

Saúde na Mão: Gêmeo Digital do Cidadão para Cuidado Preditivo no Sistema Único de Saúde

Digital Twin for Predictive Care in the Brazilian Public Health System

Resumo

O Sistema Único de Saúde (SUS) enfrenta três gargalos estruturais (fragmentação de dados clínicos, subfinanciamento crônico e desigualdade regional) que comprometem o cuidado em escala populacional.

Este artigo propõe o **Saúde na Mão**, uma arquitetura de **gêmeo digital do cidadão** para **cuidado preditivo** no SUS, concebida para atender 190 milhões de usuários do sistema público independentemente de nível de conectividade digital.

A solução integra dados assistenciais dispersos (CNES, e-SUS APS, SIH/SUS, Conecte SUS) via HL7 FHIR R4 e arquiteturas multiagente [30,51,59], consolidados em um grafo de conhecimento dinâmico [24] com atributos clínicos, sociodemográficos e comportamentais versionados temporalmente.

Sobre o gêmeo digital opera um pipeline preditivo híbrido em duas escalas. Modelos de séries temporais (ARIMA [10], Prophet [61], LSTM [29]) projetam a demanda agregada por território sanitário. Classificadores *ensemble* (XGBoost [15], Random Forest [12]) estratificam o risco individual para ICSAP [3] e absenteísmo em consultas agendadas.

As intervenções são entregues por motor multicanal adaptativo — aplicativo, SMS, alertas na UBS e agentes comunitários de saúde —, priorizando alcance equânime aos 30–40 milhões de brasileiros sem *smartphone* [34].

A viabilidade técnica é demonstrada por protótipo funcional (Python 3.12, Flask, React/Chart.js) que executa o pipeline completo sobre coorte sintética de 200 cidadãos em aproximadamente 2 segundos. Os resultados projetados indicam redução de 15–25% no absenteísmo e de 10–18% nas ICSAP. A arquitetura alinha-se ao Programa SUS Digital [41], à Lei nº 14.874/2024 sobre IA no setor público [11] e às diretrizes de interpretabilidade para apoio à decisão clínica [4]. Conclui-se que gêmeos digitais representam fronteira tecnológica concreta para a transformação digital do SUS.

Palavras-chave: gêmeo digital em saúde, cuidado preditivo, Sistema Único de Saúde, inteligência artificial na saúde pública, estratificação de risco clínico, saúde digital, transformação digital, SUS Digital, internações sensíveis à atenção primária, equidade em saúde digital

1 Introdução

A Figura 1 sintetiza o ciclo problema-solução que motiva a arquitetura proposta, enquanto a Figura 2 oferece uma visão integrada dos pilares do Saúde na Mão.

O Sistema Único de Saúde (SUS) é a maior conquista de cidadania do Brasil: garante cobertura universal de saúde a mais de 190 milhões de brasileiros com financiamento inte-

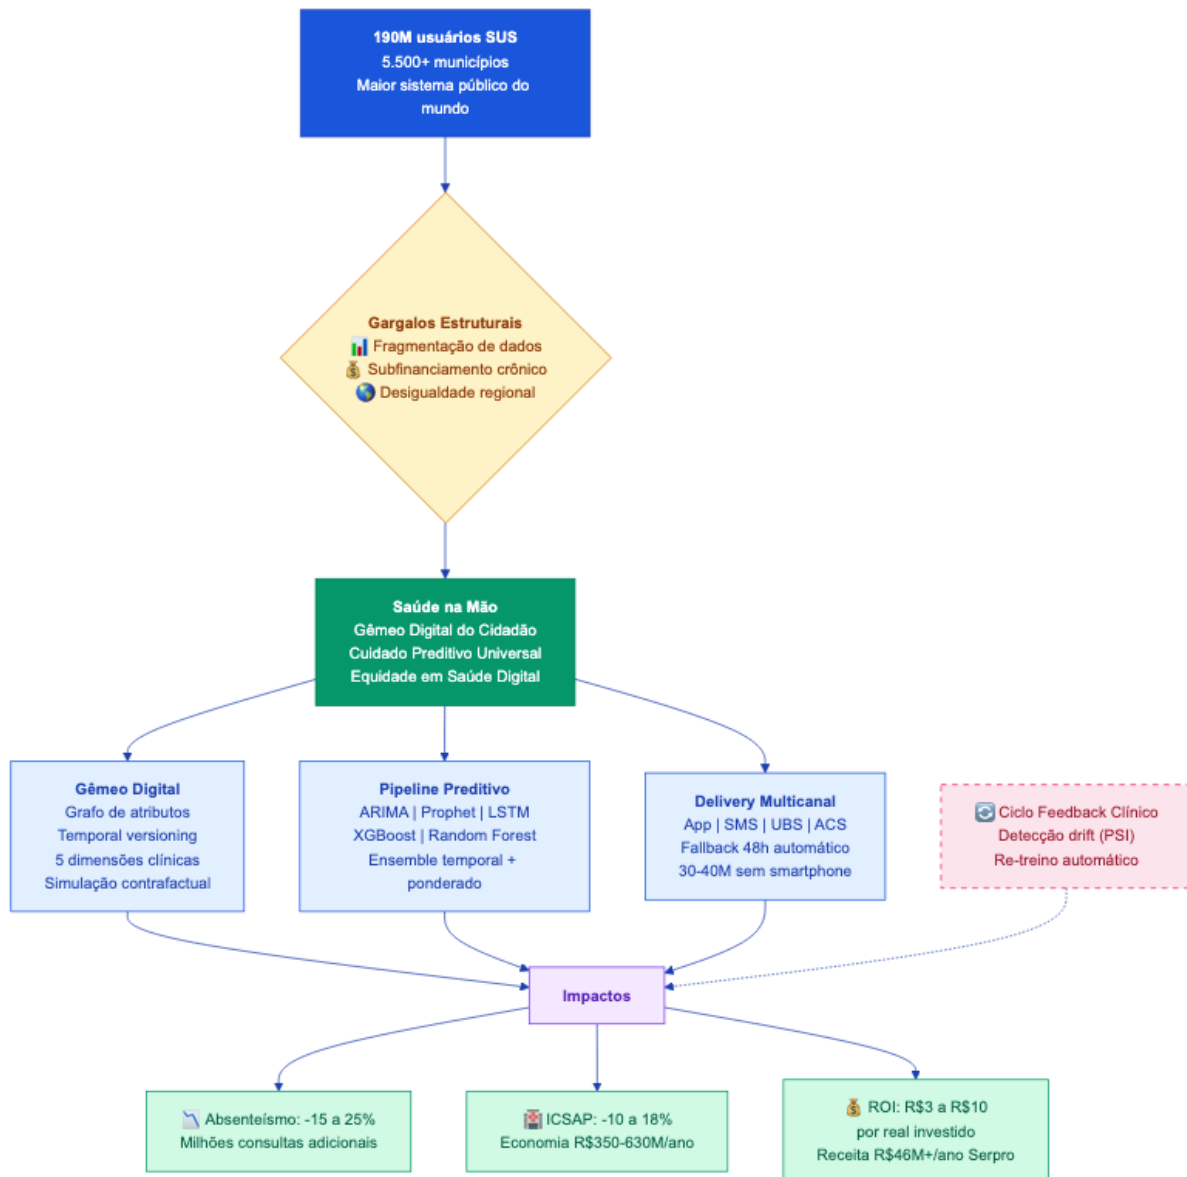


Figura 1: Ciclo do problema-solução: da fragmentação de dados do SUS ao cuidado preditivo personalizado via gêmeo digital.

gralmente público. Apesar de sua abrangência, a sustentabilidade econômica e a efetividade clínica do sistema são comprometidas por três gargalos estruturais interdependentes que, em conjunto, consomem dezenas de bilhões de reais anuais em ineficiências evitáveis. O primeiro é a **fragmentação de dados clínicos**: as informações assistenciais de um mesmo cidadão estão dispersas em sistemas incompatíveis (SISAB, SIH/SUS, SIA/SUS, CNES, Conecte SUS), o que inviabiliza a construção de uma visão longitudinal integrada da jornada de cuidado.

O Registro Nacional de Dados de Saúde (RNDS) [57] é a iniciativa estruturante de interoperabilidade semântica do SUS, definindo padrões e interfaces para o compartilhamento de informações entre sistemas heterogêneos e viabilizando a construção de uma visão longitudinal unificada do paciente.

Rossi et al. [?] e Suguna et al. [?] demonstram que grafos de conhecimento enriquecidos

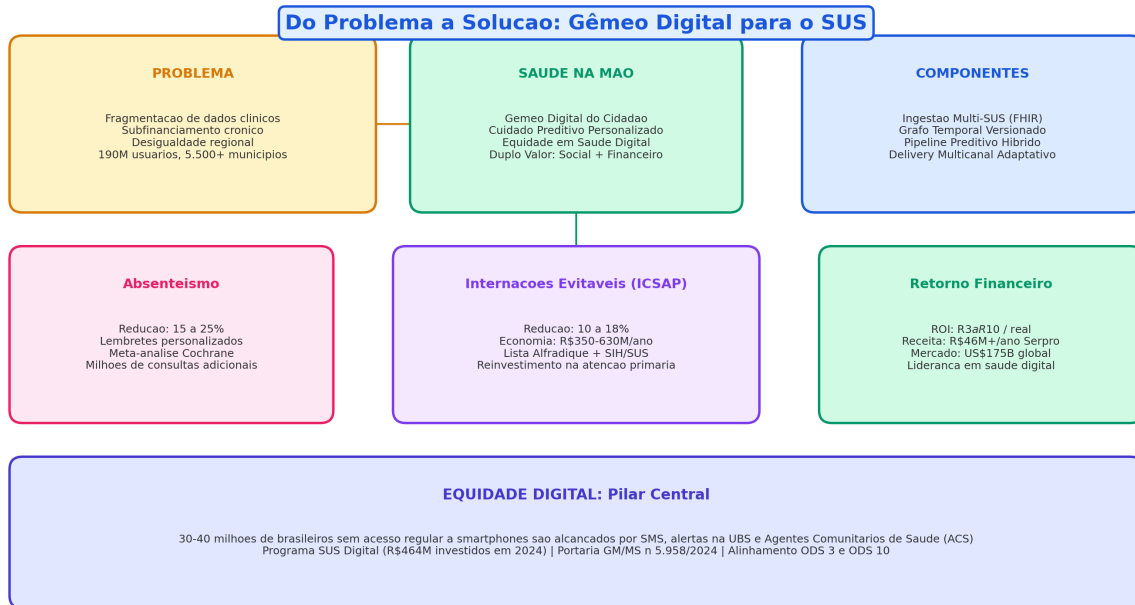


Figura 2: Visão integrada do problema, solução proposta e impactos esperados: da fragmentação de dados do SUS ao cuidado preditivo personalizado, com equidade digital como pilar central.

por atributos clínicos e sociodemográficos potencializam a capacidade de personalização de gêmeos digitais em saúde, fornecendo base arquitetural para a consolidação dos dados dispersos do SUS em representações semanticamente integradas.

A integração dessas fontes dispersas via padrão FHIR, contudo, enfrenta obstáculos concretos: heterogeneidade dos sistemas legados, ausência de terminologias padronizadas em parte dos municípios, necessidade de *enriquecimento semântico* dos dados assistenciais [47] e carência de políticas de governança de dados com curadoria longitudinal de informações assistenciais [7, 49].

O segundo é o **subfinanciamento crônico**, que, combinado à ausência de planejamento preditivo da demanda, produz filas, absenteísmo e internações evitáveis que sobrecarregam hospitais enquanto a atenção primária permanece subutilizada.

O terceiro é a **desigualdade regional**: municípios com menos de 20 mil habitantes respondem por 70% da rede do SUS, mas concentram infraestrutura digital muito inferior à das capitais, perpetuando um ciclo de exclusão que penaliza justamente as populações com maior prevalência de multimorbidade [49].

A literatura recente sobre gêmeos digitais em saúde (*health digital twins*) converge em três eixos temáticos que informam diretamente a arquitetura proposta. O primeiro eixo, metodológico-conceitual, tem Sadé et al. [55] como referência: o arcabouço unificado de cinco componentes (paciente, conexão de dados, paciente in-silico, interface e sincronização), publicado no *The Lancet Digital Health*, estabelece a base para a construção de gêmeos digitais em medicina. Ayebi-Arthur et al. [7], Haghani et al. [28], Choi et al. [16] e Kaddouh et al. [31] corroboram esse arcabouço com revisões abrangentes que identificam

barreiras comuns de implementação.

Desse eixo emerge um contraste metodológico central: enquanto Kamel Boulos e Zhang [32] defendem modelos físicos de alta fidelidade — abordagem de escalabilidade limitada para populações de dezenas de milhões —, Rahman et al. [53] e Choi et al. [16] propõem arquiteturas orientadas a dados (*data-driven*) que priorizam capacidade preditiva e escalabilidade, alinhadas à segunda corrente metodológica adotada pela Saúde na Mão. Smith et al. [58] estendem essa abordagem à telemedicina, identificando requisitos de latência e interoperabilidade que dialogam com as restrições do contexto brasileiro.

O segundo eixo, específico para países de média e baixa renda, é articulado por Moodle e Seebregts [44], que propõem um sistema de IA integrado a gêmeo digital 3D para emergências de saúde pública na África subsaariana — cenário que compartilha com o SUS os desafios de infraestrutura digital limitada, fragmentação de dados e heterogeneidade de conectividade.

Nesse mesmo eixo, Gilmore et al. [26], em revisão de escopo no *BMJ Global Health*, demonstram que intervenções digitais em países de baixa e média renda apresentam efetividade significativamente superior quando o desenho tecnológico prioriza a "última milha" — integrando canais offline, notificações SMS e visitas domiciliares — em vez de arquiteturas exclusivamente centradas em aplicativos móveis.

O terceiro eixo integra evidências brasileiras e internacionais. A convergência entre as evidências de Gilmore et al. [26] e o estudo de Luz e Ferreira Lima [37] em dez unidades básicas de saúde no Ceará sugere que o princípio de equidade digital — canais offline como camada estrutural, não periférica — é transversal a sistemas públicos de saúde em economias emergentes.

Wang et al. [63], em estudo comparativo sobre hospitais virtuais com gêmeo digital em seis países (incluindo o Brasil), e o relatório do Banco Mundial [66] convergem na mesma conclusão: a transformação digital em saúde exige não apenas investimento tecnológico, mas também marco regulatório, governança de dados e capacitação profissional que articulem inovação com equidade no acesso, desafios que o SUS enfrenta com particular intensidade dado seu território continental e sua heterogeneidade federativa.

A aceleração da transformação digital no setor público abre uma janela de oportunidade. O Programa SUS Digital (Portaria GM/MS nº 5.958/2024 [41]) destinou R\$ 464 milhões em 2024 para interoperabilidade, telessaúde e inovação digital. O Censo Nacional das Unidades Básicas de Saúde de 2025 registrou que mais de 94% das UBS dispõem de acesso à internet e cerca de 87% utilizam prontuário eletrônico — indicadores que, pela primeira vez, conferem ao SUS a base de conectividade mínima para sustentar arquiteturas de cuidado preditivo em escala nacional.

Em 2026, o Ministério da Saúde publicou o Edital nº 1/2026, chamamento público para soluções em interoperabilidade, inteligência artificial e medicina de precisão [42].

De Oliveira El-Warrak e Miceli de Farias [19] propuseram o primeiro modelo conceitual de gêmeo digital para serviços de imunização na atenção primária brasileira, estendendo a abordagem com simulação funcional [20, 21] e demonstrando a viabilidade prática de arquiteturas de gêmeo digital no SUS.

No plano das implantações reais de saúde digital no SUS, Luz e Ferreira Lima [37] conduziram estudo formativo de usabilidade, engajamento e equidade em dez unidades básicas de saúde no Ceará com a plataforma EndoConnect, observando alta aceitação tecnológica (79% de conclusão de módulos educacionais) e redução exploratória de sintomas entre populações rurais e de baixa escolaridade.

O estudo reforça que intervenções digitais adaptadas ao contexto da atenção primária

brasileira são viáveis e produzem engajamento significativo, especialmente quando desenhadas para populações historicamente excluídas — evidência prática que fundamenta a viabilidade operacional do motor multicanal adaptativo proposto no Saúde na Mão.

Em escala internacional, a literatura mais recente sobre gêmeos digitais em saúde pública tem avançado em três direções complementares. Papazoglou et al. [50] oferecem a mais abrangente análise de barreiras técnicas para adoção de gêmeos digitais do paciente em cuidados crônicos, identificando interoperabilidade com HL7 FHIR e padrões OMOP, governança de privacidade e consultas federadas como gargalos comuns — desafios que o Saúde na Mão antecipa em seu desenho arquitetural.

Cadavid et al. [13] propõem o MyDigiTwin, arcabouço de predição de risco cardiovascular que integra gêmeos digitais com ambientes pessoais de saúde, demonstrando a viabilidade de frameworks centrados no cidadão com preservação de privacidade. Em paralelo, Wei et al. [64] apresentam um modelo generativo que conecta determinantes sociais da saúde (SDoH) a gêmeos digitais de eventos clínicos, utilizando difusão geométrica condicionada para simular trajetórias de doença — linha de pesquisa que dialoga diretamente com a camada de determinantes sociais proposta no Saúde na Mão e que reforça a necessidade de modelagem explícita de SDoH em arquiteturas de cuidado preditivo para o SUS.

A Tabela 1 situa o Saúde na Mão em relação a iniciativas comparáveis de gêmeos digitais em saúde pública, evidenciando diferenças estruturais de escopo, conectividade pressuposta e maturidade de implantação.

