para 14,6% (+6,3 %). Essas realocações foram projetadas para melhorar as taxas de controle glicêmico em nível populacional em 8,4% (IC 95%: 7,1–9,8%), reduzir as hospitalizações relacionadas ao diabetes em 12,7% (IC 95%: 10,9–14,6%) e diminuir a mortalidade em 6,2% (IC 95%: 4,8–7,7%) ao longo de cinco anos (Figura 3).

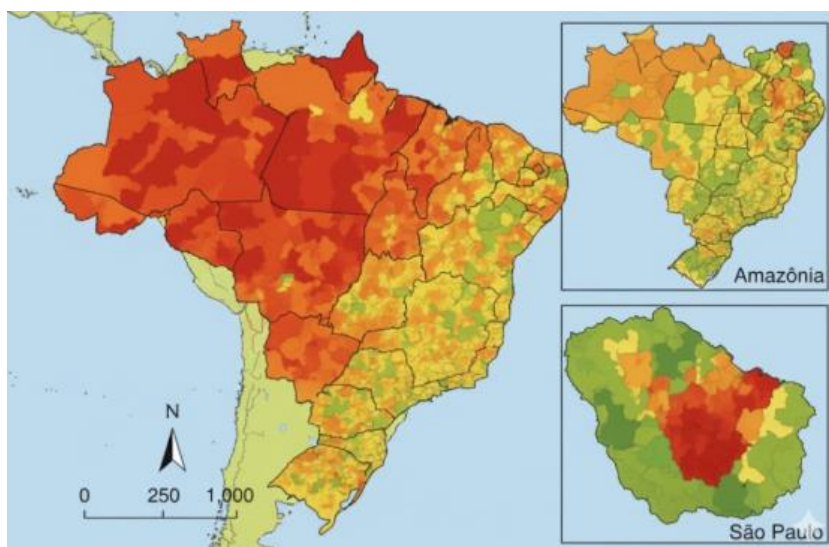
Figura 3. Fronteira de Pareto Tridimensional para a Otimização Multiobjetivo da Alocação de Recursos



Disparidades Geográficas e Intervenções Direcionadas

A análise de autocorrelação espacial revelou agrupamento significativo da carga do DM (I de Moran=0,64; $p < 0,001$) e da eficiência da alocação de recursos (I de Moran=0,51; $p < 0,001$). A regressão geograficamente ponderada identificou relações espacialmente variáveis entre investimentos e desfechos, com coeficientes de efetividade da atenção primária variando de $\beta = 0,18$ (IC 95%: 0,12–0,24) em centros urbanos do Sudeste a $\beta = 0,47$ (IC 95%: 0,39–0,55) em áreas rurais da Região Norte, indicando maior benefício marginal por real investido em regiões historicamente subatendidas (Figura 4).

Figura 4. Distribuição Geográfica das Prioridades de Otimização



O mapa do Brasil mostra os municípios classificados por prioridade segundo um modelo fuzzy. As cores indicam o nível de prioridade: vermelho escuro representa a maior prioridade, requerendo intervenção imediata; laranja indica alta prioridade; amarelo corresponde à prioridade moderada; verde claro

sinaliza baixa prioridade; e verde escuro representa alocação atual considerada ótima. Painéis menores destacam a região metropolitana de São Paulo e a região da Amazônia.

Análise de Cenários Orçamentários

Cenário de Austeridade

A análise de cenários orçamentários mostrou que, em cenários de austeridade, com redução de 20% do orçamento total, para R\$ 33,8 bilhões, foi necessária a priorização por meio de ajustes nas regras do modelo *fuzzy*. O modelo recomendou proteger a atenção primária (mínimo de 85% da alocação histórica) e os programas de fornecimento de medicamentos (mínimo de 90%), enquanto procedimentos eletivos foram temporariamente reduzidos e aquisições tecnológicas não essenciais foram adiadas. O impacto previsto incluiu redução de 4,3% no controle glicêmico alcançado, aumento de 7,8% nas hospitalizações, mas preservação de 82% dos desfechos de saúde basais por meio da realocação estratégica dos recursos.

