Journal of Health Informatics

J Health Inform. 2026;18:e1854
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1854

ARTIGO COMPLETO
CBIS 2026

Agentes de inteligência artificial para apoio à modelagem clínica interoperável em saúde

Artificial intelligence agents to support interoperable clinical modeling in health

Dandra Alves de Souza[1] ✉, Renata Dutra Braga[1], Suse Barbosa Castilho[1], Lívia Morais Vilela[2], Willian Oliveira[2], Carlos Augusto Gonçalves Tibiriçá[2], Diana Ferreira Guimarães[2], Luiselena Luna Esmeraldo[2], Juliana Pereira de Souza-Zinader[1], Rita Goreti Amaral[1]

ORCID: 0000-0001-5458-6244 · 0000-0002-3448-0343 · 0000-0003-4480-5380 · 0009-0005-3386-9401 · 0009-0008-3625-6530 · 0000-0002-1455-0906 · 0009-0003-2318-3110 · 0000-0002-7135-5947 · 0009-0005-7780-4626 · 0000-0001-8890-0852

[1] Universidade Federal de Goiás, Goiânia (GO), Brasil.

[2] Superintendência de Tecnologia, Inovação e Saúde Digital, Secretaria de Saúde do Estado de Goiás, Goiânia (GO), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1854

DOI
10.59681/2175-4411.v18.iEspecial.2026.1854

RECEBIDO
17/05/2026

APROVADO
20/07/2026

PROCESSO DE AVALIAÇÃO
Double Blind Review

EDITOR RESPONSÁVEL
Juliano de Souza Gaspar

ACESSO
Aberto, CC BY 4.0

AUTOR CORRESPONDENTE
Dandra Alves de Souza
dandra_souza@discente.ufg.br

LICENÇA

Este é um artigo publicado em acesso aberto sob a licença Creative Commons CC BY 4.0, que permite uso, distribuição e reprodução em qualquer meio, desde que o trabalho original seja corretamente citado.

CC BY 4.0

RESUMO

Objetivo: Descrever a arquitetura de agentes de inteligência artificial de uma plataforma desenvolvida em parceria entre uma instituição de pesquisa e uma secretaria estadual de saúde para apoio à modelagem clínica interoperável baseada no padrão HL7 Fast Healthcare Interoperability Resources (FHIR). **Método:** Os agentes foram definidos em oficinas de cocriação com especialistas em interoperabilidade e modelagem clínica, utilizando Design Sprint e Design Thinking. Foram especificados três agentes integrados a uma arquitetura de Geração Aumentada por Recuperação (RAG): ED (Entendimento da Demanda), AV (Análise de Viabilidade) e MCA (Modelagem Clínica Apoiada). **Resultados:** A plataforma oferece nove serviços inteligentes voltados à elicitação de caso de uso, análise de viabilidade, extração de elementos clínicos, recomendação de regras de negócio e busca semântica de artefatos FHIR, sob o princípio Human-in-the-Loop (HITL). **Conclusão:** A arquitetura proposta amplia o suporte à modelagem FHIR em saúde com supervisão humana contínua.

Descritores: Interoperabilidade da Informação em Saúde; Inteligência Artificial; Saúde Digital.

ABSTRACT

Objective: To describe the artificial intelligence agent architecture of a platform developed through a partnership between a research institution and a state health department to support interoperable clinical modeling based on the HL7 Fast Healthcare Interoperability Resources (FHIR) standard. **Method:** The agents were defined through co-creation workshops with specialists in interoperability and clinical modeling, using Design Sprint and Design Thinking approaches. Three agents integrated into a Retrieval-Augmented Generation (RAG) architecture were specified: DU (Demand Understanding), FA (Feasibility Analysis), and ACM (Assisted Clinical Modeling). **Results:** The platform provides nine intelligent services focused on use case elicitation, feasibility analysis, extraction of clinical elements, recommendation of business rules, and semantic search for FHIR artifacts, under the Human-in-the-Loop (HITL) principle. **Conclusion:** The proposed architecture expands support for FHIR modeling in healthcare while ensuring continuous human oversight.

Keywords: Health Information Interoperability; Artificial Intelligence; Digital Health.

CBIS 2026 XXI CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE

Artigo apresentado no XXI Congresso Brasileiro de Informática em Saúde (CBIS 2026), realizado de 23 a 25 de setembro de 2026, em Brasília (DF), e publicado na seção CBIS 2026 do Journal of Health Informatics.