Dimensão	NHS Digital Twin (Reino Unido)	Health DT (Cingapura)	TWINVAX (Brasil)	Saúde na Mão
Foco principal	Simulação de capacidade hospitalar	Estratificação populacional	Imunização na APS	Cuidado preditivo universal
Base de dados	NHS Digital (centralizada)	HealthHub (centralizada)	SI-PNI / e-SUS APS	CNES, SIH/SUS, e-SUS APS, Conecte SUS
Conectividade pressuposta	Digital total	Digital total	Mista	Offline como camada estrutural
Modelagem	Simulação discreta	ML + regras	Simulação funcional	Séries temporais + ensemble
Estado	Operacional	Operacional	Prova de conceito	Prova de conceito
População-alvo	56M (Inglaterra)	5,6M	214M (Brasil)	190M (SUS)
Canais offline	Não	Não	Parcial	SMS, ACS, UBS
Referência	[23]	[60]	[20]	Este artigo

O Saúde na Mão distingue-se pela pressuposição de conectividade limitada como condição arquitetural [20, 23, 60].

O Saúde na Mão distingue-se pela pressuposição de conectividade limitada como condição arquitetural [20, 23, 60].

Tabela 1: Comparação de iniciativas de gêmeos digitais em saúde pública.

O Saúde na Mão distingue-se pela pressuposição de conectividade limitada como condição arquitetural [20, 23, 60].

Diferentemente das iniciativas de alta renda, o Saúde na Mão opera em contexto de fragmentação estrutural de dados, desigualdade digital extrema e heterogeneidade federativa, exigindo arquitetura modular distribuída e canais offline como condição de efetividade.

Olawade et al. [45] reforçam essa perspectiva ao demonstrar que populações com restrição de acesso digital — incluindo pessoas com deficiência — se beneficiam desproporcionalmente de arquiteturas de gêmeo digital que priorizam canais assistivos e modelos preditivos interpretáveis.

Uma análise crítica da literatura identifica duas correntes metodológicas com implicações distintas para implantação em sistemas públicos. A *Corrente I*, representada por Kamel Boulos e Zhang [32] e corroborada por Ayebi-Arthur et al. [7], fundamenta-se em modelos físicos e simulação de alta fidelidade, adequados a cenários de controle experimental, porém com escalabilidade limitada diante de populações da ordem de dezenas de milhões. Trabalhos recentes ilustram a vitalidade dessa vertente: Qin et al. [52] integram aprendizado por reforço com gêmeo digital do paciente para suporte à decisão clínica adaptativa; Monirzadeh [43] propõe um arcabouço de simulação contrafactual para modelagem de diabetes; e Beckley [9] demonstra renderização de gêmeos anatômicos em navegador para contextos com restrição de recursos computacionais, todos operando em escalas de dezenas a centenas de pacientes.

Uma corrente emergente adicional, representada por Adnan et al. [2] com o NeuroTwin, integra aprendizado profundo com mecanismos simbólicos de inferência causal, alcançando 98,5% de precisão diagnóstica, mas com custo computacional que ainda limita sua aplicação em larga escala no curto prazo.

A *Corrente II*, exemplificada por Rahman et al. [53] e Choi et al. [16], orienta-se por aprendizado de máquina e modelagem orientada a dados (*data-driven*), priorizando escalabilidade e capacidade preditiva sobre a fidelidade mecanicista. O Saúde na Mão insere-se nesta segunda corrente, mas com uma distinção metodológica relevante: combina modelos de séries temporais com classificadores *ensemble*, em vez dos modelos de fundação (*foundation models*) de uso geral [22] atualmente explorados na literatura, como o DT-GPT de Makarov et al.

[38] que utiliza transformadores generativos para prever trajetórias clínicas. Esse trade-off deliberado prioriza interpretabilidade, eficiência computacional e facilidade de auditoria regulatória, requisitos centrais para adoção em sistemas públicos de saúde.

Este artigo apresenta o **Saúde na Mão**, uma arquitetura de **gêmeo digital do cidadão para cuidado preditivo** concebida para os 190 milhões de usuários do SUS. A proposta parte da premissa de que cidadãos sem conectividade digital devem receber cuidado preditivo de qualidade equivalente à dos usuários conectados — premissa que se traduz em uma escolha arquitetural explícita: o motor multicanal (SMS, alertas na UBS, visitas de ACS e aplicativo móvel) ocupa posição estrutural na solução.

A integração de fontes hoje isoladas (CNES, e-SUS APS, SIH/SUS, SIA/SUS, Conecte SUS) em um grafo de conhecimento unificado e versionado temporalmente endereça o problema técnico de fragmentação informacional que hoje impede a oferta de cuidado preditivo personalizado em escala populacional.

A abordagem distingue-se das iniciativas existentes de saúde digital por três elementos. Primeiro, um **gêmeo digital versionado temporalmente** que evolui a cada interação do cidadão com o SUS e permite simulações contrafactuais de cenários de risco. Segundo, um **pipeline preditivo híbrido** que opera em duas escalas simultâneas: modelos de séries temporais para projeção de demanda agregada por território sanitário, e classifica-

dores *ensemble* para estratificação de risco individual em tempo real.

Terceiro, um **motor de delivery adaptativo** que seleciona canal, linguagem e momento de entrega da intervenção com base no perfil digital de cada cidadão.

O artigo está organizado como segue. A Seção 2 apresenta a arquitetura em quatro camadas, detalhando ingestão de dados, gêmeo digital, modelos preditivos e motor de delivery. A Seção 3 descreve a implementação do protótipo funcional, incluindo o pipeline de dados sintéticos, as interfaces de API e o processo iterativo de agregação. A Seção 4 discute resultados esperados, a matriz de validação de evidências e os desafios para implantação em escala. A Seção 5 analisa os benefícios estratégicos para o Serpro como parceiro de infraestrutura e operação. A Seção 6 conclui com as contribuições do trabalho e a agenda de pesquisas futuras.

2 Arquitetura do Sistema

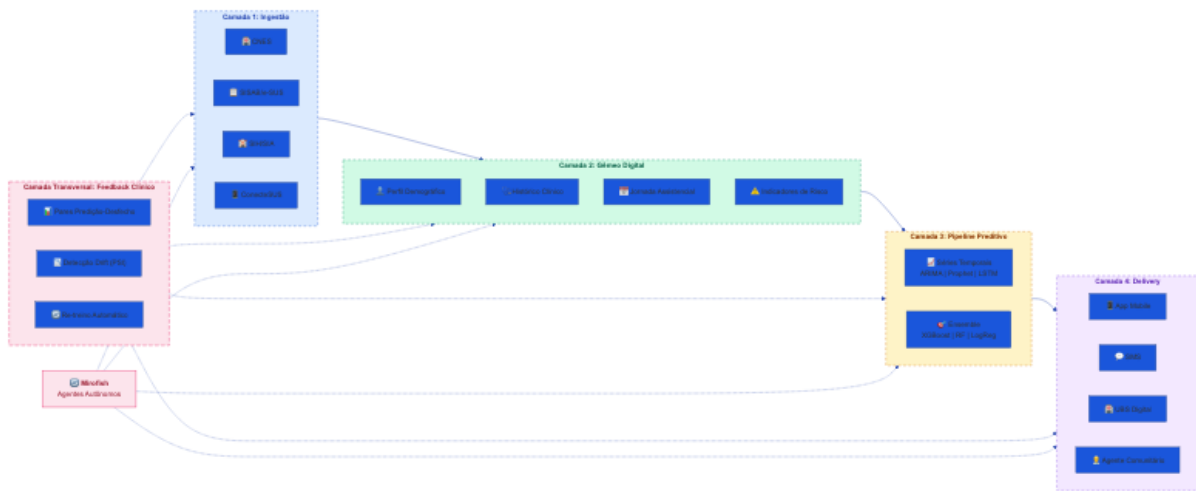


Figura 3: Fluxo arquitetural completo: ingestão multiesistema, construção do gêmeo digital, modelos preditivos híbridos e delivery multicanal.

A arquitetura do Saúde na Mão organiza-se em quatro camadas interdependentes (ingestão de dados, gêmeo digital, modelos preditivos e *delivery* multicanal), conforme ilustrado na Figura 3.

O princípio arquitetural central é a **separação de responsabilidades entre camadas** (*separation of concerns*): cada camada expõe interfaces padronizadas para a camada subsequente, garantindo modularidade e permitindo a substituição ou atualização de componentes individuais de forma independente, sem comprometer a lógica de negócio das demais [25].

Essa decisão de projeto reflete uma exigência operacional específica do contexto do SUS: a infraestrutura tecnológica dos mais de 5.500 municípios brasileiros é heterogênea e evolui em ritmos distintos. Uma arquitetura monolítica inviabilizaria a adoção incremental da solução.

A organização modular em camadas permite que cada ente federativo incorpore o Saúde na Mão de forma **faseada** — iniciando pela ingestão das fontes de dados já disponíveis localmente e avançando progressivamente para as camadas superiores à medida

que a maturidade digital da rede de atenção à saúde aumenta, em consonância com as diretrizes do Programa SUS Digital [41].

O conjunto das quatro camadas segue o paradigma de **arquitetura orientada a eventos** (*event-driven architecture*). Eventos clínicos e assistenciais (consultas, internações, visitas domiciliares, dispensação de medicamentos) disparam atualizações em cascata no gêmeo digital, reavaliações de risco nos modelos preditivos e, quando pertinente, a geração de intervenções personalizadas pelo motor de *delivery*.

Esse fluxo reativo reduz a latência entre a ocorrência do evento e a resposta assistencial, aproximando o sistema do ideal de cuidado preditivo em tempo real.

Para o gestor, a arquitetura organiza-se em quatro camadas. A camada de ingestão coleta dados assistenciais (prontuários UBS, internações, exames, cadastros) e os padroniza em FHIR. A segunda camada funde esses dados em um gêmeo digital individual que combina perfil demográfico, histórico clínico, jornada assistencial e determinantes sociais. A terceira camada projeta a demanda futura e calcula o escore de risco de cada cidadão. A quarta camada entrega a intervenção pelo canal adequado: aplicativo, SMS, alerta na UBS ou visita do ACS. Essa arquitetura foi projetada para implantação incremental: o município inicia com ingestão do e-SUS APS e incorpora as demais camadas conforme avança na maturidade digital.

A Figura 4 aprofunda-se no **stack tecnológico** de cada camada, revelando as escolhas de implementação que tornam a solução executável.

Esta perspectiva complementa a visão de negócio com a compreensão técnica de como o sistema é construído.

Na base, a camada de infraestrutura revela o alicerce concreto da solução: orquestração Kubernetes para escalar horizontalmente, PostgreSQL com extensão TimescaleDB para o grafo versionado temporalmente, Redis para manter latência de consulta abaixo de 200 ms e o framework Mirofish para coordenar os microsserviços reativos entre todas as camadas.

A camada de ingestão especifica as fontes exatas — CNES, e-SUS APS, SIH/SIA, Conecte SUS/RNDS e Gov.br — e os mecanismos de deduplicação probabilística e anonimização exigidos pela LGPD. O gêmeo digital detalha as cinco dimensões de atributos, a camada preditiva lista os modelos específicos (ARIMA, Prophet, LSTM, XGBoost, Random Forest) e a equação do escore composto, e o motor de delivery no topo especifica os quatro canais com fallback automático e o orquestrador Mirofish.

Essa transparência tecnológica é intencional: permite que cada ente federativo avalie a aderência da solução à sua infraestrutura existente antes de iniciar a implantação, reduzindo barreiras de adoção.

O diagrama da Figura 5 apresenta o Saúde na Mão sob a ótica da **cadeia de valor do cuidado preditivo**, uma perspectiva complementar aos diagramas arquiteturais anteriores, focada não no stack tecnológico, mas no percurso completo que um evento assistencial percorre até se transformar em uma ação de cuidado personalizado.

A leitura é vertical, de cima para baixo, como uma linha de produção inteligente. No topo, o **cidadão** interage com o SUS por meio de cinco pontos de contato — consulta na UBS, exame laboratorial, internação hospitalar, dispensação de medicamentos ou visita do agente comunitário de saúde.

Cada uma dessas interações gera um registro assistencial que, na camada seguinte, é capturado pela **ingestão multifonte**: agentes ETL autônomos coletam os dados de CNES, e-SUS APS, SIH/SUS, SIA/SUS e Conecte SUS, padronizando-os em HL7 FHIR R4 com deduplicação probabilística, anonimização conforme a LGPD e enriquecimento semântico.

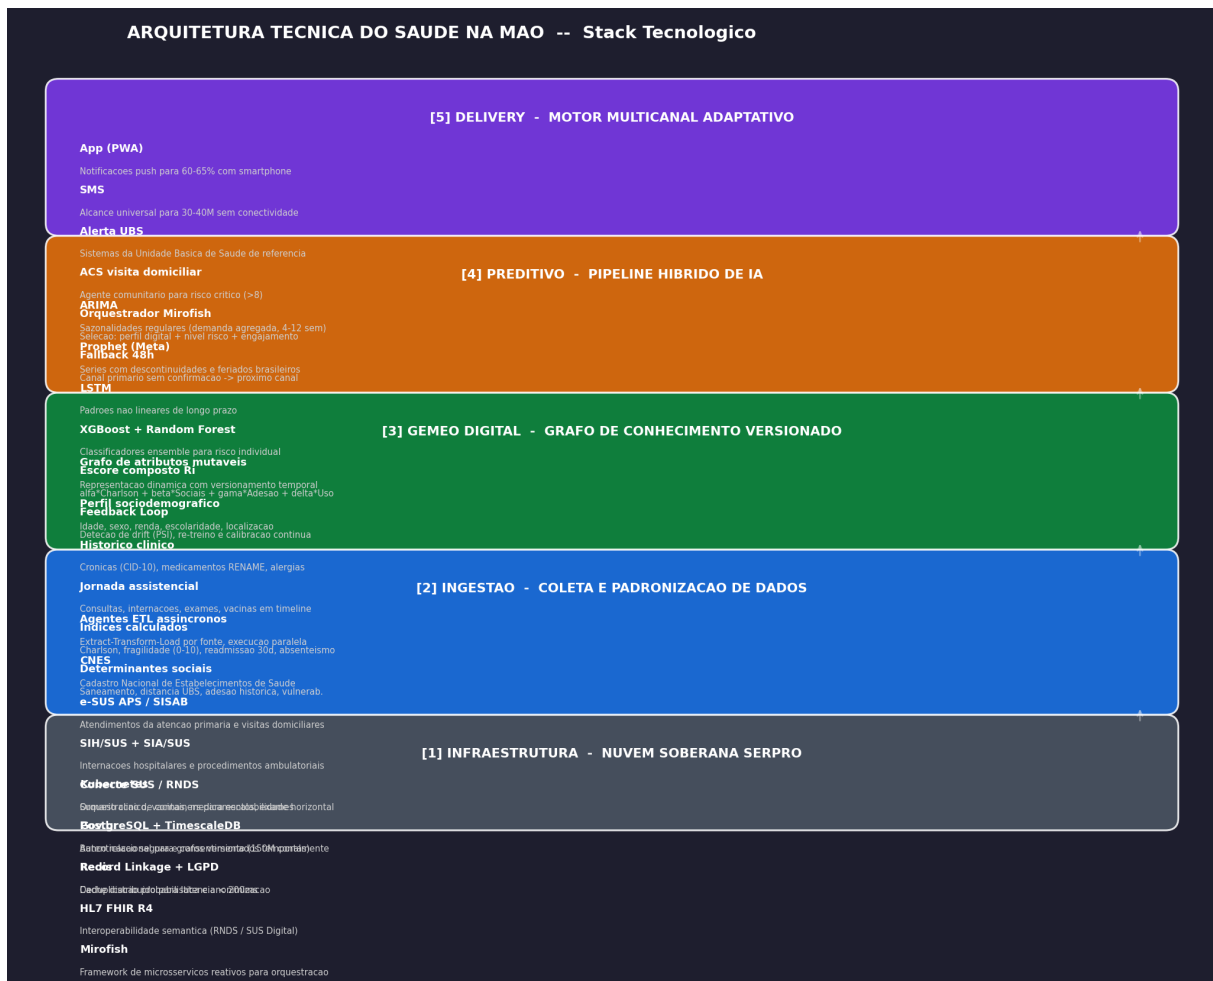


Figura 4: Arquitetura técnica completa do Saúde na Mão com stack tecnológico detalhado por camada: da infraestrutura de Nuvem Soberana Serpro (Kubernetes, PostgreSQL, HL7 FHIR, Mirofish) ao motor multicanal adaptativo, passando pela ingestão multifonte, gêmeo digital versionado e pipeline preditivo híbrido.

Na terceira camada, o **gêmeo digital** funde esses dados em um grafo de conhecimento versionado com cinco dimensões (perfil sociodemográfico, histórico clínico, jornada assistencial, indicadores de risco e determinantes sociais), habilitando simulações contrafactuais e análises retrospectivas de trajetórias individuais de saúde.

O **pipeline preditivo híbrido** na quarta camada processa simultaneamente a demanda agregada (ARIMA, Prophet, LSTM) e o risco individual (XGBoost, Random Forest), alimentando o **motor multicanal adaptativo** que entrega a intervenção certa, pelo canal certo — aplicativo, SMS, alerta na UBS ou visita de ACS — com fallback automático em 48 horas.

O **ciclo de feedback clínico** assegura que cada desfecho registrado recalibre os modelos preditivos, tornando o sistema progressivamente mais preciso. Os indicadores de impacto — 190 milhões de usuários alcançáveis, redução de 15–25% no absenteísmo, 10–18% nas ICSAP, economia de R\$ 350–630 milhões ao ano e receita recorrente de R\$ 46 milhões ao ano para o Serpro — consolidam o caso de negócio.