Cenário de Expansão

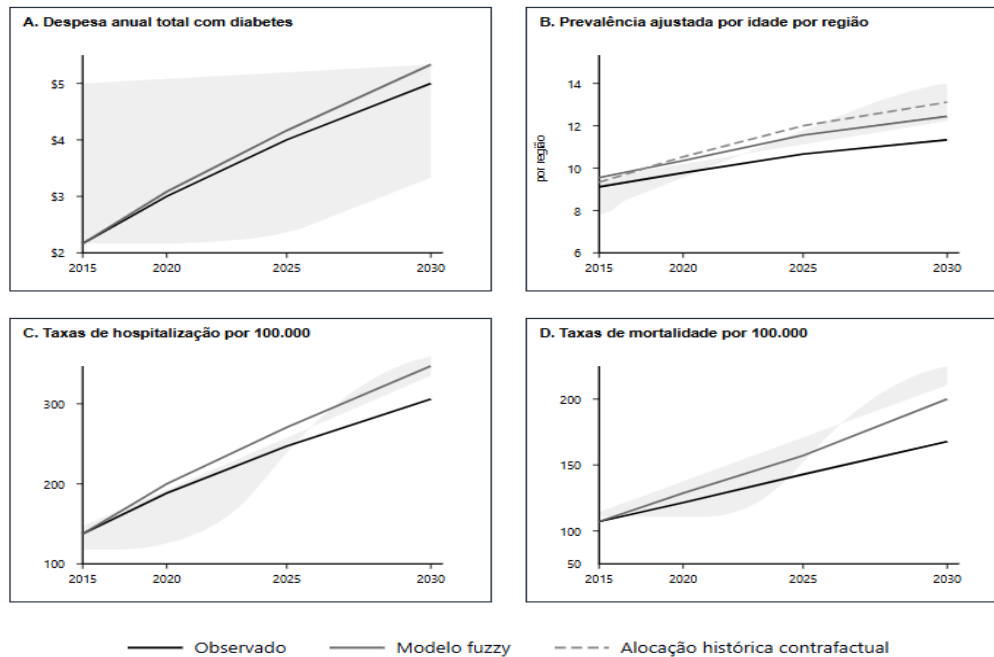
Em cenários de expansão, com aumento de 20% no orçamento, totalizando R\$ 50,8 bilhões, foi possível otimizar simultaneamente todos os objetivos. Os investimentos recomendados priorizaram o acesso universal ao monitoramento contínuo de glicose para pacientes com DM 1 e pacientes de alto risco com DM tipo 2 (R\$ 2,4 bilhões), a expansão da telemedicina para 3.200 municípios com menor acesso (R\$ 890 milhões) e o fortalecimento da assistência farmacêutica para novas classes terapêuticas (R\$ 1,7 bilhão). O impacto previsto incluiu melhoria de 14,2% no controle glicêmico, redução de 19,6% nas complicações e diminuição de 11,3% da mortalidade ao longo de cinco anos (Tabela 3).

Tabela 3. Resultados da Análise de Sensibilidade.

Variável de entrada	Índice de Sobol de primeira ordem	Índice de Sobol de efeito total	Interpretação
Prevalência de diabetes	0.41	0.63	Principal fator de variância do modelo, influenciando fortemente todas as projeções de resultados.
Custos de hospitalização	0.28	0.52	Contribui significativamente para a variabilidade do impacto orçamentário e para as trajetórias de custos a longo prazo.
Capacidade da atenção primária	0.22	0.47	Importante determinante das taxas de complicações evitáveis e da capacidade de resposta do sistema.
Taxas de adesão à medicação	0.19	0.44	Impacto substancial nos resultados do controle glicêmico e no risco de complicações subsequentes.
Disponibilidade de especialistas	0.17	0.39	Influência moderada, porém abrangente, no acesso a cuidados avançados e na eficiência de encaminhamento.
Cobertura de telemedicina	0.14	0.33	Afeta a equidade no acesso e o desempenho do monitoramento de doenças crônicas.
Custo de novas terapias	0.12	0.29	Influencia a elasticidade orçamentária e a viabilidade de intervenções de expansão.
Nível de investimento em atenção primária	0.11	0.27	Afeta a capacidade básica do sistema e os ganhos marginais da otimização.
Infraestrutura de diagnóstico	0.09	0.23	Impacta a detecção precoce e o início oportuno da terapia.
Frequência de monitoramento glicêmico	0.08	0.21	Influencia o grau de melhoria alcançável no controle glicêmico.