COMO CITAR ESTE ARTIGO: de Souza DA, Braga RD, Castilho SB, Vilela LM, Oliveira W, Tibiriçá CAG, et al. Agentes de inteligência artificial para apoio à modelagem clínica interoperável em saúde. J Health Inform 2026;18:e1854. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1854

1 INTRODUÇÃO

A interoperabilidade semântica de dados em saúde consolida-se como condição estruturante para a continuidade assistencial, a segurança do paciente, a integração de sistemas heterogêneos e a gestão eficiente de recursos públicos em saúde [1]. No Brasil, alinhada às metas da Estratégia Global de Saúde Digital da Organização Mundial da Saúde [2], a Rede Nacional de Dados em Saúde (RNDS) do Ministério da Saúde estabelece uma infraestrutura nacional de troca de dados cujas especificações técnicas adotam o padrão HL7 Fast Healthcare Interoperability Resources (FHIR) como base para o compartilhamento de informações clínicas entre entes federativos [3].

Baseado em tecnologias web, como APIs RESTful, JSON e XML, o FHIR permite modelar e trocar dados clínicos por meio de recursos padronizados que podem ser especializados para contextos locais e nacionais. Essa especialização é representada por artefatos denominados *Implementation Guides* (IGs), *profiles*, *ValueSets*, *CodeSystems*, extensões e Modelos de Informação (MIs) [4].

Apesar de sua consolidação como padrão global, a produção de artefatos FHIR permanece um desafio de alta complexidade [5]. A construção de um IG exige domínio simultâneo de múltiplos saberes: conhecimento aprofundado do domínio clínico; fluência em terminologias padronizadas, como SNOMED CT, LOINC, CID-10 e Tabela SUS; competência em engenharia de requisitos e modelagem da informação em saúde; e proficiência na estrutura técnica do padrão, que contempla recursos, extensões, perfis, cardinalidades, invariantes, expressões FHIRPath e ferramentas de publicação (SUSHI e IG Publisher) [4,5].

A raridade desse perfil profissional multidisciplinar nas equipes de saúde pública gera forte dependência de consultores externos, longos ciclos de revisão, retrabalho sistemático na elaboração de MIs e IGs, e dificuldades persistentes para manter consistência semântica, rastreabilidade entre artefatos e governança evolutiva dos modelos publicados [5,6]. Baslyman [7] aponta a elicitação inadequada de requisitos como fator recorrente de falhas ou baixa adoção de soluções digitais em saúde, resultando em artefatos imprecisos ou inconsistentes com os fluxos clínicos que pretendem representar.

Uma instituição pública de saúde enfrenta esse desafio de forma objetiva. A secretaria mantém o IG FHIR estadual (https://fhir.saude.go.gov.br/r4/core/), referenciado por iniciativas nacionais de interoperabilidade, e desenvolve, em parceria com uma Universidade Pública, IGs voltados a casos de uso clínicos e administrativos relevantes ao Sistema Único de Saúde (SUS). A necessidade de ampliar a produção de MIs e IGs em escala, sem expandir proporcionalmente a equipe especializada e sem comprometer a qualidade técnica e semântica dos artefatos, motivou o desenvolvimento de uma plataforma inteligente para apoio à modelagem clínica interoperável. A plataforma foi concebida como um companheiro digital da jornada FHIR: fluxo estruturado de sete etapas que vai do entendimento da demanda clínica à governança do IG publicado, guiando dois perfis de usuário ao longo do processo: o Autor do MI, responsável técnico pela construção do Modelo de Informação, e o Núcleo de Padronização, instância institucional de revisão e governança dos artefatos.

Saab *et al.* [8] e Thirunavukarasu *et al.* [9] demonstram que Grandes Modelos de Linguagem (LLMs) alcançam resultados em *benchmarks* médicos e são capazes de interpretar descrições em linguagem natural para apoiar tarefas de raciocínio técnico-clínico complexas. A técnica de Geração Aumentada por Recuperação (RAG), ao enriquecer as respostas dos LLMs com informações recuperadas de repositórios de IGs FHIR nacionais e internacionais, reduz alucinações e aumenta a aderência às estruturas técnicas e semânticas dos padrões estabelecidos [10]. Agentes de inteligência artificial (IA), definidos por Rajpurkar *et al.* [11] como sistemas LLMs aumentados com ferramentas de acesso a informações externas e capacidade de execução de tarefas multietapa, têm demonstrado desempenho superior a modelos isolados em tarefas clínicas complexas [5]. O paradigma *Human-in-the-Loop* (HITL), por sua vez, consolida-se como condição necessária para a implantação segura e responsável de IA em contextos críticos, garantindo que as sugestões dos sistemas inteligentes permaneçam sob supervisão e controle humano em todos os pontos de decisão [12].