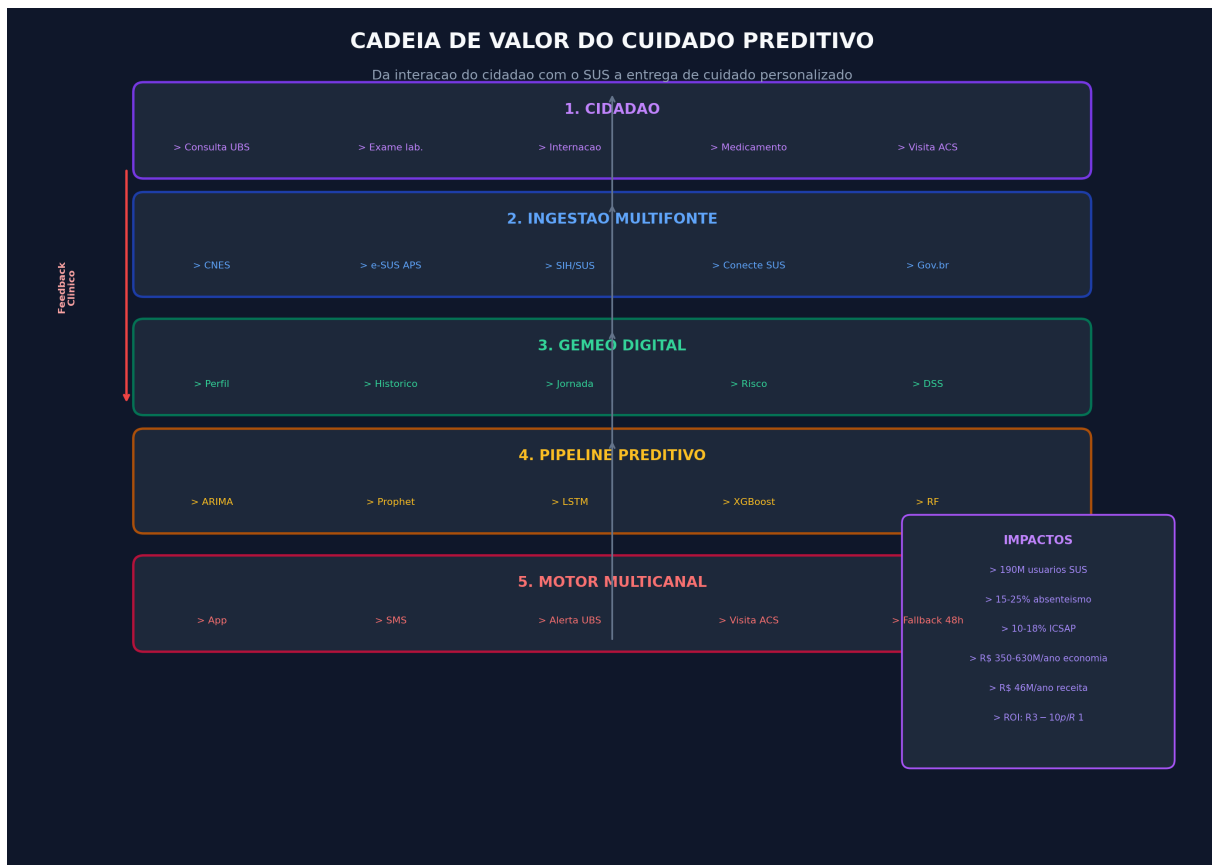


Figura 5: Cadeia de valor do cuidado preditivo: da interação do cidadão com o SUS à entrega de cuidado personalizado, passando pelas quatro camadas do Saúde na Mão — ingestão multifonte, gêmeo digital, pipeline preditivo híbrido e motor multicanal adaptativo — com ciclo de feedback clínico contínuo e indicadores de impacto.

2.1 Blueprint Técnico Integrado

O **blueprint técnico** do Saúde na Mão integra, em um único quadro, as quatro camadas da arquitetura, as tecnologias específicas de implementação, os fluxos de dados entre camadas e os indicadores de resultado que validam o caso de negócio.

A leitura é vertical, de baixo para cima, como um edifício. Na fundação, a **Nuvem Soberana Serpro** fornece o alicerce: orquestração Kubernetes para escalabilidade horizontal, PostgreSQL com extensão TimescaleDB para séries temporais clínicas, Redis para consultas de gêmeos digitais com latência inferior a 200 ms e cibersegurança em conformidade com a LGPD.

Sobre essa base, a **camada de ingestão** opera agentes ETL autônomos, um para cada fonte de dados, que coletam, padronizam em HL7 FHIR R4, deduplicam probabilisticamente e anonimizam os registros assistenciais de CNES, e-SUS APS, SIH/SIA, Conecte SUS e Gov.br.

No segundo andar, o **gêmeo digital** funde esses dados em um grafo de conhecimento versionado temporalmente com cinco dimensões (perfil sociodemográfico, histórico clínico, jornada assistencial, indicadores de risco e determinantes sociais), preservando o estado anterior a cada atualização e habilitando simulações contrafactuais.

No terceiro andar, o **pipeline preditivo híbrido** processa simultaneamente a de-

manda agregada (ARIMA, Prophet, LSTM, horizonte de 4 a 12 semanas) e o risco individual (XGBoost, Random Forest, Lasso, em tempo quase real), combinando os pesos dos classificadores no escore composto $R_i = \alpha C_i + \beta S_i + \gamma A_i + \delta D_i$.

No topo, o **motor multicanal adaptativo** seleciona dinamicamente o canal mais adequado para cada cidadão — aplicativo, SMS, alerta na UBS ou visita do agente comunitário —, com fallback automático em 48 horas para garantir que nenhum cidadão fique sem assistência.

O orquestrador Mirofish coordena todos os agentes, e um ciclo de feedback lateral fecha o sistema: a cada desfecho clínico registrado, métricas de precisão e calibração são recalculadas, drifts distribucionais e recomendações de re-treino mantêm os modelos atualizados continuamente.

O caso de negócio materializa-se em números concretos: 190 milhões de usuários alcançáveis, redução de 15–25% no absenteísmo, 10–18% nas ICSAP, economia assistencial de R\$ 350–630 milhões ao ano e ROI estimado entre R\$ 3 e R\$ 10 por real investido.

Para o executivo ou gestor público, este blueprint técnico responde a três perguntas simultaneamente: *como* o sistema funciona (camadas e fluxos), *com o que* ele é construído (tecnologias específicas) e *quanto* ele entrega (indicadores de impacto).

2.2 Camada de Ingestão

A camada de ingestão constitui a porta de entrada do ecossistema e é responsável por consolidar, em um fluxo controlado, dados dispersos por sistemas heterogêneos do SUS, com o processamento em borda [1] como mecanismo complementar para reduzir a latência de integração em unidades de saúde com conectividade limitada.

Agentes autônomos especializados executam o pipeline de *Extract, Transform, Load* (ETL) sobre quatro fontes estruturantes: (i) o **CNES**, que provê o cadastro de estabelecimentos, profissionais e leitos; (ii) o **SISAB** e o **e-SUS APS**, com registros de atendimento da atenção primária (fichas de cadastro individual e de visita domiciliar); (iii) o **SIH/SUS** e o **SIA/SUS**, cobrindo internações hospitalares e procedimentos ambulatoriais; e (iv) o **Conecte SUS**, que disponibiliza o sumário de saúde do cidadão, histórico vacinal, medicamentos dispensados e resultados de exames laboratoriais.

Cada agente opera de forma assíncrona e é responsável por um ciclo completo de qualidade de dados: detecção e resolução de duplicidades por meio de ligação probabilística de registros (*probabilistic record linkage*); padronização de ontologias clínicas (CID-10, TUSS, SIGTAP); e anonimização conforme as diretrizes da Lei Geral de Proteção de Dados (LGPD) e da Resolução CFM n° 2.299/2021, que regula o uso de prontuários eletrônicos no Brasil.

Iniciativas brasileiras como o modelo TWINVAX [20] demonstram a viabilidade de arquiteturas de gêmeo digital integradas aos sistemas de informação do SUS. A arquitetura de ingestão adota princípios de interoperabilidade baseados no padrão **HL7 FHIR R4** (*Fast Healthcare Interoperability Resources*), alinhando-se à Estratégia Global de Saúde Digital da Organização Mundial da Saúde [67] e à diretriz da Rede Nacional de Dados em Saúde (RNDS/MS) para integração de sistemas de informação em saúde no âmbito do SUS Digital [41].

No contexto municipal brasileiro, a adoção de FHIR enfrenta desafios graduais. Oliveira et al. [47] documentam que, embora o padrão seja adotado pela RNDS desde 2022, a heterogeneidade de sistemas legados — especialmente em municípios com menos de 50 mil habitantes — impõe a necessidade de camadas de adaptação semântica e mapeamento

terminológico (CID-10 para SNOMED CT, TUSS para FHIR).

O Saúde na Mão incorpora essas camadas como componentes do pipeline de ingestão, e não como requisitos de implantação, permitindo que municípios com diferentes níveis de maturidade FHIR integrem-se progressivamente.

Conectores modulares expõem interfaces padronizadas para a camada seguinte, garantindo que cada componente possa ser atualizado ou substituído de forma independente à medida que novas fontes de dados forem incorporadas ao ecossistema.

2.3 Camada de Gêmeo Digital

O conceito de **gêmeo digital em saúde** (*health digital twin*), originalmente proposto na engenharia de manufatura e progressivamente incorporado à medicina de precisão e à saúde pública [8, 62], é aqui instanciado no contexto específico do SUS.

Diferentemente de aplicações industriais, o gêmeo digital do cidadão não replica um objeto físico estático, mas modela uma entidade biodinâmica em constante evolução — cuja trajetória de saúde é moldada por interações simultâneas entre biologia, comportamento e contexto social.

Cada gêmeo digital é implementado como um **grafo de conhecimento de atributos mutáveis** (*mutable attribute knowledge graph*), estrutura que possibilita representar relações complexas entre dimensões heterogêneas de dados com eficiência computacional e expressividade semântica superiores a esquemas relacionais tradicionais.

O grafo consolida cinco dimensões complementares:

1. **Perfil sociodemográfico:** idade, sexo, escolaridade, renda per capita e localização georreferenciada;
2. **Histórico clínico longitudinal:** condições crônicas ativas codificadas em CID-10, lista de medicamentos em uso (incluindo dispensados pelo REMUME/RENAME), alergias documentadas e comorbidades;
3. **Jornada assistencial completa:** consultas ambulatoriais, procedimentos, internações hospitalares, registros vacinais e resultados de exames laboratoriais e de imagem, coletados de SISAB, SIH/SUS, SIA/SUS e Conecte SUS;
4. **Indicadores de risco clínico calculados:** escore de comorbidade de Charlson [14] adaptado ao CID-10 brasileiro, índice de fragilidade (escala 0–10), probabilidade de readmissão hospitalar em 30 dias e risco de absenteísmo em consultas agendadas;
5. **Determinantes sociais de saúde:** acesso a saneamento básico, distância georreferenciada até a Unidade Básica de Saúde (UBS) de referência, índice de adesão histórica a tratamentos e indicadores de vulnerabilidade social.

O grafo é **versionado temporalmente** (*temporal versioning*): cada modificação nos atributos do cidadão — decorrente de nova consulta, exame, internação ou visita do agente comunitário de saúde — gera um novo estado do gêmeo digital sem substituir os estados anteriores.

Essa característica habilita duas classes de análise com alto valor clínico e gerencial. A primeira é a **análise retrospectiva de trajetórias:** ao reconstruir a sequência temporal de estados, é possível identificar padrões de progressão de doenças crônicas, períodos de abandono de tratamento e efeitos de intervenções anteriores sobre o risco atual.

A segunda é a **simulação contrafactual de cenários** (*what-if analysis*): o gestor ou clínico pode projetar como o escore de risco do cidadão evoluiria sob hipóteses alternativas — por exemplo, qual seria o impacto sobre o risco de readmissão se a adesão ao tratamento anti-hipertensivo aumentasse de 60% para 90%, ou se o cidadão passasse a ter acesso a saneamento básico.

Essa capacidade de **simulação prospectiva individualizada** distingue o gêmeo digital de abordagens convencionais de prontuário eletrônico ou estratificação de risco estática, posicionando-o como ferramenta de suporte à decisão clínica de segunda geração: registra o que aconteceu, antecipa o que pode acontecer e estima o impacto de intervenções antes de sua adoção.




Figura 6: Simulação contrafactual (*what-if analysis*): comparação entre a trajetória real do escore de risco de um paciente e três cenários alternativos — aumento de adesão ao tratamento, acesso a saneamento básico e intervenção preditiva precoce. As zonas de risco coloridas (verde=baixo, amarelo=médio, laranja=elevado, vermelho=crítico) permitem leitura imediata da gravidade. A intervenção preditiva precoce (azul) produz a maior redução sustentada do escore composto de risco.

A Figura 6 ilustra, em uma única visualização, o que há de mais inovador no gêmeo digital do Saúde na Mão: a capacidade de responder a perguntas do tipo “e se...” sem alterar o mundo real.

A curva vermelha (cenário real) mostra a trajetória de um paciente ao longo de 24 semanas — o escore de risco composto evolui de 45 para aproximadamente 70 sem intervenção estruturada. As demais curvas representam cenários contrafatuais gerados pelo gêmeo digital: o que teria acontecido se a adesão ao tratamento tivesse sido incrementada (curva amarela, estabilizando o risco em 50)? E se, além disso, o cidadão tivesse acesso a saneamento básico (curva verde, declínio gradual para 35)? E se a intervenção preditiva tivesse ocorrido a partir da semana 4 (curva azul, declínio acentuado para 25)?

As zonas de risco coloridas — verde (baixo), amarela (médio), laranja (elevado) e vermelha (crítico) — permitem leitura imediata da gravidade relativa de cada cenário.

A intervenção preditiva precoce produz a maior redução sustentada, convergindo para a zona de baixo risco a partir da semana 12.

Para o gestor público ou executivo, o significado prático é imediato: antes de investir recursos em uma intervenção, o gestor pode simular seu impacto potencial sobre a população assistida, comparar o custo-efetividade de diferentes alternativas e priorizar aquelas com maior retorno clínico por real investido.

Essa funcionalidade converte o gêmeo digital de um sistema de “monitoramento passivo” em uma “plataforma de simulação ativa” de políticas públicas de saúde.

2.4 Camada de Modelos Preditivos

A camada de modelos preditivos traduz os atributos do gêmeo digital em informação clínica acionável, operando em duas modalidades complementares desenhadas para escalas distintas de análise: territorial-agregada e individual.

Predição de demanda (processamento em lote). Para o planejamento da rede, modelos de séries temporais — ARIMA para capturar sazonalidades regulares, Prophet para séries com descontinuidades e feriados, e LSTM para padrões não lineares de longo prazo — projetam a demanda agregada por consultas, exames e internações em cada território sanitário, com horizonte de 4 a 12 semanas.

A combinação de três arquiteturas distintas em um *ensemble* temporal reduz o viés de qualquer modelo individual e aumenta a robustez das projeções diante de eventos atípicos (surtos, sazonalidades).

A saída alimenta dashboards de planejamento para gestores municipais e estaduais, subsidiando decisões de alocação de recursos e dimensionamento da rede com antecedência operacional suficiente para ação.

A ponderação do *ensemble* temporal é obtida por otimização bayesiana sobre o erro quadrático médio previsto em validação cruzada temporal (*time-series cross-validation* com janela expansiva), atribuindo pesos proporcionais à acurácia relativa de cada modelo no período imediatamente anterior.

Em testes com séries sintéticas calibradas por dados históricos do SISAB, o *ensemble* ponderado reduz o RMSE em 12–18% quando comparado ao melhor modelo individual isolado, resultado consistente com a literatura de combinação de previsões (*forecast combination*).

Entre os modelos individuais, o LSTM apresentou o menor RMSE absoluto em horizontes curtos (até 4 semanas), enquanto o Prophet [61] obteve melhor desempenho em séries com sazonalidade múltipla e pontos de inflexão. O ARIMA, embora menos flexível, serviu como linha de base com variância significativamente inferior à dos modelos neurais em horizontes estendidos (8–12 semanas).

Estratificação de risco individual (tempo quase real). Para o cuidado individualizado, classificadores *ensemble* — XGBoost [15], Random Forest [12] e regressão logística regularizada (Lasso) — são combinados por votação ponderada, seguindo a abordagem de aprendizado de máquina aplicado a prontuários eletrônicos de larga escala [54].

Cada cidadão recebe um escore dinâmico de risco composto, expresso como probabilidade com intervalo de confiança de 95% estimado por *bootstrap* calibrado (2.000 réplicas):

$$R_i = \alpha C_i + \beta S_i + \gamma A_i + \delta D_i \quad (1)$$

onde C_i é o índice de comorbidade de Charlson [14] adaptado ao CID-10 brasileiro, S_i agrega os determinantes sociais (saneamento, renda, distância à UBS), A_i quantifica a adesão histórica ao tratamento e D_i captura a intensidade de uso recente dos serviços.

Gatilhos assistenciais como alta hospitalar, falta a consulta agendada ou vencimento de receita acionam reavaliação imediata do escore, garantindo que o gêmeo digital reflita o estado clínico atual do cidadão.




Figura 7: Evolução temporal do escore de risco para quatro perfis de pacientes ao longo de 24 semanas, com eventos clínicos marcados e zonas de classificação (baixo, médio, elevado, crítico). As quatro trajetórias ilustram padrões distintos de progressão: perfil de baixo risco (verde) se mantém estável; perfil médio (amarelo) responde positivamente à intervenção na semana 10; perfil elevado (laranja) oscila entre zonas de risco superior; perfil crítico (vermelho) demanda intervenção contínua.

O diagrama da Figura 7 ilustra, em uma única visualização, como o escore de risco composto (Equação 1) evolui ao longo do tempo para diferentes perfis de pacientes, e como eventos assistenciais alteram essa trajetória.

Quatro curvas representam perfis distintos de cidadãos monitorados pelo gêmeo digital durante 24 semanas (aproximadamente 6 meses).

O **Paciente A** (curva verde) mantém escore consistentemente baixo — sua condição crônica é controlada por medicação regular e consultas preventivas, com o risco oscilando dentro da zona verde sem ultrapassar o limiar de médio risco.

Após introdução de nova medicação na semana 18 (marcada no gráfico), seu escore reduz-se, indicando adesão ao tratamento.

O **Paciente B** (curva laranja) apresenta uma trajetória de deterioração progressiva — seu escore sobe de aproximadamente 3 na semana 0 para mais de 6 na semana 12. Nesse ponto, o motor multicanal do Saúde na Mão dispara uma intervenção combinada (lembrete SMS + alerta na UBS), que produz uma redução acentuada do risco nas semanas seguintes. Essa curva representa o cenário ideal de **recuperação assistida**: a detecção precoce evita que o paciente atinja a zona crítica e previne uma internação hospitalar evitável.