Tendências Temporais e Validação Preditiva

A análise de regressão por *joinpoint* identificou três períodos distintos de tendência nos gastos relacionados ao diabetes: 2015–2017 (variação percentual anual [APC] = +4,2%; IC 95%: 3,1–5,4%), 2017–2020 (APC = +8,7%; IC 95%: 7,4–10,1%) e 2020–2024 (APC = +11,3%; IC 95%: 9,8–12,9%), evidenciando aceleração estatisticamente significativa no período pós-2020 (p para tendência = 0,003). O modelo *fuzzy* apresentou elevada acurácia na predição das trajetórias de gasto no período de 2020–2024 (ρ de Spearman = 0,89; $p < 0,001$), bem como das tendências dos desfechos associados ($\rho = 0,83$; $p < 0,001$), com base nos dados utilizados para treinamento no intervalo de 2015–2019 (Figura 5).

Figura 5. Tendências temporais em indicadores-chave relacionados ao diabetes.

Painéis multivariados de séries temporais de 2015-2024 com projeções até 2030: (A) Despesa anual total com diabetes com intervalos de predição de 95%, (B) Prevalência ajustada por idade por região, (C) Taxas de hospitalização por 100.000 habitantes, (D) Taxas de mortalidade por 100.000 habitantes. Dados observados como linhas sólidas, predições do modelo fuzzy como linhas tracejadas, alocação histórica contrafactual como linhas pontilhadas.

Análise de Custos Específicos por Complicação e Prioridades de Prevenção

A análise de 1.247.332 hospitalizações relacionadas ao DM com complicações documentadas (2015-2024) revelou eventos cardiovasculares (n=486.219; 39,0%), complicações do pé diabético (n=298.447; 23,9%) e insuficiência renal (n=187.663; 15,0%) como causas predominantes. Os custos anuais medianos aumentaram de USD 130,5 (R\$ 487) na linha de base para USD 334,0 (R\$ 1.247) no primeiro ano após complicações macrovasculares. O modelo *fuzzy* priorizou investimentos em prevenção de complicações direcionados a essas condições de alto custo, predizendo redução de 31,4% nas hospitalizações relacionadas a complicações por meio de programas otimizados de detecção precoce e intervenção.

DISCUSSÃO

Nosso estudo revela como mecanismos inteligentes de suporte à decisão podem remodelar o cuidado ao diabetes ao desvendar ineficiências estruturais e expor oportunidades negligenciadas para investimento estratégico. A abordagem integrada de modelagem *fuzzy* destaca trajetórias transformadoras para o fortalecimento do desempenho do sistema de saúde, demonstrando que uma alocação mais equitativa e

orientada a resultados é alcançável quando a incerteza é rigorosamente incorporada ao desenho de políticas.

Modelos de lógica *fuzzy* têm demonstrado importância significativa no manejo de incerteza e imprecisão em dados biomédicos, particularmente em sistemas diagnósticos e suporte à decisão clínica, ao capturar interações não lineares e incertezas que modelos convencionais negligenciam (11). Sua força em ambientes clínicos complexos alinha-se com evidências crescentes de que tais sistemas aprimoram a interpretabilidade, apoiam a otimização de recursos e melhoram a confiabilidade preditiva em diversos contextos de saúde populacional (12). Nossos resultados reforçam evidências anteriores mostrando que a lógica *fuzzy* se destaca na navegação de incertezas dentro dos sistemas de saúde, porém estendem esse entendimento ao demonstrar maior coerência, trajetórias de decisão mais claras e desempenho mais confiável quando aplicada à alocação de recursos em larga escala em cenários de saúde pública do mundo real.

A otimização da alocação de recursos em saúde pública demanda integração rigorosa de evidências, definição ética de prioridades e modelagem adaptativa para equilibrar equidade, eficiência e incerteza sob orçamentos restritos (13). Metodologias emergentes, combinando análise de decisão multicritério, avaliação de tecnologias em saúde e otimização algorítmica, facilitam a priorização transparente e sensível ao contexto que apoia decisões políticas resilientes e escaláveis, ao mesmo tempo que melhora a custo-efetividade em populações heterogêneas para sistemas de saúde com recursos limitados por meio do aprimoramento do engajamento das partes interessadas e da prestação de contas (14). Nossos achados ecoam discussões mais amplas sobre priorização em saúde pública, porém avançam o campo ao mostrar como uma estrutura *fuzzy* integrada pode remodelar padrões de investimento que simultaneamente aprimoram a equidade, reforçam a prevenção primária e produzem ganhos substanciais nos desfechos populacionais em comparação com padrões de gastos prevalentes.