Frei *et al.* [13] propõem uma estratégia agentiva ponta a ponta para converter narrativas clínicas em recursos FHIR; Kabak *et al.* [14] exploram a técnica de RAG para recomendações clínicas baseadas em dados de pacientes no formato FHIR; e Paili [15] demonstra o uso de IA generativa para geração de conjuntos de dados sintéticos semanticamente validados. Contudo, persiste uma lacuna importante: a maior parte dessas iniciativas tem ênfase no consumo de dados clínicos já estruturados, seja para apoio ao clínico, seja para transformação automatizada de registros, e pouca atenção tem sido dedicada ao apoio inteligente ao processo anterior à geração dos artefatos FHIR, ou seja, ao trabalho do modelador. São escassas as arquiteturas de IA orientadas à engenharia da informação em saúde no que se refere à elicitação de demandas, à análise de viabilidade técnica e semântica, à extração de elementos clínicos, à recomendação de regras de negócio e à busca semântica de artefatos terminológicos.

Para enfrentar essa lacuna, este artigo apresenta a arquitetura de agentes de inteligência artificial de uma plataforma voltada ao apoio da modelagem clínica

interoperável, descrevendo os agentes especificados e os serviços inteligentes implementados, a base vetorial de conhecimento e os mecanismos de governança e controle humano incorporados à solução. São detalhados os três agentes das etapas iniciais da Jornada FHIR: o Agente ED (Entendimento da Demanda), o Agente AV (Análise de Viabilidade) e o Agente MCA (Modelagem Clínica Apoiada). Esses agentes proveem nove serviços inteligentes (S2 a S10), detalhados na seção de Resultados. A principal contribuição reside na proposição de uma arquitetura orientada ao modelador, que posiciona a IA no suporte ao processo de engenharia da informação em saúde, a montante da geração dos artefatos computacionais, integrando LLMs de última geração, base vetorial sobre IGs nacionais e internacionais em uma jornada guiada e auditável.

Além desta introdução, o artigo apresenta, na seção de Método, o processo de cocriação e engenharia de requisitos que fundamentou a especificação dos agentes; na seção de Resultados, a descrição dos serviços inteligentes da plataforma; na Discussão são descritas as contribuições para a área, trabalhos correlatos e as limitações do estudo; e, na Conclusão, a síntese das contribuições com indicação de trabalhos futuros.

2 MÉTODOS

O desenvolvimento dos agentes inteligentes seguiu uma estrutura iterativa em quatro eixos: (i) levantamento de requisitos por meio de oficinas de cocriação; (ii) especificação dos agentes e serviços inteligentes; (iii) implementação incremental com validação contínua junto à equipe técnica; e (iv) documentação versionada em repositório GitHub, contendo histórias de usuário, critérios de aceitação, regras de negócio e requisitos inteligentes de cada serviço (Figura 1).

A concepção dos agentes foi fundamentada em duas oficinas presenciais de cocriação, realizadas ao longo de duas semanas, com participação de 18 (dezoito) participantes. Todos integravam o Núcleo de Padronização, critério adotado para a seleção, e reuniam competências em interoperabilidade, modelagem clínica, engenharia de requisitos e desenvolvimento de software. O método integrou os princípios do *Design Sprint* [16] e do *Design Thinking* [17], conduzidos em cinco etapas: entendimento do desafio, mapeamento do fluxo atual, geração de ideias, priorização e prototipação conceitual. A ferramenta Miro foi utilizada como ambiente colaborativo digital para registro e estruturação dos resultados em tempo real.