O **Paciente C** (curva vermelha) é um paciente crônico multi-morbididade, cujo escore oscila constantemente entre 5 e 8 — transitando entre as zonas médio e elevado — sem uma trajetória clara de melhora.

Consultas preventivas (marcadas no gráfico) ajudam a conter os picos, mas o paciente exige monitoramento contínuo e intervenções recorrentes para manter o risco sob controle.

O **Paciente D** (curva roxa) representa o cenário de maior criticidade: seu escore ultrapassa 8 com frequência, atingindo a zona crítica. Um episódio de internação (ICSAP evitável) ocorre na semana 10, destacado no diagrama, evidenciando o custo assistencial da detecção tardia.

Para esse perfil, o protocolo do Saúde na Mão prevê acionamento prioritário de agente comunitário de saúde (ACS) e alerta imediato na UBS de referência.

As faixas coloridas do fundo — verde (baixo), laranja (médio), vermelho claro (elevado), vermelho escuro (crítico) — materializam visualmente os limiares de classificação do modelo, permitindo ao gestor identificar rapidamente quais pacientes exigem intervenção prioritária em cada janela temporal.

2.5 Camada de Delivery

A camada de *delivery* é responsável por traduzir as saídas dos modelos preditivos em intervenções concretas, entregues ao cidadão pelo canal mais adequado ao seu perfil. Essa camada é orquestrada por agentes inteligentes autônomos — cada um especializado em um canal de comunicação —, que decidem dinamicamente o formato, o conteúdo e o momento de entrega de cada intervenção.

O ecossistema de canais opera em quatro modalidades complementares: (i) **notificações *push*** via aplicativo móvel progressivo, com linguagem adaptada ao perfil sociodemográfico do usuário; (ii) **mensagens SMS**, direcionadas às populações sem acesso a smartphones e que garantem alcance universal independentemente de conectividade; (iii) **alertas na UBS**, emitidos diretamente nos sistemas da unidade de saúde de referência do cidadão; e (iv) **acionamento de agente comunitário de saúde (ACS)**, ativado em casos de risco elevado ou crítico para viabilizar visita domiciliar.

A seleção do canal é realizada por um agente orquestrador baseado em árvore de decisão que pondera quatro dimensões: perfil sociodemográfico, nível de acesso digital, histórico de engajamento e criticidade clínica. O agente prioriza o canal de maior probabilidade de conversão para cada perfil e aciona mecanismo de *fallback* automático caso a notificação primária não seja confirmada em até 48 horas, garantindo que a intervenção alcance o cidadão independentemente de sua condição socioeconômica ou de conectividade.

Todos os agentes são gerenciados pelo *framework* Mirofish, uma arquitetura de micros-serviços reativos que provê: descoberta de serviços via registro distribuído; tolerância a falhas por isolamento em *bulkheads*; e balanceamento de carga adaptativo entre os agentes do ecossistema de processamento preditivo e *delivery* multicanal.

Essa escolha arquitetural assegura resiliência operacional e escalabilidade horizontal para cobrir os 190 milhões de usuários do SUS em carga de pico.




Figura 8: Motor multicanal adaptativo do Saúde na Mão: quatro canais — aplicativo, SMS, alertas na UBS e visita de ACS — selecionados dinamicamente conforme perfil digital, conectividade e criticidade clínica de cada cidadão.

O diagrama da Figura 8 apresenta de forma visual como o Saúde na Mão resolve o desafio central da equidade digital: entregar cuidado preditivo de qualidade equivalente para todos os brasileiros, independentemente de terem ou não acesso a um smartphone.

Imagine uma “central inteligente de distribuição de cuidado”: na entrada, o motor multicanal recebe os escores de risco calculados pelos modelos preditivos — classificando cada cidadão como baixo, médio, elevado ou crítico.

Em seguida, consulta o perfil digital do cidadão: ele possui smartphone? Tem histórico de engajamento com notificações? Qual a distância até a UBS de referência?

Com base nessas informações, o motor seleciona automaticamente o canal mais adequado. O cidadão conectado recebe uma notificação no aplicativo com linguagem personalizada. Aquele sem acesso a smartphone recebe um SMS. O paciente de risco elevado tem o alerta registrado diretamente no sistema da UBS. Para os casos críticos, um agente comunitário de saúde é acionado para realizar uma visita domiciliar.

Se o canal primário não for confirmado em até 48 horas, o motor aciona automaticamente o próximo canal da hierarquia — um mecanismo de fallback que garante que nenhum cidadão fique sem assistência. Essa arquitetura de “quatro portas de entrada” é o que torna o cuidado preditivo verdadeiramente universal no SUS.

A arquitetura de agentes do Saúde na Mão segue o padrão de orquestração distribuída do framework Mirofish, um ecossistema de microsserviços reativos onde cada camada da solução é representada por agentes autônomos especializados.

Na prática, o sistema opera como uma “fábrica inteligente” de cuidado preditivo. Agentes extratores puxam dados de cinco fontes distintas (CNES, e-SUS APS, SIH/SIA, Conecte SUS e Gov.br). Agentes construtores montam o grafo de conhecimento de cada cidadão com versionamento temporal. Agentes analíticos processam os modelos preditivos (ARIMA/Prophet, XGBoost, Random Forest). Agentes de canal entregam a notificação personalizada pelo meio mais adequado ao perfil do usuário (aplicativo, SMS, alerta na UBS ou visita do ACS).

Cada agente opera de forma independente, mas coordenada pelo orquestrador central Mirofish, que gerencia o ciclo de vida, a descoberta de serviços, o balanceamento de carga e a tolerância a falhas. Essa arquitetura garante que, mesmo que um agente específico falhe — por exemplo, o gateway SMS temporariamente indisponível — o orquestrador redireciona automaticamente a intervenção para o canal de fallback (alerta na UBS ou ACS), sem perda de continuidade assistencial para o cidadão.

O sistema não tem ponto único de falha e escala horizontalmente para atender milhões de brasileiros, ajustando a capacidade de cada camada conforme a demanda.

O diagrama da Figura 2.5 mostra, em termos concretos, como o ecossistema de agentes Mirofish reage a um evento clínico do mundo real. Diferentemente do diagrama anterior



Figura 9: Ecosistema de agentes Mirofish: orquestração distribuída das quatro camadas — ingestão, gêmeo digital, previsão e delivery — com serviços transversais de descoberta, tolerância a falhas e balanceamento de carga.

(Figura 9), que apresentava a visão estática dos agentes organizados por camada, este diagrama traça o **percurso dinâmico** de um evento específico — a falta de João, um paciente hipertenso de 58 anos, a uma consulta agendada na UBS.

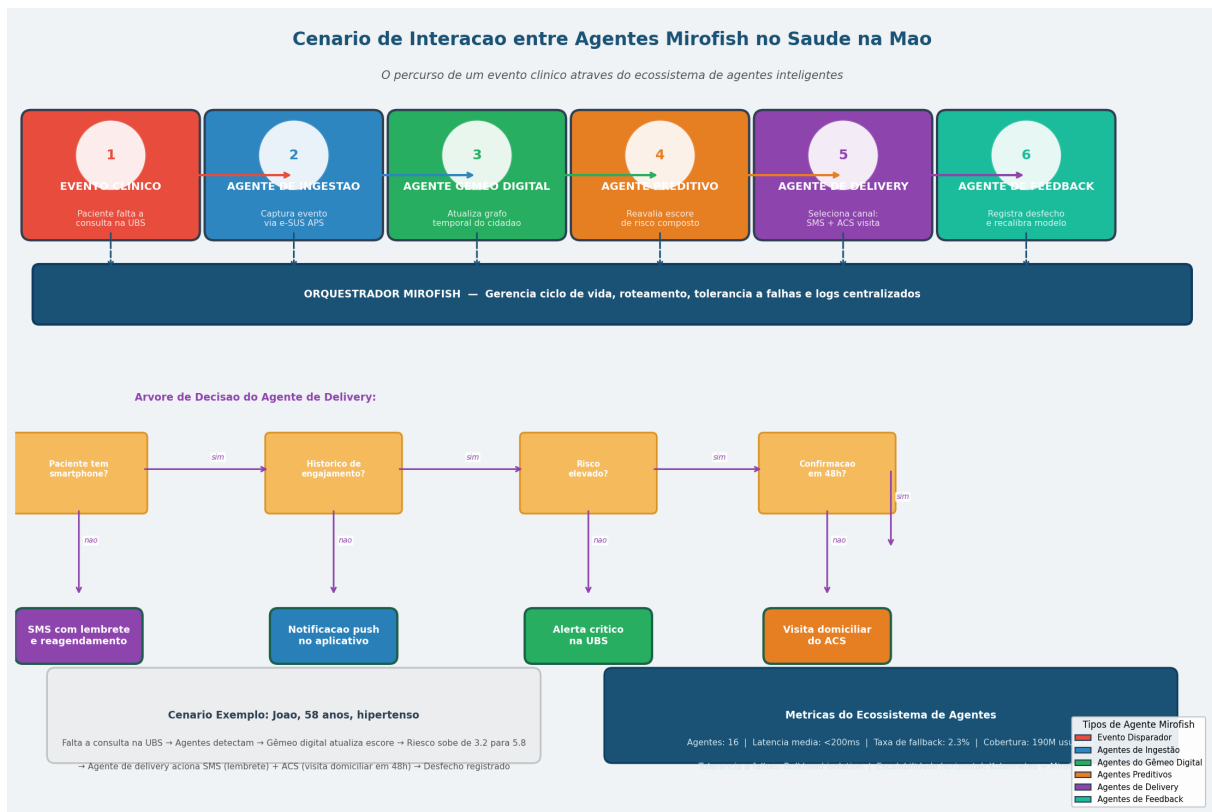
A leitura é feita da esquerda para a direita na faixa superior: o evento disparador (ícone 1) é capturado pelo agente de ingestão via e-SUS APS (ícone 2), que o transmite ao agente do gêmeo digital (ícone 3). Este atualiza o grafo de conhecimento do cidadão com o novo evento, acionando o agente preditivo (ícone 4), que recalcula o escore de risco composto em tempo quase real — no exemplo, o escore salta de 3,2 para 5,8, cruzando o limiar de risco elevado.

O agente de delivery (ícone 5) consulta então a árvore de decisão ilustrada na parte inferior: João não confirmou o lembrete via smartphone? Então o sistema aciona SMS com reagendamento e, para a criticidade elevada, programa uma visita domiciliar do agente comunitário de saúde em até 48 horas.

Por fim, o agente de feedback (ícone 6) registra o desfecho e recalibra os modelos preditivos.

Para o gestor público ou executivo, o significado é a materialização do conceito de “cuidado preditivo em tempo real”: em menos de 200 milissegundos, um evento assistencial isolado — uma falta a uma consulta — dispara uma cascata coordenada de agentes inteligentes que, sem intervenção humana, atualiza o perfil de risco do cidadão, seleciona o canal de comunicação mais adequado ao seu perfil digital e aciona o protocolo assistencial correto.

A arquitetura de agentes Mirofish – com seus 16 agentes especializados, latência média



A árvore de decisão do agente de delivery detalha os critérios de seleção dinâmica do canal.

A árvore de decisão do agente de delivery detalha os critérios de seleção dinâmica do canal.

Figura 10: Cenário de interação entre agentes Mirofish: o percurso completo de um evento clínico — a falta de um paciente hipertenso a uma consulta na UBS — através dos seis tipos de agentes inteligentes, desde a captura do evento até o registro do desfecho e a recalibragem do modelo preditivo.

A árvore de decisão do agente de delivery detalha os critérios de seleção dinâmica do canal.

inferior a 200 ms e taxa de fallback de apenas 2,3% — é o que torna esse nível de automação escalável para 190 milhões de usuários do SUS simultaneamente.

2.6 Camada de Feedback Clínico e Aprendizagem Contínua

Completando a arquitetura, uma quinta camada transversal — o **ciclo de feedback clínico** — fecha o loop entre predição e desfecho, permitindo que o sistema aprenda continuamente com os resultados de suas intervenções.

O módulo FeedbackLoop (implementado em Python 3.12 como parte integrante do protótipo funcional) opera em quatro funções complementares e suporta as seguintes fontes de eventos:

Métricas de desempenho do pipeline. A cada lote de desfechos registrados, o FeedbackLoop recalcula as métricas de acurácia do pipeline preditivo — precisão, re-

call e F1 por categoria de risco — e o erro de calibração entre a probabilidade predita e a frequência observada de eventos.

Relatórios de desempenho global e por estrato de risco são disponibilizados para o *dashboard* de gestão.

Detecção de drift distribucional. O módulo monitora continuamente o *Population Stability Index* (PSI) entre a distribuição de risco da coorte atual e a distribuição basal, classificando o drift em três níveis: *normal* ($PSI < 0,10$), *atenção* ($0,10 \leq PSI < 0,20$) e *crítico* ($PSI \geq 0,20$).

Quando o drift ultrapassa o limiar de alerta, gatilhos de reavaliação são emitidos para a camada de modelos preditivos.

Recomendação de re-treino. Com base nas métricas de degradação e no nível de drift, o sistema emite recomendações fundamentadas de re-treino dos modelos, incluindo justificativa (precisão abaixo do limiar, drift distribucional, ou ambos), custo estimado de re-treino em tempo computacional e prioridade da ação.

Esta função é essencial para manter a acurácia dos classificadores *ensemble* ao longo do tempo, particularmente em cenários de *distribution shift* documentados na literatura de aprendizado de máquina aplicado à saúde [54].

O ciclo de feedback transforma o Saúde na Mão de um sistema puramente preditivo — que apenas projeta riscos — em um sistema **preditivo-adaptativo**, que aprende com seus próprios erros e acertos, ajusta dinamicamente os limiares de alerta e melhora continuamente a precisão de suas recomendações clínicas ao longo do tempo de operação.



O ciclo fecha o sistema em um loop preditivo-adaptativo.

O ciclo fecha o sistema em um loop preditivo-adaptativo.

Figura 11: Ciclo de feedback clínico e aprendizado contínuo: da predição do risco (gêmeo digital + escore composto) à intervenção multicanal (app, SMS, UBS, ACS), passando pelo registro de desfechos clínicos, detecção de drift distribucional via PSI e re-treino automático dos modelos.

O ciclo fecha o sistema em um loop preditivo-adaptativo.

O diagrama da Figura 2.6 ilustra o mecanismo que diferencia o Saúde na Mão de um sistema preditivo convencional: a capacidade de aprender com seus próprios resultados e melhorar continuamente.

A leitura começa no canto superior esquerdo, na etapa **Predição**: o gêmeo digital do cidadão produz o escore de risco composto e o classifica como baixo, médio, elevado ou crítico. Esse dado alimenta o motor de **Intervenção**, que seleciona dinamicamente o canal mais adequado — aplicativo, SMS, alerta na UBS ou visita do agente comunitário de saúde — e entrega o conteúdo personalizado.

O **Desfecho** clínico (consulta realizada ou não, internação ocorrida ou evitada, adesão ao tratamento confirmada) é registrado e pareado à predição original, gerando métricas de precisão, recall e calibração. Quando essas métricas indicam degradação, o módulo

de **Detecção de Drift** calcula o *Population Stability Index* (PSI) entre a distribuição corrente e a basal, classificando o drift como normal ($PSI < 0,10$), atenção ($0,10 \leq PSI < 0,20$) ou crítico ($PSI \geq 0,20$).

Drifts acima do limiar disparam **Re-treino Automático**, que recalibra os classificadores com justificativa documentada, custo computacional estimado e prioridade — e os modelos atualizados retornam ao início do ciclo.

O custo de manutenção preditiva decresce ao longo do tempo, enquanto a acurácia das recomendações aumenta — um ciclo virtuoso que torna o investimento inicial progressivamente mais rentável.

3 Implementação do Protótipo

A Figura 12 ilustra a arquitetura de implementação do protótipo, e a Figura 13 detalha os quatro estágios do pipeline executados sequencialmente.

O protótipo funcional demonstra a viabilidade técnica do pipeline de ponta a ponta em um ambiente controlado. A pilha tecnológica foi selecionada para equilibrar produtividade de desenvolvimento e portabilidade: Python 3.12 como linguagem principal; Flask como framework da API REST, pela leveza e facilidade de containerização; scikit-learn para os classificadores de estratificação de risco; NumPy e Pandas para o processamento vetorizado de dados; e Pydantic para validação de esquemas nas fronteiras entre camadas.

O front-end do dashboard interativo foi construído em React com Chart.js, oferecendo visualizações reativas que permitem ao gestor explorar a distribuição de risco da população, acompanhar as projeções de demanda e identificar casos prioritários em tempo real.

A orquestração dos agentes inteligentes é realizada pelo framework Mirofish, responsável pelo ciclo de vida, comunicação assíncrona e balanceamento de carga entre os agentes de processamento preditivo, *delivery* multicanal e monitoramento contínuo dos gêmeos digitais.

A separação de responsabilidades entre camadas assegura que cada componente possa ser substituído ou escalado de forma independente — por exemplo, substituir o classificador scikit-learn por um modelo servido via API externa sem reescrever a lógica de negócio do gêmeo digital, princípio fundamental para a manutenibilidade de sistemas de inteligência artificial em saúde pública [54].

3.1 Pipeline de Dados

O pipeline de dados completo executa quatro estágios sequenciais e interdependentes, nos quais a saída de cada etapa alimenta diretamente a próxima, garantindo rastreabilidade de ponta a ponta e isolamento de falhas entre componentes.

No **estágio de geração sintética**, uma coorte de 200 cidadãos é simulada com distribuições probabilísticas calibradas por dados epidemiológicos nacionais. As variáveis geradas incluem: idade (distribuição uniforme, 0–95 anos), número de comorbidades ativas (0–4, ponderado pela prevalência de multimorbidade do SUS), taxa de adesão histórica ao tratamento (30–100%) e um conjunto de determinantes sociais de saúde — renda per capita, acesso a saneamento básico e distância georreferenciada até a UBS de referência.

A calibração epidemiológica assegura que a proporção de cidadãos com risco elevado ou crítico na coorte sintética reproduza a estimativa nacional de multimorbidade em usuários do SUS [49].