Iniquidades geográficas em saúde ao longo do vasto território brasileiro refletem disparidades socioeconômicas profundas, com as regiões Norte e Nordeste experimentando maiores cargas de doença e acesso mais limitado aos cuidados de saúde do que suas contrapartes do Sul e Sudeste (15,16). Isso ressalta a necessidade de intervenções geograficamente direcionadas apoiadas por planejamento informado por dados, monitoramento contínuo e governança focada em equidade para estreitar de forma sustentável as lacunas de acesso e melhorar mensuravelmente os desfechos de saúde populacional (17). Nossos resultados validam diretamente e alinham-se com evidências

mais amplas de iniquidades regionais pronunciadas, mas avançam esse entendimento ao mostrar como as respostas de investimento modeladas variam entre territórios, revelando ganhos desproporcionais em áreas carentes e demonstrando o valor de estratégias geograficamente informadas para corrigir desequilíbrios estruturais na prestação de cuidados ao DM.

A análise de cenários orçamentários em saúde pública avalia criticamente trajetórias fiscais sob variadas pressões econômicas, mudanças demográficas e intervenções políticas, revelando vulnerabilidades no agrupamento de recursos e priorização de despesas. No Brasil, análises do SUS destacam gastos catastróficos crescentes em meio à austeridade, projetando iniquidades aprofundadas sem alocações federais ampliadas (18,19). Globalmente, projeções sublinham estagnação da assistência ao desenvolvimento e crescentes ônus de dívida, necessitando estruturas adaptativas para sustentar a cobertura universal em meio a populações envelhecidas e pandemias (20,21). Nossa análise espelha preocupações mais amplas sobre vulnerabilidade fiscal em saúde pública, porém as avança ao demonstrar como o orçamento adaptativo baseado em *fuzzy* pode proteger serviços essenciais, orientar realocação estratégica e aprimorar o desempenho do sistema sob cenários tanto de financiamento restrito quanto expandido.

Tendências temporais em saúde pública são essenciais para compreender a progressão de doenças ao longo do tempo. A validação preditiva integra dados longitudinais para aprimorar a acurácia de previsão de desfechos em saúde, possibilitando estratégias de intervenção precisas (22,23). Abordagens de modelagem avançadas apoiam cada vez mais previsões em tempo real, fortalecem a capacidade de alerta precoce e melhoram a acurácia do planejamento, particularmente em ambientes dinâmicos de saúde pública moldados por transições demográficas, mudanças epidemiológicas e restrições de recursos (24). A regressão *joinpoint* de nosso estudo revelou fases distintas nas tendências de gastos relacionados ao DM com evidente aceleração nos anos recentes, consistente com a literatura enfatizando análise de tendências temporais em saúde pública. Diferentemente da modelagem preditiva geral, que depende fortemente da integração de dados longitudinais para previsão e desenho de intervenção, nosso modelo *fuzzy* demonstrou previsões precisas de gastos e desfechos dentro desses períodos identificados, afirmando o valor de análises temporais especializadas em cenários sensíveis a recursos. Essa comparação destaca a importância de abordagens analíticas personalizadas para abordar efetivamente desafios de saúde dinâmicos.

Análises de custos específicos por complicações no DM demonstram consistentemente que eventos cardiovasculares, insuficiência renal e complicações de membros inferiores geram a maior carga financeira, ressaltando a importância de estratégias focadas em prevenção (25,26). O fortalecimento da detecção precoce, a otimização do controle glicêmico e a expansão de modelos de cuidado multidisciplinares podem reduzir substancialmente gastos evitáveis e melhorar desfechos em longo prazo em populações de alto risco (27,28). Nossos achados reforçam o entendimento estabelecido de que complicações graves geram a maior sobrecarga financeira no cuidado ao diabético, porém expandem essa perspectiva ao mostrar como estratégias de prevenção direcionadas e informadas por modelagem podem modificar significativamente os desfechos dentro de um grande sistema de saúde pública. A escalada de custos demonstrada após complicações macrovasculares alinha-se com a literatura enfatizando a necessidade crítica de detecção precoce e estratégias preventivas multidisciplinares para reduzir a carga econômica e melhorar os desfechos dos pacientes.