Na etapa de mapeamento do fluxo atual (*AS IS*), três grupos de participantes identificaram oito categorias de pontos críticos no processo de modelagem FHIR: (a) complexidade e dependência de especialistas na análise de viabilidade; (b) ausência de governança para IGs já publicados; (c) dificuldade de aderência entre MIs e artefatos FHIR; (d) verificação manual de instâncias e qualidade; (e) divergência e falta de rastreabilidade entre dados de origem e artefatos; (f) inconsistência no uso do FHIR entre modeladores; (g) dificuldade de interpretação semântica e clínica; e (h) ausência de regras automáticas para compatibilidade com perfis nacionais. Na etapa de priorização, os grupos convergiram para três eixos estratégicos: assistência inteligente orientada por agentes, automação semântica e terminológica, e rastreabilidade e governança dos artefatos.

2.1 Especificação dos Agentes e Stack Tecnológico

Com base nos resultados das oficinas, foram especificados os agentes e os seus serviços inteligentes, documentados por meio de histórias de usuário, critérios de aceitação no formato Dado/Quando/Então e requisitos não funcionais de qualidade, explicabilidade, privacidade e controle humano. A plataforma está sendo implementada em Python 3.11+ com *backend* Django e *frontend* Next.js. O motor LLM principal é o Google Gemini (gemini-2.0-flash / gemini-1.5-pro); o Qwen3 (Alibaba Cloud, maio de 2025) atua como motor de pré-processamento semântico [18]. A base de conhecimento contém informações que permitem recuperação léxica e semântica (texto e vetor) e está armazenada no Elasticsearch.

Todos os agentes operam sob o princípio HITL: nenhum dado é consolidado sem a confirmação explícita do Autor do MI. As saídas dos agentes são apresentadas como sugestões editáveis, com rastreabilidade entre conteúdo gerado e fontes de origem. Campos preenchidos automaticamente são sinalizados visualmente para distingui-los de conteúdo inserido manualmente, e a plataforma não sobrescreve conteúdo sem confirmação do usuário. Todas as interações dos agentes são registradas em uma trilha de auditoria contendo: entrada, saída, data e hora, versão do modelo e usuário responsável pela decisão final.

Figura 1. Síntese do processo de concepção, implementação e governança dos agentes inteligentes da Plataforma.