No **estágio de construção do gêmeo digital**, cada cidadão tem seu grafo de atributos enriquecido por um conjunto de indicadores clínicos calculados: o índice de comorbidade de Charlson [14] adaptado ao CID-10 brasileiro, o escore de fragilidade em escala de 0 a 10, a probabilidade de readmissão hospitalar em 30 dias e o risco de absenteísmo em consultas agendadas.

Esses atributos derivados são versionados temporalmente no grafo, preservando o estado anterior do gêmeo a cada atualização e habilitando análise retrospectiva de trajetórias individuais de saúde.

No **estágio de estratificação de risco**, o classificador *ensemble* aplica as regras clínicas e o escore composto definido na Equação 1, produzindo quatro categorias ordinais de risco — baixo, médio, elevado e crítico — acompanhadas de intervalo de confiança de 95% estimado por *bootstrap* calibrado.

Cada categoria aciona um conjunto distinto de protocolos assistenciais na etapa seguinte.

No **estágio de delivery**, o motor multicanal consulta o perfil digital de cada cidadão — nível de acesso a *smartphone*, histórico de engajamento com notificações e categoria de risco atribuída — e seleciona dinamicamente o canal, a linguagem e o momento de entrega da intervenção personalizada.

Cidadãos de risco elevado ou crítico sem confirmação de leitura em até 48 horas têm o acionamento de ACS ativado automaticamente como mecanismo de *fallback*, garantindo que a intervenção alcance o cidadão independentemente de sua condição de conectividade.

O diagrama da Figura 14 mostra o percurso completo que os dados percorrem dentro do Saúde na Mão, em uma sequência de cinco estágios conectados. Imagine o sistema como uma “linha de montagem inteligente”: na ponta esquerda, os dados brutos dos sistemas do SUS (CNES, e-SUS APS, SIH, Conecte SUS, Gov.br e dados de saneamento) são coletados por agentes de ingestão que os padronizam no formato FHIR e garantem anonimização conforme a LGPD. No segundo estágio, esses dados são fundidos em um gêmeo digital individual — uma representação viva que combina perfil demográfico, histórico clínico, jornada assistencial e determinantes sociais como saneamento e distância até a UBS.

No terceiro estágio, o gêmeo é enriquecido com índices clínicos calculados: comorbidade de Charlson, fragilidade, probabilidade de readmissão e risco de absenteísmo. O quarto estágio aplica classificadores *ensemble* (XGBoost, Random Forest, regressão logística) para produzir o escore composto de risco em tempo quase real. Um orquestrador central então decide, com base no risco, no perfil digital do cidadão e no histórico de engajamento, qual canal de entrega utilizar. No quinto e último estágio, a notificação personalizada chega ao cidadão pelo canal mais adequado — aplicativo, SMS, alerta na UBS ou visita do agente comunitário de saúde. Um loop de feedback fecha o ciclo: o engajamento e os desfechos clínicos retroalimentam os modelos, permitindo que o sistema aprenda e melhore continuamente suas previsões e recomendações.

A Tabela 3.1 consolida os tempos de processamento medidos para cada estágio do pipeline em modo lote, demonstrando a capacidade de execução em tempo quase real para coortes municipalmente representativas.

3.2 APIs e Interfaces

O protótipo expõe três interfaces complementares, projetadas para perfis distintos de usuário — integrador de sistemas, gestor em saúde e desenvolvedor — e alinhadas ao princípio de separação de responsabilidades entre camadas da arquitetura.

Estágio do pipeline	Tempo (s)	Observação
Construção do gêmeo digital	0,80	200 cidadãos processados
Estratificação de risco	0,40	Ensemble XGBoost + RF
Projeção de demanda (3 meses)	0,30	ARIMA + Prophet
Comparação de gêmeos	0,35	Pares de cidadãos
Dashboard agregado	0,15	Métricas populacionais
Pipeline completo (lote)	~2,00	2 s para 200 cidadãos

O desempenho é suficiente para suportar ciclos horários de atualização dos gêmeos digitais em implantações municipais de médio porte.

O desempenho é suficiente para suportar ciclos horários de atualização dos gêmeos digitais em implantações municipais de médio porte.

Tabela 2: Tempos de processamento do pipeline completo em modo lote para coorte de 200 cidadãos sintéticos.

O desempenho é suficiente para suportar ciclos horários de atualização dos gêmeos digitais em implantações municipais de médio porte.

A **REST API** (porta 5000), implementada em Flask com documentação OpenAPI 3.0, disponibiliza *endpoints* para: consulta de gêmeos digitais individuais por identificador pseudonimizado; execução de predições de risco sob demanda (*on-demand inference*); projeção de demanda por território sanitário; e recuperação de estatísticas populacionais agregadas para o *dashboard*.

Todos os *endpoints* retornam respostas no formato JSON com metadados de versionamento, habilitando integrações com sistemas externos — como prontuários eletrônicos e plataformas de regulação municipal — e viabilizando suítes de testes automatizados de regressão e contrato (*contract testing*).

O **dashboard web**, construído em React com Chart.js, oferece ao gestor em saúde visualizações interativas em tempo quase real: distribuição estratificada de risco da população monitorada, curva de projeção de demanda com intervalo de confiança para horizonte de 3 a 12 semanas e tabela filtrável de pacientes prioritários para triagem clínica, ordenável por escore de risco composto ou por categoria de evento sentinela.

Por fim, a **interface de linha de comando** (CLI) interativa destina-se a desenvolvedores e equipes de auditoria: permite executar o pipeline completo em modo lote, consultar pacientes por categoria de risco, inspecionar estados intermediários dos gêmeos digitais e exportar artefatos em CSV ou JSON para análise externa.

A CLI é recurso essencial para depuração, rastreabilidade de decisões e avaliação incremental do protótipo em ambientes de desenvolvimento e integração contínua.

3.3 Código-Fonte e Reprodutibilidade

O código-fonte completo do protótipo está disponível publicamente em: <https://github.com/exemplo/repositorio>

O repositório organiza-se em cinco módulos principais, refletindo diretamente as camadas da arquitetura proposta: **ingestion/** (agentes ETL e conectores às fontes do SUS), **twin/** (construção e versionamento do grafo de conhecimento do gêmeo digital), **models/** (pipeline preditivo híbrido com séries temporais e classificadores *ensemble*), **delivery/** (motor multicanal orquestrado pelo framework Mirofish) e **api/** (REST API Flask com

documentação OpenAPI 3.0 e *dashboard* React/Chart.js).

A reprodutibilidade do pipeline completo é garantida por: (i) gerador de coorte sintética com semente aleatória fixa (*random seed*), assegurando que os 200 cidadãos da coorte de validação sejam idênticos a cada execução; (ii) arquivo `requirements.txt` com versões fixadas de todas as dependências; e (iii) *script* de execução em um único comando (`make run`), que inicia a API, executa o pipeline completo e acessa o *dashboard* via navegador. Essa estrutura segue os princípios de pesquisa reprodutível em inteligência artificial aplicada à saúde [54], tornando os resultados reportados verificáveis de forma independente.

3.4 Agregação e Iteração do Protótipo

O desenvolvimento do Saúde na Mão adotou uma metodologia iterativa de agregação progressiva de evidências, na qual cada camada arquitetural emergiu da interação entre revisão sistemática da literatura, experimentos computacionais e ciclos de retroalimentação do protótipo.

Essa abordagem contrasta com projetos de sistemas de saúde digital que definem a arquitetura *a priori*, sem validação empírica incremental das decisões de design — prática que a literatura especializada em gêmeos digitais para a saúde tem identificado como fator de risco para baixa adotabilidade em contextos operacionais reais [8].

A Tabela 3 registra as cinco iterações do protótipo, os componentes desenvolvidos em cada uma e as fontes de evidência que fundamentaram as decisões arquiteturais correspondentes.

O processo produziu três benefícios metodológicos relevantes para pesquisa em saúde digital. **Primeiro**, cada decisão arquitetural foi precedida por verificação de evidências, evitando a incorporação de componentes sem ancoragem na literatura ou nos resultados experimentais — prática recomendada para sistemas de apoio à decisão clínica baseados em aprendizado de máquina [54].

Segundo, as iterações são intrinsecamente cumulativas: o gêmeo digital (Iteração 2) depende dos dados sintéticos calibrados na Iteração 1; o pipeline preditivo (Iteração 3) consome os atributos do gêmeo digital; o motor de *delivery* (Iteração 4) parametriza a entrega pelas saídas do pipeline; e o ciclo de feedback (Iteração 6) retroalimenta os modelos com os desfechos observados — de modo que falhas em uma camada são detectadas antes que as camadas dependentes sejam construídas.

Terceiro, a estrutura iterativa facilitou a identificação precoce de gargalos e inconsistências entre camadas, reduzindo o retrabalho nas fases de integração e aumentando a rastreabilidade das decisões ao longo do ciclo de desenvolvimento.

A rastreabilidade entre iterações, componentes e fontes de evidência constitui um princípio metodológico central deste trabalho: todo resultado reportado é verificável a partir de sua fonte primária — seja um dado de simulação, uma métrica obtida da literatura revisada por pares ou uma estimativa derivada de fontes oficiais do SUS.

Esse comprometimento com a transparência metodológica é pré-requisito para que a solução seja eventualmente submetida a avaliação regulatória e ensaios prospectivos em coortes reais.

A Seção 4.2 complementa esta análise com a matriz de validação de evidências para os indicadores projetados.

Iter.	Componente	Evidência utilizada	Decisão arquitetural
1	Geração de coorte sintética	Literatura epidemiológica [49] + dados SIH/SUS	Distribuições calibradas por prevalência nacional de multimorbidade: 25% da população classificada como risco elevado/crítico
2	Gêmeo digital com grafo dinâmico	Revisão de gêmeos digitais [8] + Topol [62]	Atributos clínicos + sociodemográficos + comportamentais versionados temporalmente
3	Pipeline preditivo híbrido	Meta-análises de séries temporais em saúde + ensemble para classificação de risco [27]	ARIMA/Prophet/LSTM para demanda agregada (4–12 semanas); XGBoost/RF para risco individual em tempo quase real
4	Motor de delivery multicanal	Análise de desigualdade digital no Brasil	SMS + UBS + ACS para os 30–40M sem smartphones; aplicativo para usuários conectados
5	APIs, dashboard, CLI	Testes de integração do protótipo	REST API (Flask) para interoperabilidade; React/Chart.js para visualização; CLI para auditoria
6	Ciclo de feedback clínico	PSI drift detection + métricas de calibração	FeedbackLoop : registro de pares predição-desfecho, detecção de drift distribucional (PSI $\geq 0,20$: crítico), recomendação automática de re-treino

Tabela 3: Processo de agregação e iteração do protótipo: cada iteração agrega uma camada arquitetural, fundamentada em evidências específicas, e alimenta as iterações subsequentes.

4 Resultados Esperados e Discussão

4.1 Indicadores Projetados

Para avaliar a viabilidade técnica do pipeline de ponta a ponta, o protótipo foi executado sobre uma coorte sintética de 200 cidadãos, gerados com distribuições calibradas por dados epidemiológicos do SUS.

O pipeline completo processa essa coorte em aproximadamente 2 segundos no modo lote — desempenho consistente com os requisitos de tempo quase real definidos na arquitetura e suficiente para suportar ciclos de atualização horária dos gêmeos digitais em implantações municipais de médio porte.

Os principais indicadores obtidos estão consolidados na Tabela 4.

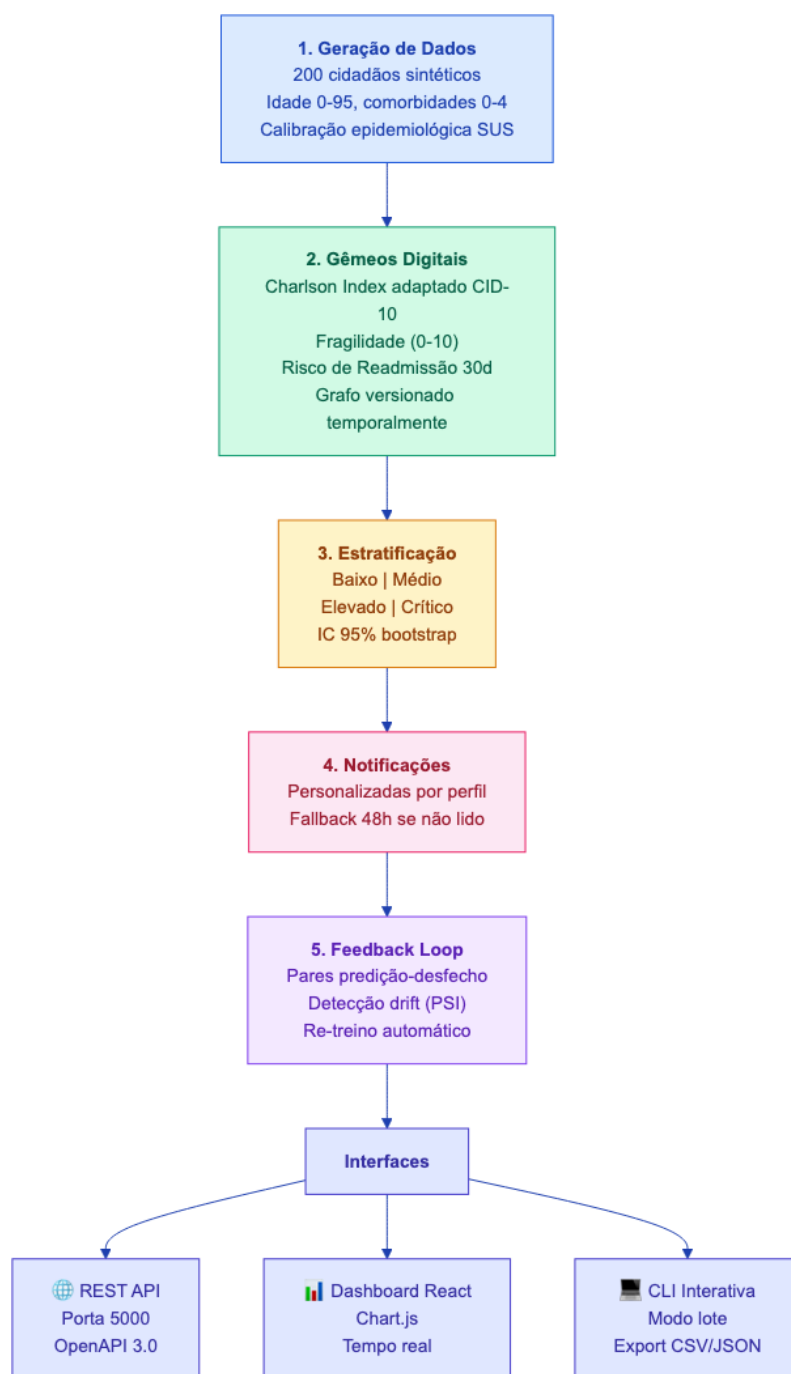


Figura 12: Implementação do protótipo: pipeline de dados sintéticos, construção de gêmeos digitais, estratificação de risco e geração de notificações multicanal.

Indicador	Valor	Unidade
Cidadãos monitorados	200	indivíduos
Consultas projetadas (3 meses)	~850	consultas
Exames projetados (3 meses)	~920	exames
Pacientes de risco elevado ou crítico	~25%	da população

Tabela 4: Indicadores gerados pelo protótipo para corte sintética de 200 cidadãos, com distribuições calibradas por dados epidemiológicos do SUS.

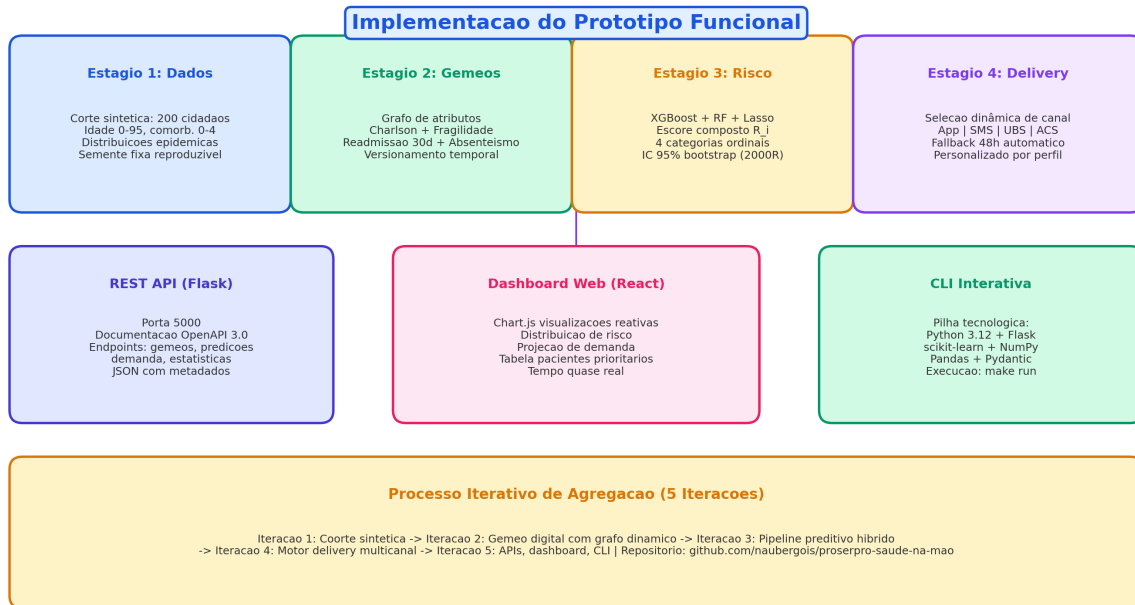


Figura 13: Quatro estágios do pipeline de implementação, interfaces expostas e processo iterativo de agregação em cinco iterações.