CONCLUSÃO

A otimização baseada em lógica *fuzzy* demonstra potencial substancial para aprimorar a eficiência do cuidado ao diabético dentro do SUS no Brasil por meio de realocação estratégica priorizando a expansão da atenção primária e intervenções focadas em equidade em regiões carentes. Limitações incluem uso de dados retrospectivos, impossibilidade de validação prospectiva e não captura de atendimentos na rede privada.

REFERÊNCIAS

1. Zadeh LA. Fuzzy sets. *Information and Control*. 1965;8(3):338-353.
2. Kachukhashvili GS, Tsiskarishvili NE, Dubovik MV, Badiashvili GV. The use of fuzzy sets techniques in managing health organizations. *Medinfo*. 1995;8 Pt 1:541.
3. Halim M, Ho KM, Liu A. Fuzzy Logic for medical expert systems. *Ann Acad Med Singap*. 1990 Sep;19(5):672-83.
4. Chen L, Liu W, Zhang J. An interval type-2 fuzzy multi-criteria decision-making approach for patient bed allocation. *Sci Rep*. 2025;15(1):21019.
5. Brazilian Ministry of Health. Strategic Action Plan to Combat Chronic Diseases in Brazil 2021-2030. Brasília: Ministry of Health; 2021.

6. Paim J, Travassos C, Almeida C, Bahia L, Macinko J. The Brazilian health system: history, advances, and challenges. *Lancet*. 2011;377(9779):1778-97.
7. Brazilian Ministry of Health, DATASUS. Hospital Information System of SUS (SIH-SUS). Available at: <http://datasus.saude.gov.br>. Accessed December 2025.
8. Massuda A, Hone T, Leles FAG, de Castro MC, Atun R. The Brazilian health system at crossroads: progress, crisis and resilience. *BMJ Glob Health*. 2018;3(4):e000829.
9. Schmidt MI, Duncan BB, Mill JG, Lotufo PA, Chor D, Barreto SM, et al. Cohort Profile: Longitudinal Study of Adult Health (ELSA-Brasil). *Int J Epidemiol*. 2015;44(1):68-75.
10. Hatsek A, Hochberg I, Daoud Naccache D, Biderman A, Shahar Y. Design of a bi-directional methodology for automated assessment of compliance to continuous application of clinical guidelines, and its evaluation in the type 2 diabetes domain. *PLoS One*. 2024;19(5):e0303542.
11. Drnovšek R, Milavec Kapun M, Šteblaj S, Rajkovič U. Multicriteria Risk Evaluation Model: Utilizing Fuzzy Logic for Improved Transparency and Quality of Risk Evaluation in Healthcare. *Risk Manag Healthc Policy*. 2025;18:637-653.
12. Zadeh LA. Towards a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic. *Fuzzy Sets Syst*. 1997;90:11-27.
13. Collins M, Mazzei M, Baker R, Morton A, Frith L, Syrett K, et al. Developing a combined framework for priority setting in integrated health and social care systems. *BMC Health Serv Res*. 2023;23(1):879.
14. Berezowski J, Czapla M, Manulik S, Ross C. Rationing in healthcare-a scoping review. *Front Public Health*. 2023;11:1160691.
15. Albuquerque MV, Viana ALD, Lima LD, Ferreira MP, Fusaro ER, Iozzi FL. Regional health inequalities: changes observed in Brazil from 2000-2016. *Cien Saude Colet*. 2017;22(4):1055-1064.
16. Caldeira TCM, Soares MM, Silva LESD, Veiga IPA, Claro RM. Chronic disease risk and protective behaviors in Brazilian state capitals and the Federal District, according to the National Health Survey and the Chronic Disease Risk and Protective Factors Telephone Survey Surveillance System, 2019. *Epidemiol Serv Saude*. 2022;31(spe1):e2021367.
17. Hone T, Rasella D, Barreto ML, Majeed A, Millett C. Association between expansion of primary healthcare and racial inequalities in mortality amenable to