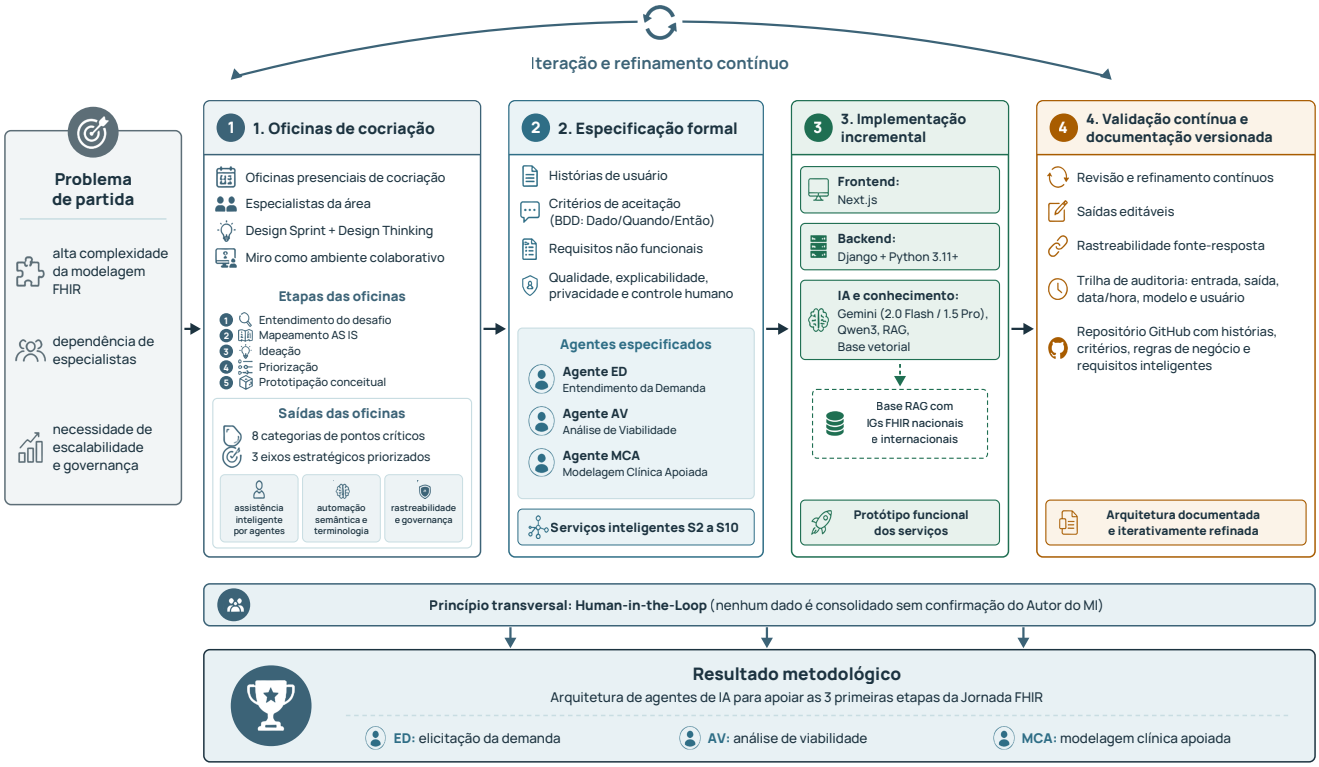

Fonte: Elaborado pelos autores (2026).

2.2 Aspectos Éticos

Este estudo não foi submetido a Comitê de Ética em Pesquisa (CEP), pois se caracteriza como desenvolvimento técnico e especificação arquitetural de uma plataforma de software, sem envolvimento de pacientes, profissionais de saúde como sujeitos de pesquisa, testes com usuários, coleta de dados pessoais, uso de prontuários, dados clínicos reais ou dados sensíveis identificáveis ou anonimizados. As oficinas de cocriação foram conduzidas como atividades técnicas de levantamento e estruturação de requisitos, e os resultados utilizados no artigo correspondem a produtos agregados, como categorias de problemas, fluxos, requisitos, histórias de usuário e especificações dos agentes, sem identificação individual dos participantes.

A base de conhecimento prevista para a arquitetura é composta por documentos técnicos, guias de implementação, padrões e artefatos FHIR públicos ou institucionais. Ainda assim, por se tratar de uma solução aplicada ao domínio da saúde, a plataforma incorpora princípios de IA responsável, *Human-in-the-Loop*, rastreabilidade fonte-resposta, trilha de auditoria, revisão humana obrigatória e conformidade com a Lei Geral de Proteção de Dados (LGPD).

3 RESULTADOS

A plataforma organiza a modelagem clínica em uma Jornada FHIR de sete etapas, cada uma apoiada por agentes especializados. No estágio atual de desenvolvimento da plataforma, este artigo contempla as três primeiras etapas da Jornada FHIR (Figura 2), correspondentes aos agentes ED, AV e MCA e aos serviços inteligentes S2 a S10 (Tabela 1). As etapas subsequentes (Mapeamento FHIR, Construção do IG, Publicação e Revisão e Governança) estão em especificação e são escopo de trabalhos futuros.

Tabela 1. Agentes e serviços inteligentes cobertos por este artigo (Etapas 1 a 3 da Jornada FHIR)

Etapa	Agente	Objetivo	Serviços	Produto
1 – Entendimento da Demanda	Agente ED	Elicitar e consolidar o caso de uso clínico	S2, S3	Documento de Entendimento do Caso de Uso
2 – Análise de Viabilidade	Agente AV	Analisar viabilidade técnica e identificar reuso	S4, S5, S6	Parecer de Viabilidade Técnica; Feedback ao Solicitante
3 – Modelagem Clínica Apoiada	Agente MCA	Construir o Modelo de Informação FHIR	S7, S8, S9, S10	Modelo de Informação; Artefatos FHIR vinculados

Fonte: Elaborado pelos autores (2026).

Figura 2. Arquitetura metodológica resultante para concepção dos agentes de IA da Plataforma.



Fonte: Elaborado pelos autores (2026).

3.1 Agente ED (Entendimento da Demanda)

O Agente ED atua como facilitador cognitivo na elicitação e consolidação do caso de uso clínico. O agente utiliza técnicas de processamento de linguagem natural (PLN) e LLMs, com suporte da base vetorial para contextualizar a sua análise com padrões FHIR importantes ao domínio identificado.