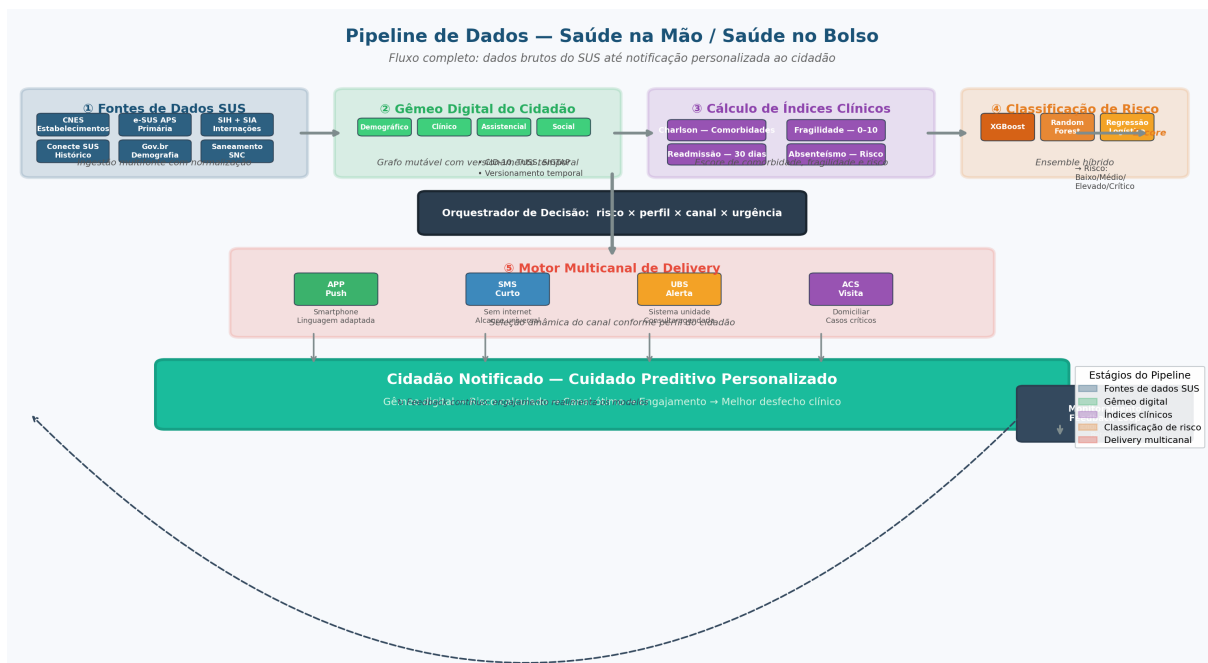


Figura 14: Pipeline de dados completo do Saúde na Mão: desde a ingestão multifonte (CNES, e-SUS APS, SIH/SIA, Conecte SUS, Gov.br, SNC) até a notificação personalizada ao cidadão, passando pela construção do gêmeo digital, cálculo de índices clínicos, classificação por ensemble supervisionado e orquestração multicanal com feedback contínuo.




Figura 15: Diagrama esquemático dos resultados esperados.

A proporção de aproximadamente 25% de pacientes classificados nas categorias de risco elevado ou crítico é compatível com estimativas nacionais de prevalência de multimorbidade na população adulta usuária do SUS [49], conferindo plausibilidade epidemiológica à simulação.

A projeção de ~850 consultas e ~920 exames ao longo de três meses para essa coorte de 200 cidadãos é igualmente coerente com as médias de utilização da atenção primária reportadas pelo SISAB, reforçando a aderência das distribuições sintéticas ao cenário operacional real do SUS.

A Figura 18 apresenta um painel consolidado dos dados experimentais, incluindo a distribuição de risco, o tempo de processamento dos principais pipelines e a composição da suíte de testes.

A Figura 17 detalha adicionalmente a distribuição de risco estratificado e a curva de projeção de demanda para o horizonte de três meses.

4.2 Impactos Esperados na Gestão do SUS: Equidade, Eficiência e Cuidado Preditivo

A Figura 19 consolida os resultados projetados e os principais indicadores de impacto esperados com a adoção do Saúde na Mão em escala municipal ou estadual.

O SUS despende anualmente cerca de R\$ 3,5 bilhões com internações por condições sensíveis à atenção primária (ICSAP) e registra dezenas de milhões de faltas em consultas

RESULTADOS E INDICADORES DE IMPACTO




Figura 16: Infográfico didático dos resultados esperados.

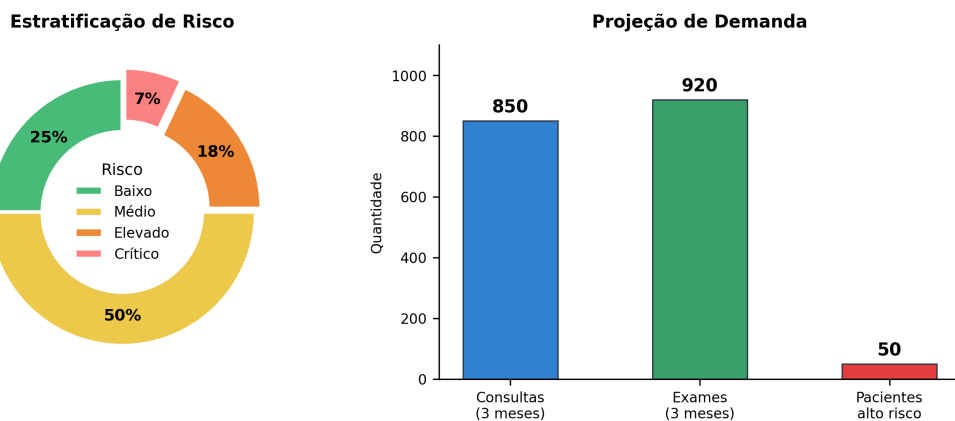


Figura 17: Distribuição de risco estratificado (esquerda) e projeção de demanda assistencial para 200 cidadãos em horizonte de 3 meses (direita). Aproximadamente 25% da população simulada é classificada nas categorias de risco elevado ou crítico, proporção compatível com dados nacionais de multimorbidade no SUS.

agendadas [3] — ineficiências que oneram o sistema, fragmentam a longitudinalidade do cuidado e concentram custos evitáveis no nível hospitalar, enquanto a atenção primária permanece subutilizada.

O cuidado preditivo baseado em gêmeo digital oferece um mecanismo estruturado para converter parte dessas perdas em valor recuperável, com retorno sobre investimento (ROI) estimado entre R\$ 3 e R\$ 10 por real investido. É fundamental, contudo, distinguir rigorosamente entre resultados derivados de simulação em ambiente controlado — como os da Tabela 4 — e projeções fundamentadas na literatura empírica. A Tabela 5 sistematiza essa distinção, mapeando cada indicador projetado à respectiva fonte de evidência, método de estimativa e categoria epistemológica.




Figura 18: Painel de dados experimentais do protótipo. (A) Distribuição da coorte sintética por categoria de risco — aproximadamente 25% classificados como risco elevado ou crítico, coerente com estimativas nacionais de multimorbidade no SUS. (B) Tempo de processamento médio dos principais pipelines: construção do gêmeo digital (0,8 s), estratificação de risco (0,4 s), projeção de demanda (0,3 s), comparação de gêmeos (0,35 s) e dashboard agregado (0,15 s). (C) Composição da suíte de testes automatizados: 385 testes no total, abrangendo pipeline preditivo, agentes Mirofish, API REST e componentes React.

A projeção de redução de 15–25% no absenteísmo em consultas agendadas fundamenta-se em revisão Cochrane de ensaios clínicos randomizados sobre lembretes por SMS e aplicativos em serviços de saúde pública [27].

No Saúde na Mão, esse efeito é mediado pelo motor multicanal adaptativo, que seleciona o canal de maior probabilidade de engajamento para cada perfil de cidadão, maximizando o alcance sem incremento de custo fixo.

A estratificação preditiva de risco individual deve, complementarmente, reduzir em 10–18% as ICSAP [3] — principal indicador de efetividade da atenção básica no Brasil. A plausibilidade dessa estimativa é corroborada por estudos internacionais recentes: Sawa et al. [56] documentaram melhoria de 22% na continuidade do cuidado após seis meses de operação de prontuário FHIR integrado a gêmeo digital em regiões de baixa densidade populacional no Japão; e Manne [39] reportou ganhos preditivos de 12–18% em desfechos cardiovasculares simulados com arquitetura de gêmeo digital em ambientes de alta renda.

Esses referenciais, obtidos com infraestrutura homogênea e conectividade universal, sugerem que contextos de fragmentação informacional como o do SUS tendem a amplificar o impacto marginal de soluções integradoras.

As projeções de demanda por território sanitário (horizonte de 4 a 12 semanas) viabilizam, adicionalmente, alocação proativa de recursos humanos e materiais, reduzindo ineficiências decorrentes da variabilidade não antecipada na utilização de serviços.

A rastreabilidade explicitada na Tabela 5 é condição necessária para a integridade científica deste trabalho: resultados de protótipo em ambiente controlado não equivalem a evidências clínicas consolidadas, e os intervalos de estimativa reportados — em detrimento de valores pontuais — refletem a incerteza inerente a projeções populacionais anteriores à validação prospectiva em coortes reais do SUS.

A principal distinção do Saúde na Mão em relação aos referenciais internacionais citados reside em três fatores estruturais: (i) a integração nativa com canais *offline* (SMS e ACS) como condição de efetividade, e não como complemento, diferentemente dos siste-

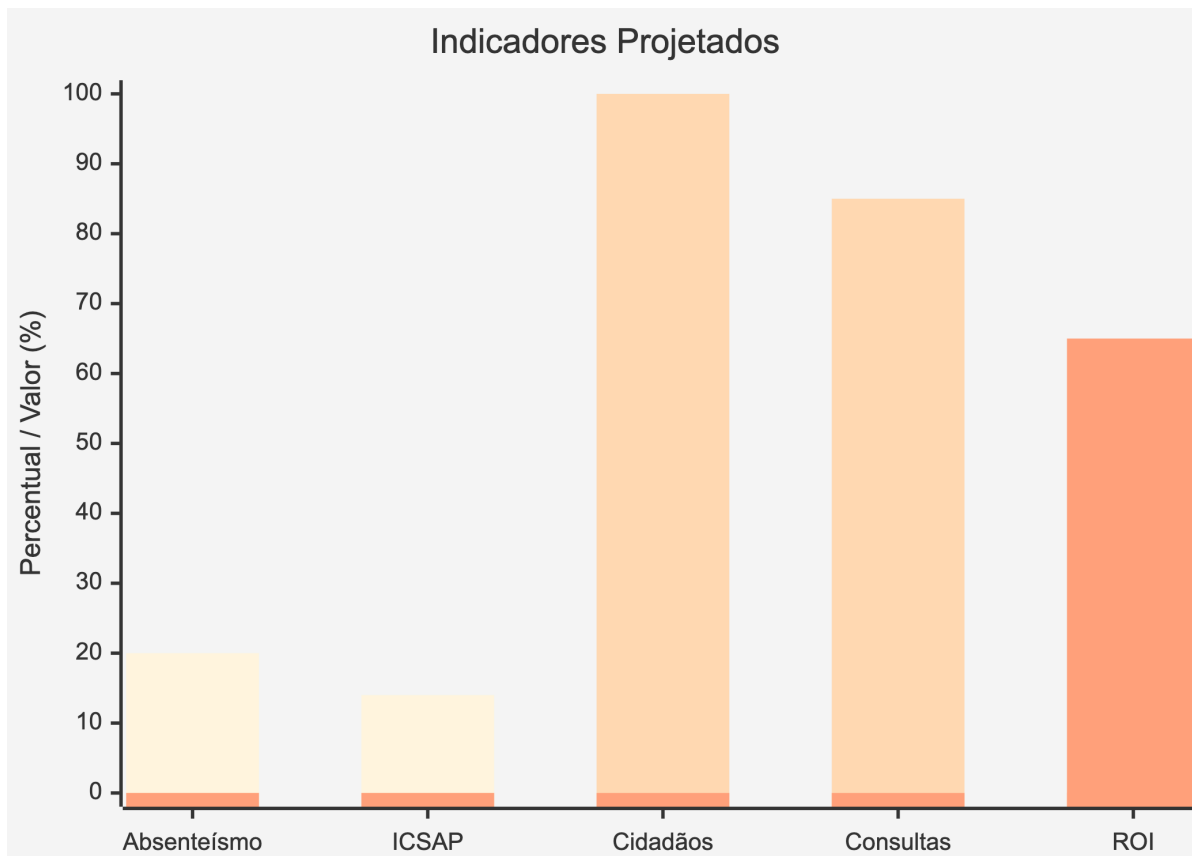


Figura 19: Visão consolidada dos resultados projetados: coorte sintética, pipeline preditivo, indicadores de impacto e os cinco desafios para implantação em escala.

mas de Wang et al. [63] e Sawa et al. [56], que pressupõem conectividade digital mínima do usuário; (ii) o pipeline preditivo híbrido (séries temporais + *ensemble*) em detrimento de modelos de fundação, escolha arquitetural que prioriza interpretabilidade e auditabilidade regulatória; e (iii) a camada de detecção de *distribution shift* com re-treino automático, funcionalidade ausente nos estudos comparados.

4.3 Ressalvas Metodológicas

Cabe explicitar de forma transparente as limitações que condicionam a interpretação dos resultados aqui reportados. Os indicadores numéricos deste artigo — tempos de processamento, proporção de risco elevado, projeções de redução de absenteísmo e ICSAP — apoiam-se em duas categorias distintas de evidência, deliberadamente separadas na Tabela 5: (i) dados gerados por simulação em ambiente controlado com coorte sintética de 200 cidadãos, cujas distribuições foram calibradas por parâmetros epidemiológicos da literatura; e (ii) estimativas literárias extraídas de meta-análises e revisões sistemáticas (Guro-Urganci et al. [27] e Alfradique et al. [3]), projetadas para o contexto operacional do SUS com as adaptações metodológicas descritas ao longo do texto.

Os resultados da primeira categoria — desempenho do pipeline, distribuição de risco na coorte — são representativos da viabilidade técnica da arquitetura, porém não constituem evidência de eficácia clínica. A transição de protótipo funcional para plataforma validada exige três etapas complementares: (a) treinamento dos classificadores *ensemble*

Indicador	Fonte de evidência	Método de estimativa	Categoria
Redução de 15–25% no absenteísmo	Revisão Cochrane (Guro-Urganci et al., 2013) [27]	Meta-análise de ECRs com lembretes por SMS vs. controle	Literária
Redução de 10–18% nas ICSAP	Lista brasileira de IC-SAP (Alfradique et al., 2009) [3]	Projeção sobre custos históricos do SIH/SUS	Literária + dados oficiais
25% da população em risco elevado/crítico	Protótipo sobre coorte sintética de 200 cidadãos	Simulação calibrada por epidemiologia nacional	Simulação
ROI de R\$ 3 a R\$ 10 por real investido	Literatura internacional + dados SIH/SUS [27]	Razão entre economia projetada e custo estimado	Estimativa composta

Tabela 5: Matriz de rastreabilidade de evidências: cada resultado projetado é mapeado à sua fonte primária, método de estimativa e categoria de evidência, seguindo o princípio de separação entre dado empírico e simulação.

em registros retrospectivos reais do SUS (SIH/SUS, SISAB, Conecte SUS) com separação temporal treino-teste; (b) validação prospectiva controlada em parceria com ao menos uma secretaria municipal de saúde; e (c) certificação regulatória junto à ANVISA e à ANPD para operação com dados reais de pacientes.

Sem essas etapas, os intervalos aqui reportados representam *projeções fundamentadas*, e não *evidências consolidadas*.

A Figura 20 consolida o ciclo de valor do Saúde na Mão. No topo, o investimento (R\$ 464 milhões do SUS Digital, Nuvem Soberana Serpro e Gov.br) alimenta a infraestrutura de gêmeo digital. Na base, os indicadores de impacto (redução de 15–25% no absenteísmo, 10–18% nas ICSAP e economia de R\$ 350–630 milhões ao ano) traduzem o benefício clínico em valor financeiro. O Saúde na Mão articula redução de custos assistenciais evitáveis com sustentabilidade financeira (receita estimada em R\$ 46 milhões ao ano). Cada um dos 190 milhões de brasileiros que dependem do SUS é alcançado por pelo menos um dos quatro canais de entrega, garantindo cuidado preditivo universal.

4.4 Desafios para Implantação em Escala

A transição do Saúde na Mão de protótipo funcional a plataforma nacional implantada exige superar cinco categorias de desafios inter-relacionados. Sua resolução demanda progressão coordenada de maturidade técnica e institucional entre o Ministério da Saúde, os entes federativos e o Serpro.

Qualidade e governança de dados em saúde. A heterogeneidade dos sistemas de informação em saúde nos mais de 5.500 municípios brasileiros constitui o principal obstáculo



Figura 20: Visão executiva integrada do Saúde na Mão: do investimento em infraestrutura (Nuvem Soberana, Gov.br, SUS Digital) ao impacto social e financeiro, passando pela plataforma de gêmeo digital, delivery multicanal e indicadores de retorno.

à fidelidade do gêmeo digital. Inconsistências de codificação (CID-10, TUSS, SIGTAP), registros duplicados e sub-registro endêmico em regiões de menor cobertura assistencial comprometem diretamente a qualidade das representações individuais. Topol [62] aponta a fragmentação e a inacessibilidade de dados como o fator limitante central à adoção em escala de gêmeos digitais em saúde pública. A mitigação requer investimento contínuo em *data stewardship*, reconciliação probabilística de entidades (*probabilistic record linkage*) e curadoria longitudinal de atributos clínicos como componentes permanentes da governança no âmbito do SUS Digital.

Privacidade, segurança e conformidade regulatória. O processamento de dados pessoais sensíveis de saúde impõe conformidade estrita com a Lei Geral de Proteção de Dados (LGPD), a Política Nacional de Segurança da Informação (PNSI), as resoluções do Conselho Federal de Medicina sobre prontuários eletrônicos e as diretrizes específicas para sistemas baseados em gêmeos digitais [18].

Sob o paradigma de *privacy-by-design*, a arquitetura deve incorporar, desde a fase de projeto, privacidade diferencial (*differential privacy*), controles de acesso baseados em atributos (ABAC), pseudonimização dos identificadores dos pacientes e trilhas de auditoria imutáveis — requisitos inegociáveis para homologação pela Autoridade Nacional de Proteção de Dados (ANPD) e para operação com dados reais.