- primary care in Brazil: A national longitudinal analysis. *PLoS Med.* 2017;14(5):e1002306.
18. Torres TF, Santos PHA, Russo LX, Silva EN. Monitoring financial healthcare protection in Brazil: evolution, inequalities, and associated factors. *Public Health.* 2024;236:175-183.
 19. Maia LR, Campos MR, Castanheira D. Fiscal austerity and municipal health spending: an interrupted time series study. *Rev Saude Publica.* 2024;58:42.
 20. Global Burden of Disease Health Financing Collaborator Network. Past, present, and future of global health financing: a review of development assistance, government, out-of-pocket, and other private spending on health for 195 countries, 1995-2050. *Lancet.* 2019;393(10187):2233-2260.
 21. World Health Organization. Financing and implementation of the Programme budget (Document A76/19). Geneva: WHO; 10 May 2023. Available at: https://apps.who.int/gb/ebwha/pdf_files/WHA76/A76_19-en.pdf. Accessed December 2025.
 22. Zhu J, Cui Y, Zhang J, Yan R, Su D, Zhao D, et al. Temporal trends in the prevalence of Parkinson's disease from 1980 to 2023: a systematic review and meta-analysis. *Lancet Healthy Longev.* 2024;5(7):e464-e479.
 23. Alshaiikh H, Alghamdi H, Aldosari H, Alanazi A, Aldosari B. Data Analytics Applications in Population Health in Saudi Arabia: Challenges and Opportunities. *Stud Health Technol Inform.* 2025;328:501-504.
 24. Ryan-Ibarra S, Nishimura H, Gallington K, Grinnell S, Bekemeier B. Time to Modernize: Local Public Health Transitions to Population-Level Interventions. *J Public Health Manag Pract.* 2021;27(5):464-472.
 25. Candrilli SD, Meyers JL, Boye K, Bae JP. Health care resource utilization and costs during episodes of care for type 2 diabetes mellitus-related comorbidities. *J Diabetes Complications.* 2015;29(4):529-33.
 26. Bommer C, Sagalova V, Heesemann E, Manne-Goehler J, Atun R, Bärnighausen T, et al. Global Economic Burden of Diabetes in Adults: Projections From 2015 to 2030. *Diabetes Care.* 2018;41(5):963-970.
 27. Zhou X, Siegel KR, Ng BP, Jawanda S, Proia KK, Zhang X, et al. Cost-effectiveness of Diabetes Prevention Interventions Targeting High-risk Individuals and Whole Populations: A Systematic Review. *Diabetes Care.* 2020;43(7):1593-1616.

28. Templer S, Abdo S, Wong T. Preventing diabetes complications. *Intern Med J.* 2024;54(8):1264-1274.

Este preprint foi submetido sob as seguintes condições:

- Os autores declaram que os necessários Termos de Consentimento Livre e Esclarecido de participantes ou pacientes na pesquisa foram obtidos e estão descritos no manuscrito, quando aplicável.
- Os autores declaram que a elaboração do manuscrito seguiu as normas éticas de comunicação científica.
- Os autores declaram que estão cientes que são os únicos responsáveis pelo conteúdo do preprint e que o depósito no SciELO Preprints não significa nenhum compromisso de parte do SciELO, exceto sua preservação e disseminação.
- Os autores declaram que os dados, aplicativos e outros conteúdos subjacentes ao manuscrito estão referenciados.
- O manuscrito depositado está no formato PDF.
- Os autores declaram que a pesquisa que deu origem ao manuscrito seguiu as boas práticas éticas e que as necessárias aprovações de comitês de ética de pesquisa, quando aplicável, estão descritas no manuscrito.
- Os autores declaram que uma vez que um manuscrito é postado no servidor SciELO Preprints, o mesmo só poderá ser retirado mediante pedido à Secretaria Editorial do SciELO Preprints, que afixará um aviso de retratação no seu lugar.
- Os autores concordam que o manuscrito aprovado será disponibilizado sob licença [Creative Commons CC-BY](#).
- O autor submissor declara que as contribuições de todos os autores e declaração de conflito de interesses estão incluídas de maneira explícita e em seções específicas do manuscrito.
- Os autores declaram que o manuscrito não foi depositado e/ou disponibilizado previamente em outro servidor de preprints ou publicado em um periódico.
- Caso o manuscrito esteja em processo de avaliação ou sendo preparado para publicação mas ainda não publicado por um periódico, os autores declaram que receberam autorização do periódico para realizar este depósito.
- O autor submissor declara que todos os autores do manuscrito concordam com a submissão ao SciELO Preprints.