Serviço S2 (Perguntas Inteligentes para Preenchimento de Lacunas): o agente identifica, automaticamente, as lacunas de contexto clínico no caso de uso informado pelo usuário. Para cada lacuna, gera perguntas em linguagem natural com apoio de LLMs, organizadas em cinco dimensões: (1) integração de sistemas; (2) regras de negócio; (3) exceções e casos de borda; (4) segurança e privacidade; e (5) indicadores de sucesso. A plataforma exibe o total de perguntas pendentes e prioriza as críticas para o avanço da jornada. O agente não assume informações não explicitadas pelo usuário (RN-IA-ED-01), e as respostas obtidas atualizam dinamicamente o contexto da demanda.

Serviço S3 (Geração do Documento de Entendimento): consolida o ciclo de elicitação em um Documento de Entendimento do Caso de Uso, com os campos: Título, Domínio Clínico, Objetivo, Atores Envolvidos, Fluxo Principal, Regras de Negócio, Dados Essenciais e Integrações Necessárias. O documento é apresentado para visualização e edição pelo Autor; a versão gerada automaticamente é preservada para auditoria. O aceite formal desse documento habilita o avanço para a Etapa 2.

3.2 Agente AV (Análise de Viabilidade)

O Agente AV realiza análise técnica, semântica e institucional da demanda, identificando oportunidades de reuso de artefatos existentes e fundamentando a decisão de avanço para a modelagem clínica. Opera sobre o Documento de Entendimento produzido pelo Agente ED.

Tabela 2. Categorias de Regras de Negócio Recomendadas pelo Agente MCA

Categoria	Exemplos	Classificação
Obrigatoriedade	Elemento obrigatório, condicional ou opcional	Rejeição
Cardinalidade	Mínima e máxima por elemento de dados	Rejeição
Formato	Data (AAAA-MM-DD), CPF, telefone, CEP	Rejeição
Domínio de valores	Faixas numéricas válidas, combinações permitidas	Rejeição / Advertência
Consistência semântica	Relação lógica entre elementos dependentes	Advertência
Conformidade terminológica	Validação de códigos contra ValueSet vinculado	Rejeição

Fonte: Elaborado pelos autores (2026).

Serviço S4 (Busca Semântica de MIs/IGs Similares): transforma o Documento de Entendimento em representação vetorial obtida por modelo de *embeddings*, utilizada para calcular similaridade semântica com artefatos indexados na base RAG. Os resultados são exibidos em lista ordenada por grau de aderência, com indicação de nome, origem, tipo, escopo e elementos que justificam a similaridade (Figura 3). Nenhum artefato é aplicado automaticamente sem confirmação (CA-IA-AV-03).

Figura 3. Execução do Serviço S4 para busca semântica de MIs e IGs similares.

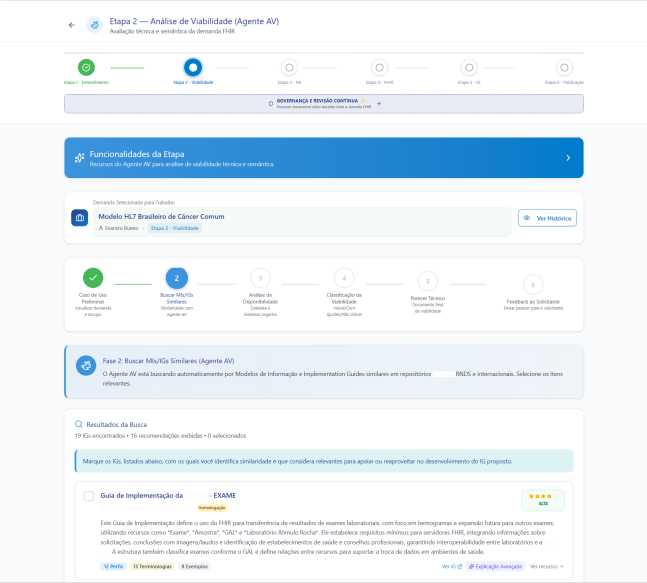

Fonte: Elaborado pelos autores (2026).

Serviço S5 (Parecer de Viabilidade Técnica): consolida os resultados da busca semântica e da análise de disponibilidade de dados em um parecer, contendo: Identificação do Projeto, Resumo Executivo, Análise de Similaridade, Disponibilidade de Dados, Classificação da Viabilidade (Viável / Viável com Ajustes / Não Viável), Recursos FHIR Recomendados, Riscos e Recomendações. O Parecer é submetido à revisão do Núcleo de Padronização antes de habilitar o avanço para a Etapa 3.