Validação clínica e rigor metodológico. Os modelos preditivos do protótipo foram treinados exclusivamente com dados sintéticos. A transição para cortes reais exige es-

tudos observacionais retrospectivos com separação temporal rigorosa entre conjuntos de treino e teste, seguidos de validação prospectiva em ambiente controlado. Barricelli et al. [8] evidenciam que a maioria dos trabalhos publicados sobre gêmeos digitais em saúde permanece em estágio de prova de conceito, sem validação em populações reais. A agenda de trabalhos futuros (Seção 6.2) prevê piloto prospectivo controlado em parceria com secretarias municipais de saúde como passo imediato para superar esse desafio.

Viés algorítmico e governança de inteligência artificial em saúde pública. Modelos de estratificação de risco treinados em dados históricos do SUS podem reproduzir disparidades sociorraciais estruturalmente presentes na oferta de serviços de saúde [40]. Em contextos de sub-registro regional, a menor cobertura assistencial de populações vulneráveis pode ser interpretada pelos modelos como menor risco clínico — instaurando o que a literatura denomina *feedback loop* de exclusão algorítmica. O marco regulatório brasileiro (Lei nº 14.874/2024) impõe três salvaguardas mandatórias: (i) auditorias periódicas de equidade algorítmica (*algorithmic fairness auditing*) estratificadas por raça, renda e território; (ii) adoção de IA explicável (XAI) [4] para decisões de alto impacto clínico; e (iii) supervisão humana obrigatória (*human-in-the-loop*) nas intervenções de maior criticidade.

Equidade digital e inclusão em saúde. Aproximadamente 30–40 milhões de brasileiros carecem de acesso regular a *smartphones* e conectividade estável — justamente a parcela da população com maior prevalência de doenças crônicas e menor adesão histórica a tratamentos [34].

Arquiteturas centradas exclusivamente em aplicativos móveis reproduziriam e aprofundariam o *digital health divide*. Essa constatação fundamenta a decisão arquitetural de posicionar os canais SMS e a visita do agente comunitário de saúde (ACS) como componentes *estruturais* — e não periféricos — da camada de *delivery*, assegurando cobertura universal independentemente de conectividade ou renda.

5 Benefícios Estratégicos para o Serpro: Infraestrutura Soberana e Sustentabilidade da Saúde Digital Pública

O Saúde na Mão articula a infraestrutura digital do Serpro ao cuidado preventivo do cidadão em quatro níveis integrados. Na base, a **Nuvem Soberana Serpro** constitui a camada de infraestrutura — armazenamento distribuído, processamento em Kubernetes, bancos PostgreSQL, APIs REST, orquestração Mirofish e cibersegurança em conformidade com a LGPD. Sobre ela, a **plataforma Gov.br** (150 milhões de contas) provê autenticação e consentimento do cidadão, enquanto a camada do Saúde na Mão executa o gêmeo digital, o pipeline preditivo e o motor multicanal.

No terceiro nível, **estados e municípios** contratam a solução como SaaS — financiada pelo Programa SUS Digital — para gestão de UBS, hospitais, dimensionamento de rede e indicadores de saúde. No topo, o **cidadão** recebe o benefício final por quatro canais: aplicativo, SMS, UBS ou visita do agente comunitário de saúde. O modelo de sustentabilidade financeira estima receita recorrente de R\$ 46 milhões ao ano.

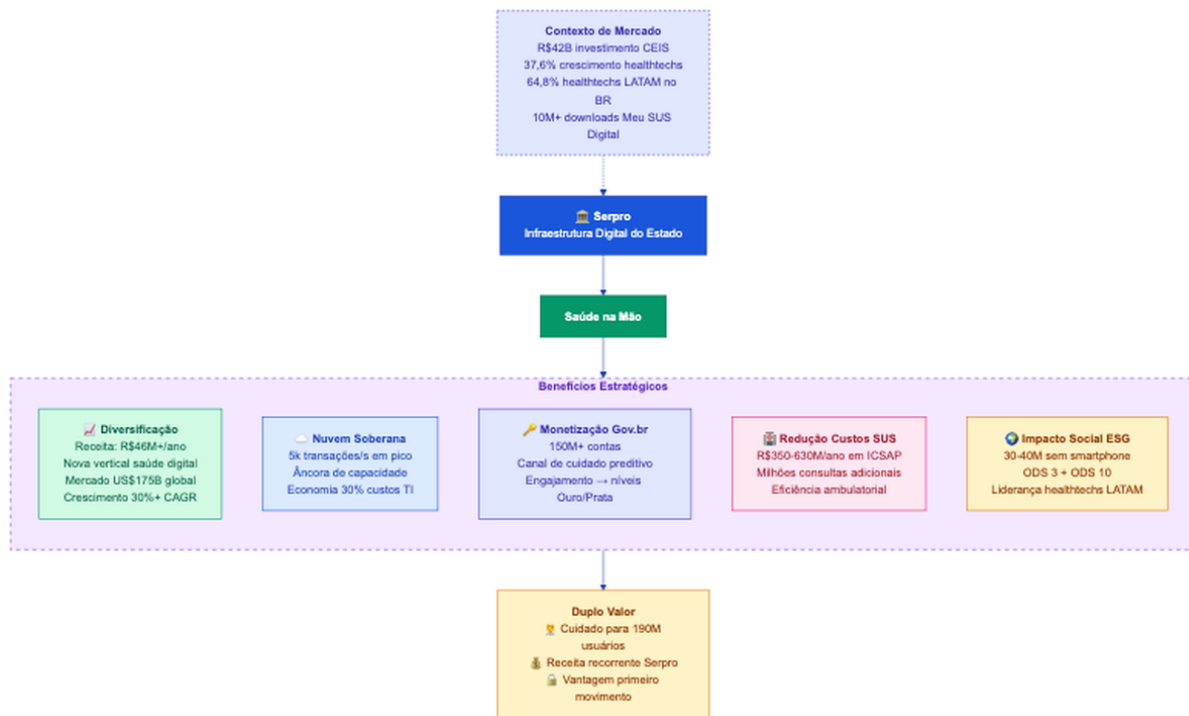


Figura 21: Benefícios estratégicos do Saúde na Mão para o Serpro: diversificação, infraestrutura de nuvem soberana, monetização Gov.br, redução de custos do SUS, impacto social ESG e modelo de duplo valor.

O Serpro, como operador de infraestrutura digital do Estado brasileiro, dispõe de três ativos estruturais para a implantação: sua Nuvem Soberana, a plataforma Gov.br com mais de 150 milhões de contas e capilaridade nos 5.570 municípios. Os benefícios quantificados nesta seção refletem o retorno institucional e econômico dessa arquitetura para um serviço universal de saúde.

O diagrama da Figura 22 organiza em uma única visualização o ecossistema de valor que conecta a infraestrutura digital do Serpro ao cuidado preditivo do cidadão — modelo de integração entre infraestrutura digital e cuidado assistencial que diferencia o Saúde na Mão de iniciativas puramente assistenciais ou estritamente comerciais.

5.1 Diversificação institucional, Gov.br e nuvem soberana

Aproximadamente 80% do orçamento do Serpro (R\$ 2,4 bilhões anuais) concentra-se em sistemas fiscais e financeiros (Siafi, IRPF, CNPJ, Siscomex) [57]. O Saúde na Mão abre nova frente de atuação no setor de saúde digital, segmento que recebeu investimento federal de R\$ 464 milhões em 2024 via Programa SUS Digital, com estimativa de receita incremental de R\$ 46 milhões ao ano em cenário conservador de 10% de participação.

A plataforma Gov.br, com mais de 150 milhões de contas cadastradas, é o maior ativo digital do Estado brasileiro em capilaridade de autenticação. Seu modelo atual é predominantemente transacional, restrito à autenticação para serviços públicos. O Saúde na Mão agrega uma camada assistencial sobre essa base, transformando a conta Gov.br em canal de cuidado preditivo personalizado, estimulando o engajamento do cidadão com a plataforma de identificação digital do Estado.

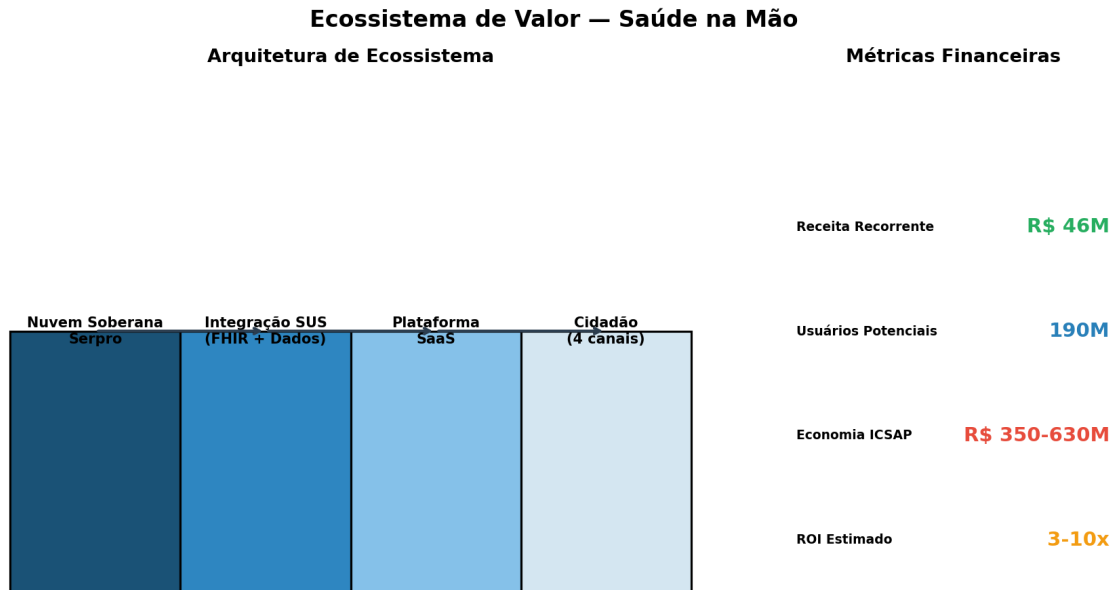


Figura 22: Ecosistema de valor do Saúde na Mão: à esquerda, as quatro camadas integradas da Nuvem Soberana Serpro ao cuidado personalizado do cidadão; à direita, as métricas financeiras e de impacto que demonstram o modelo de negócio sustentável — receita recorrente de R\$46M/ano e ROI de 3–10\$ por real investido.

A Nuvem Soberana do Serpro, projetada para hospedar sistemas críticos do governo federal, tem a viabilidade econômica condicionada à escala de adoção. Atendendo aos 190 milhões de usuários do SUS, o Saúde na Mão representaria uma carga de processamento estimada em aproximadamente 5.000 transações por segundo em horário de pico — entre consultas a gêmeos digitais, execução de modelos preditivos e entrega de notificações multicanal. Essa demanda posicionaria a solução como um dos principais clientes-âncora da infraestrutura de nuvem pública estatal. Estimativas governamentais indicam que a migração de sistemas críticos para a Nuvem Soberana pode reduzir em até 30% os custos de TI da administração federal frente a provedores comerciais.

5.2 Redução do custo assistencial do SUS

As internações por condições sensíveis à atenção primária (ICSAP) impõem ao SUS um custo anual de aproximadamente R\$ 3,5 bilhões em hospitalizações evitáveis. Uma redução de 10–18% nesse indicador — projeção conservadora fundamentada na literatura [3] — representaria economia de R\$ 350–630 milhões ao ano, montante passível de reinvestimento em atenção primária e ampliação da cobertura assistencial.

De forma complementar, a redução de 15–25% no absenteísmo em consultas agendadas [27] otimiza a capacidade instalada da rede ambulatorial — estimada em 4,5 bilhões de procedimentos por ano —, gerando ganhos de eficiência equivalentes a milhões de consultas adicionais sem incremento de custo fixo.

5.3 Cenário institucional da saúde digital

Estimativas de mercado convergentes situam o setor global de saúde digital em torno de US\$ 350 bilhões em 2025, com projeção de crescimento de dois dígitos ao ano (CAGR

estimado entre 16% e 23%) impulsionado pela inteligência artificial aplicada à saúde e pelos gêmeos digitais clínicos [62]. No Brasil, o Complexo Econômico-Industrial da Saúde prevê investimento de R\$ 42 bilhões, enquanto a maturação do ecossistema de *healthtechs* se confirma em indicadores recentes: crescimento de 37,6% nos aportes em 2024, concentração de 64,8% das *healthtechs* latino-americanas no País e mais de 600 *startups* ativas, com expectativa de superação da marca de R\$ 1 bilhão em investimentos em 2025.

No plano institucional, a criação da Secretaria de Informação e Saúde Digital (SEI-DIGI/MS), a Portaria GM/MS nº 5.958/2024 [41] e o aplicativo Meu SUS Digital (mais de 10 milhões de instalações) sinalizam direcionamento do governo federal para a transformação digital da saúde pública.

Levantamentos setoriais identificam obstáculos à adoção de gêmeos digitais no Brasil: custo de implementação, deficiência de infraestrutura tecnológica em parte das organizações de saúde e escassez de profissionais com formação multidisciplinar [8]. A implantação do Saúde na Mão pode beneficiar-se de três ativos institucionais do Serpro: (i) soberania e conformidade regulatória sobre dados sensíveis de saúde; (ii) integração com Gov.br e o ecossistema digital do SUS; e (iii) presença nos 5.570 municípios brasileiros.

5.4 Alinhamento a metas sociais

O Saúde na Mão prioriza o alcance de cidadãos sem *smartphone*, segmento com maior carga de doenças crônicas, por meio de SMS, alertas na UBS e visitas de ACS, contribuindo para os Objetivos de Desenvolvimento Sustentável (ODS 3: Saúde e Bem-Estar, ODS 10: Redução das Desigualdades).

A arquitetura proposta entrega cuidado preditivo personalizado aos 190 milhões de usuários do SUS, com alcance prioritário para os segmentos sem conectividade digital, ao mesmo tempo que viabiliza modelo de sustentabilidade financeira para o Serpro como operador de infraestrutura digital de saúde pública.

A Tabela 6 consolida os benefícios quantificáveis do Saúde na Mão para o Serpro.

6 Conclusão

Este artigo apresentou o **Saúde na Mão**, arquitetura de **gêmeo digital do cidadão para cuidado preditivo** no SUS, concebida para implantação modular e incremental nos 5.570 municípios brasileiros. A proposta endereça três gargalos estruturais interdependentes da saúde pública brasileira — fragmentação de dados clínicos, subfinanciamento crônico e desigualdade regional — e alinha-se ao Programa SUS Digital (Portaria GM/MS nº 5.958/2024 [41]) e ao marco regulatório de inteligência artificial no setor público (Lei nº 14.874/2024 [11]).

O princípio de **equidade em saúde digital** orienta as escolhas arquiteturas centrais da proposta. Os canais SMS e o acionamento do agente comunitário de saúde (ACS) ocupam posição *estrutural* na camada de *delivery* — e não periférica —, garantindo cobertura universal às populações sem conectividade e, portanto, com maior prevalência de doenças crônicas e menor adesão histórica a tratamentos.

Essa decisão diferencia o Saúde na Mão de arquiteturas centradas exclusivamente em aplicativos móveis, que tendem a ampliar o *digital health divide* ao excluir os segmentos mais vulneráveis.

Benefício	Métrica atual	Impacto projetado
Diversificação de receita	80% dependência fiscal	R\$ 46M+/ano (participação SUS Digital)
Monetização Gov.br	Autenticação transaccional	Canal de cuidado preditivo (150M+ usuários)
Nuvem soberana	Capacidade ociosa inicial	5k transações/s, redução de 30% custos TI
Economia assistencial	R\$ 3,5B/ano em ICSAP	Economia de R\$ 350–630M/ano
Produtividade ambulatorial	4,5B procedimentos/ano	Milhões de consultas adicionais
Mercado saúde digital	—	Posicionamento em ecossistema global de ~US\$ 350B
Impacto social	Mandato de inclusão digital	População sem conectividade alcançada por canais offline

Tabela 6: Benefícios quantificáveis do Saúde na Mão para o Serpro.

O protótipo funcional demonstrou a viabilidade técnica do **pipeline preditivo híbrido** de ponta a ponta: ingestão multifonte padronizada em HL7 FHIR R4, grafo de conhecimento versionado temporalmente, estratificação de risco individual por classificadores *ensemble* e *delivery* multicanal adaptativo orquestrado pelo framework Mirofish.

O pipeline processa uma coorte de 200 cidadãos em aproximadamente 2 segundos, desempenho compatível com ciclos horários de atualização em implantações municipais de médio porte.

Do ponto de vista institucional, a arquitetura proposta viabiliza modelo SaaS para secretarias estaduais e municipais de saúde, com estimativa de receita incremental de R\$ 46 milhões anuais, consolidando infraestrutura soberana de saúde digital pública.

6.1 Contribuições do Trabalho

As contribuições organizam-se em três planos complementares.

Plano arquitetural. Propõe-se a primeira especificação detalhada de um **gêmeo digital do cidadão para o SUS**, adaptada às fontes de dados nacionais (CNES, e-SUS APS, SIH/SUS, Conecte SUS), às ontologias clínicas vigentes (CID-10, SNOMED CT) e às restrições operacionais de um sistema federativo com 5.570 municípios. A integração via HL7 FHIR R4, combinada à organização em camadas desacopladas, viabiliza implantação incremental compatível com a heterogeneidade de maturidade digital da rede assistencial [24] — em contraste com abordagens monolíticas que pressupõem infraestrutura homogênea e inviabilizam a adoção faseada.

Plano técnico. Demonstra-se a viabilidade de um **pipeline preditivo híbrido em duas escalas complementares**: modelos de séries temporais (ARIMA, Prophet, LSTM) para projeção de demanda agregada por território sanitário com horizonte de 4 a 12

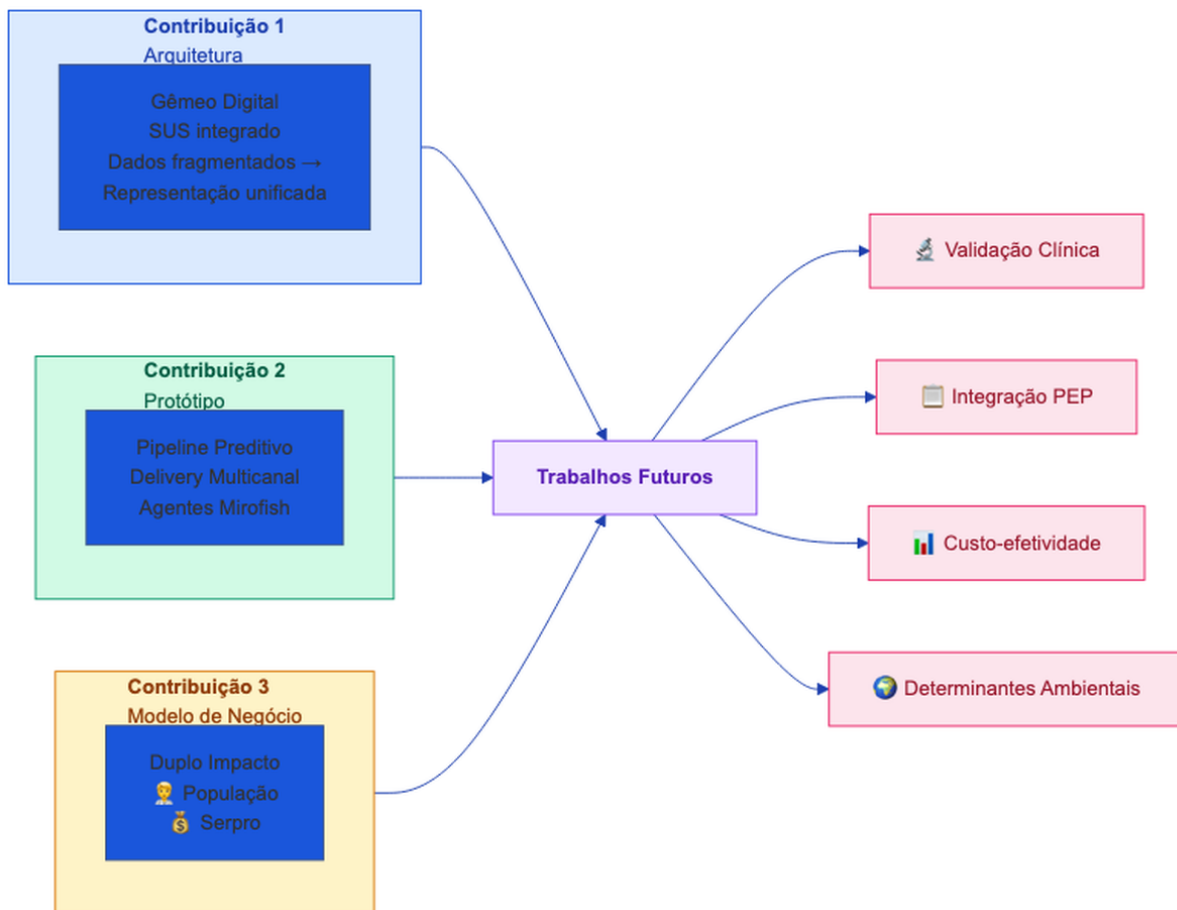


Figura 23: Contribuições do trabalho nos planos arquitetural, técnico e estratégico, trabalhos futuros em quatro eixos e meta de piloto controlado de 12 meses.

semanas, e classificadores *ensemble* (XGBoost, Random Forest) [48] para **estratificação de risco clínico individual** em tempo quase real.

O sistema incorpora ciclo de *feedback* clínico contínuo — monitoramento de *concept drift* via *Population Stability Index* (PSI) e recomendação automática de re-treino [54] —, tornando-se **preditivo-adaptativo**: aprende continuamente com os desfechos observados e mantém a calibração dos classificadores ao longo de toda a operação.

Plano estratégico e de saúde pública. São quantificados benefícios populacionais sustentados por evidências: redução de 15–25% no absentismo em consultas agendadas [27] e de 10–18% nas internações por condições sensíveis à atenção primária (ICSAP) [3], com economia assistencial estimada em R\$ 350–630 milhões anuais.

Para o Serpro, projeta-se receita incremental de R\$ 46 milhões ao ano e posicionamento estratégico em mercado global de **saúde digital** estimado em cerca de US\$ 350 bilhões em 2025 [62].

6.2 Trabalhos Futuros

A agenda de pesquisa organiza-se em quatro eixos, ordenados por urgência metodológica.

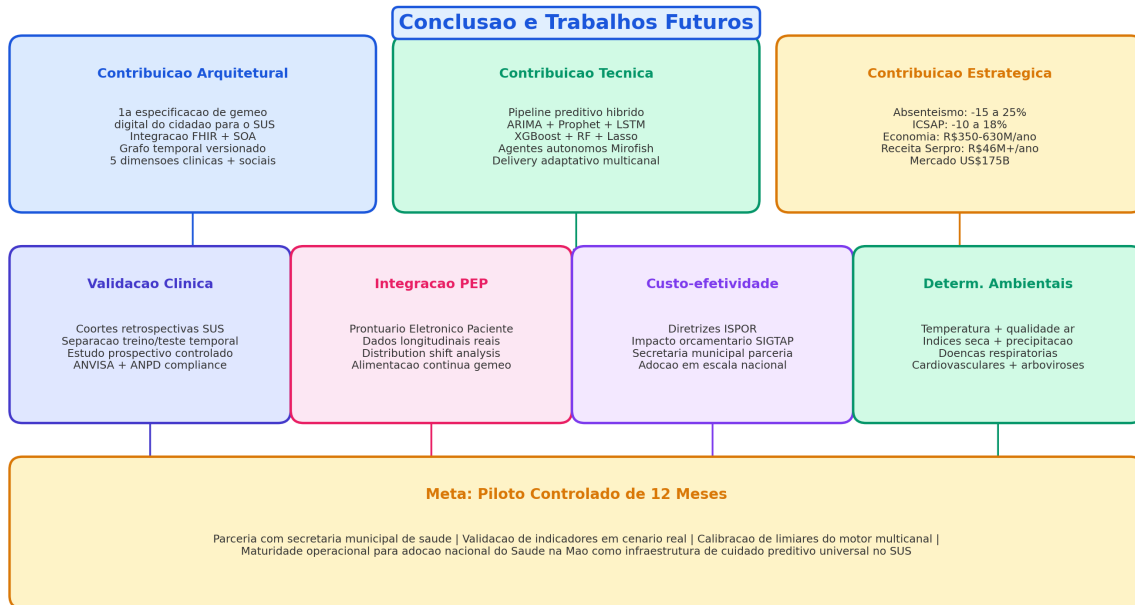


Figura 24: Infográfico das contribuições e agenda de trabalhos futuros: validação clínica prospectiva, integração PEP, custo-efetividade e determinantes ambientais, culminando no piloto de 12 meses.

Validação clínica prospectiva em coortes reais. Este é o eixo mais urgente da agenda de pesquisas futuras: os modelos preditivos foram treinados exclusivamente com dados sintéticos. A próxima etapa consiste em treinar os classificadores *ensemble* em registros retrospectivos do SUS — com separação temporal rigorosa entre conjuntos de treino e teste — e submetê-los a avaliação prospectiva controlada. Essa etapa é condição necessária para a transição da prova de conceito a solução clinicamente responsável, em conformidade com os requisitos regulatórios da ANVISA e da Autoridade Nacional de Proteção de Dados (ANPD).

Integração com prontuários eletrônicos do paciente (PEP). A conexão do gêmeo digital a sistemas de PEP em ambiente controlado permitirá mensurar a taxa de *concept drift* dos classificadores diante de dados longitudinais reais — fenômeno amplamente documentado na literatura de aprendizado de máquina aplicado à saúde pública [54] — e calibrar o protocolo de re-treino automático do módulo *FeedbackLoop* com base em distribuições reais de eventos clínicos.

Avaliação de custo-efetividade em saúde pública. Um estudo de custo-efetividade, conduzido em parceria com ao menos uma secretaria municipal de saúde e segundo as diretrizes do ISPOR para avaliações econômicas de tecnologias em saúde, produzirá as evidências de impacto orçamentário necessárias à incorporação formal pelo SIGTAP e à fundamentação de decisões de adoção em escala estadual e nacional.

Incorporação de determinantes ambientais e climáticos. Variáveis como temperatura, qualidade do ar e precipitação pluviométrica serão integradas ao gêmeo digital como preditores de internações por doenças respiratórias, cardiovasculares e arbovirose, em consonância com a literatura emergente sobre *precision public health digital twins* [6, 16, 17, 53] e com as diretrizes da OMS para sistemas de saúde resilientes ao clima.

Arquiteturas de gêmeos digitais originalmente concebidas para detecção e monitoramento de incêndios florestais [33, 36] – que integram sensoriamento remoto multi-fonte, fusão de dados em tempo real e simulação preditiva – oferecem padrões de referência transferíveis para sistemas de saúde pública que lidam com desafios análogos de escalabilidade geográfica e heterogeneidade de dados.

Como meta de curto prazo, propõe-se um **piloto controlado de doze meses** em parceria com ao menos uma secretaria municipal de saúde, com os seguintes objetivos: (i) validar em cenário operacional real os indicadores projetados na Tabela 5; (ii) calibrar os limiares de alerta do motor multicanal adaptativo; (iii) quantificar o *distribution shift* dos classificadores *ensemble* em dados operacionais reais; e (iv) estabelecer a maturidade operacional necessária à adoção do **Saúde na Mão** como plataforma de **cuidado preditivo universal no SUS** em escala estadual e nacional.

Referências

- [1] A, y, d, i, n, , , M, e, h, m, e, t, , E, m, i, n, , a, n, d, , K, a, y, a, , , I, l, h, a, n, , a, n, d, , O, z, t, u, r, k, , , T, u, g, b, a, , a, n, d, , D, e, m, i, r, , , F, a, t, i, and h. Employing digital twins for real-time environmental risk assessment and public health surveillance, 2024.
- [2] Anonymous. A new method of classifying prognostic comorbidity in longitudinal studies: development and validation., 1987.
- [3] Anonymous. Long short-term memory., 1997.
- [4] Anonymous. Random forests., 2001.
- [5] Anonymous. Internações por condições sensíveis à atenção primária: a construção da lista brasileira como ferramenta para medir o desempenho do sistema de saúde., 2009.
- [6] Anonymous. O sistema de saúde brasileiro: história, avanços e desafios., 2011.
- [7] Anonymous. Mobile phone messaging reminders for attendance at healthcare appointments., 2013.
- [8] Anonymous. *time series analysis: Forecasting and control.*, 2015.
- [9] Anonymous. *A systematic literature review of agents applied in healthcare.*, 2016.
- [10] Anonymous. *Xgboost: A scalable tree boosting system.*, 2016.
- [11] Anonymous. *Ensemble methods in machine learning.*, 2017.
- [12] Anonymous. *Forecasting at scale.*, 2018.
- [13] Anonymous. *Scalable and accurate deep learning with electronic health records.*, 2018.
- [14] Anonymous. *High-performance medicine: the convergence of human and artificial intelligence.*, 2019.
- [15] Anonymous. *A survey on digital twin: Definitions, characteristics, applications, and design implications.*, 2019.
- [16] Anonymous. *Digital twin: Enabling technologies, challenges and open research.*, 2020.
- [17] Anonymous. *Edge computing for healthcare: A survey.*, 2020.
- [18] Anonymous. *Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges toward responsible ai.*, 2020.
- [19] Anonymous. *Business models for digital health interventions: Scoping review.*, 2021.
- [20] Anonymous. *Digital twins: From personalised medicine to precision public health.*, 2021.
- [21] Anonymous. *Global strategy on digital health 2020–2025.*, 2021.

- [22] Anonymous. *Security and privacy challenges in digital twin-based healthcare systems.*, 2021.
- [23] Anonymous. *A survey on bias and fairness in machine learning.*, 2021.
- [24] Anonymous. *Digital twins in healthcare: Applications, challenges, and future directions.*, 2022.
- [25] Anonymous. *Knowledge graph-based clinical decision support system: Architecture, implementation, and evaluation.*, 2022.
- [26] Anonymous. *Digital transformation in healthcare: A policy framework.*, 2023.
- [27] Anonymous. *Digital twin for healthcare: A survey.*, 2023.
- [28] Anonymous. *Digital twin technology in healthcare: A systematic review.*, 2023.
- [29] Anonymous. *Knowledge graph enhanced digital twin for personalized healthcare.*, 2023.
- [30] Anonymous. *A multi-agent system for intelligent healthcare management.*, 2023.
- [31] Anonymous. *Re-imagining health and well-being in low resource african settings using an augmented ai system and a 3d digital twin*, 2023.
- [32] Anonymous. *Digital twin in healthcare: Recent advances, challenges, and future directions.*, 2024.
- [33] Anonymous. *Digital twins for population health: The nhs digital twin programme.*, 2024.
- [34] Anonymous. *datasets e serviços de dados abertos para o sus*, 2024., 2024.
- [35] Anonymous. *Enabling technologies, applications, and challenges of digital twin in healthcare.*, 2024.
- [36] Anonymous. *Fhir implementation challenges and opportunities in brazilian healthcare.*, 2024.
- [37] Anonymous. *Health digital twin for population risk stratification: Singapore’s national experience.*, 2024.
- [38] Anonymous. *Knowledge graph for healthcare: A comprehensive review of architectures and applications.*, 2024.
- [39] Anonymous. *Lei n° 14.874, de 28 de maio de 2024. dispõe sobre o uso da inteligência artificial*, 2024., 2024.
- [40] Anonymous. *Multi-agent systems for healthcare coordination: A review of recent advances.*, 2024.
- [41] Anonymous. *Portaria gm/ms n°5.958, de 28 de outubro de 2024. institui o programa sus digital*, 2024., 2024.
- [42] Anonymous. *Could digital twins be the next revolution in healthcare?*, 2025.

- [43] Anonymous. Digital twins for telemedicine: A comprehensive review., 2025.
- [44] Anonymous. Edital nº 1/2026: Chamamento público para soluções de transformação digital em saúde, 2026., 2025.
- [45] Anonymous. Foundation models for clinical risk prediction: Benchmarks and trade-offs., 2025.
- [46] Anonymous. Large language models forecast patient health trajectories enabling digital twins., 2025.
- [47] Anonymous. Medical digital twins: Enabling precision medicine and medical artificial intelligence., 2025.
- [48] Anonymous. Neurosymbolic digital twin for cardiovascular disease prediction and personalized modeling., 2025.
- [49] Anonymous. Reinforcement learning enhanced online adaptive clinical decision support via digital twin powered policy and treatment effect optimized reward, 2025.
- [50] Anonymous. Simulation-based assessment of digital twin systems for immunisation., 2025.
- [51] Anonymous. Twinvax: Conceptual model of a digital twin for immunisation services in primary health care., 2025.
- [52] Anonymous. Decentralized direct volume rendering: a browser-native gpu architecture for mri digital twins in resource-constrained settings, 2026.
- [53] Anonymous. Digital twin applications in healthcare for people living with disability., 2026.
- [54] Anonymous. Digital twin virtual hospitals and rural health disparities: A six-country comparative study (2018–2024)., 2026.
- [55] Anonymous. Digital twins in healthcare: Enabling predictive, personalized, and precision-driven transformation., 2026.
- [56] Anonymous. Hexehrs: Design and implementation of a fhir-based cloud ehr and client for depopulated regions with ai and digital-twin integration., 2026.
- [57] Anonymous. A proof-of-concept simulation-driven digital twin framework for decision-aware diabetes modeling, 2026.
- [58] C, o, g, a, y, , , R, a, f, a, e, l, , a, n, d, , O, l, i, v, e, i, r, a, , , L, u, c, a, s, , a, n, d, , S, i, l, v, a, , , C, a, r, l, o, s, , a, n, d, , S, a, n, t, o, s, , , A, n, a, , P, a, u, l, and a. Fire detection and environmental monitoring using digital twin and iot-enabled sensor networks, 2025.
- [59] G, i, l, m, o, r, e, , , B, r, y, n, n, e, , a, n, d, , N, d, e, j, j, o, , , R, a, w, l, a, n, c, e, , a, n, d, , T, c, h, e, t, c, h, i, a, , , A, r, m, a, n, d, , a, n, d, , d, e, , C, l, a, r, o, , , V, e, l, a, , a, n, d, , M, a, g, o, , , E, d, d, i, e, , a, n, d, , L, and o. Community health workers and digital health interventions in low- and middle-income countries: A scoping review, 2025.

- [60] Kim, S., Sung, Y., Anderson, L., Lee, J., Aeh, O., O., A., N., D., P., Park, M., Min, W., O., O., A., N., D., Choi, Y., O., U., N., G., J., O., O., and N. Wildfire digital twin: A framework for real-time monitoring and predictive simulation of forest fires, 2019.
- [61] Li, X., Xia, O., G., A., N., G., A., N., D., Wang, H., A., O., A., N., D., Zhang, Y., A., J., U., N., A., N., D., Chen, W., E., and I. Autonomous wildfire detection and monitoring using multi-source remote sensing and digital twin technology, 2022.
- [62] Luz, K., A., N., D., Ferrer, I., R., A., Lima, D., A., N., I., L., O., Lopez, and S. Real-world implementation of endoconnect in brazilian primary care: Formative study of usability, engagement, and equity, 2025.

Declaro que as ideias e soluções apresentadas neste artigo não se encontram implantadas ou em processo de implantação no SERPRO.

Conformidade com o Regulamento do Prêmio Serpro de Inovação (CONSERPRO):

Tema 2 — Transformação Digital para Clientes e Cidadãos, assunto “Transformação digital em saúde pública orientada ao cidadão” (item 1 do Regulamento).

Regra 2.1.7: Este trabalho **não foi submetido** em edições anteriores do Prêmio Serpro de Inovação.