Serviço S6 (Feedback Inteligente ao Solicitante): gera automaticamente texto de retorno personalizado ao demandante, em linguagem clara e institucional, adaptado conforme a classificação obtida no Parecer. O texto inclui: identificação da demanda, resultado da análise, síntese técnica e próximos passos. Pode ser editado pelo Núcleo antes do envio automático por e-mail, que encerra a Etapa 2.

3.3 Agente MCA (Modelagem Clínica Apoiada)

O Agente MCA é o núcleo funcional dos agentes de IA da plataforma. Ele possui quatro serviços inteligentes, organizados em cinco fases: Identificação; Nome, Escopo e Uso; Limitações e Relacionamentos; Conteúdo do Modelo; e Origem e Referências. A sua operação apoia-se na extração de informações assistida por LLM e enriquecimento de contexto baseado em similaridade semântica com outros MIs, Recursos e Terminologias FHIR.

Serviço S7 (Extração Automática de Dados da Etapa 1): extrai informações do Documento de Entendimento para preencher campos estruturados do MI, eliminando retrabalho e garantindo consistência. O agente sugere nome oficial do MI, descrição de escopo, cenários de uso, limitações e referências normativas. Campos com baixa confiança de extração são sinalizados para revisão manual. A extração não sobrescreve conteúdo inserido manualmente sem confirmação do Autor.

Serviço S8 (Extração Inteligente de Elementos de Dados): por meio de análise semântica, identifica e sugere automaticamente os elementos de dados clínicos e administrativos para compor a Tabela 2 do MI. O processo analisa o Documento de Entendimento, o Parecer de Viabilidade, documentos normativos e a base vetorial. Elementos são apresentados em organização hierárquica, com sugestão de tipos de dados FHIR compatíveis (*string*, *code*, *identifier*, *date*, *Quantity*) e terminologias associadas quando disponíveis. O agente identifica possíveis duplicidades e sinaliza inferências de baixa confiança. O Autor seleciona, ajusta ou descarta as sugestões antes da consolidação no modelo.

Serviço S9 (Recomendação de Regras de Negócio): utiliza LLMs para recomendar regras de negócio para cada elemento de dados do MI, considerando o tipo do dado, o contexto clínico das Etapas 1 e 2, as terminologias vinculadas e a base vetorial. As regras são classificadas em duas categorias: Rejeição (bloqueio de dados inválidos) e Advertência (alerta sem

bloqueio), distribuídas em seis categorias de conteúdo (Tabela 2). O identificador único de cada regra (padrão RNxx) garante rastreabilidade. O Autor pode selecionar, editar, criar manualmente ou descartar as sugestões; a plataforma impede o salvamento de regras incompletas.

Serviço S10 (Busca Semântica de Artefatos FHIR): realiza busca por similaridade em repositórios oficiais (RNDS no *Simplifier*, FHIR *Registry* e repositórios institucionais) para cada elemento de dados do MI, identificando artefatos aderentes: *ValueSets*, *CodeSystems*, *NamingSystems*, *ConceptMaps* e *Extensions*. Os resultados são ranqueados por similaridade, com metadados essenciais (nome, tipo, URL canônica, status) e filtros por tipo de artefato. Quando nenhum artefato existente for adequado, a plataforma inicia o fluxo de criação de novo artefato semântico. A aplicação de artefatos ao MI requer confirmação do Autor; artefatos obsoletos ou experimentais são sinalizados automaticamente.

3.4 Base de Conhecimento Vetorial

A eficácia dos agentes depende diretamente da qualidade e abrangência da base de conhecimento indexada. A base de conhecimento vetorial da plataforma abrange fontes brasileiras (artefatos RNDS publicados no *Simplifier*) e internacionais (HL7r4 *Core*).

O processo de ingestão compreende a coleta dos IGs em formato HTML e JSON, a fragmentação semântica dos elementos, a geração de representações vetoriais bilíngues (PT/EN) enriquecidas com uso de LLMs e, por fim, o armazenamento em banco vetorial. Na etapa de inferência, a recuperação por similaridade alimenta a geração aumentada pelo modelo de linguagem, com rastreabilidade entre resposta e fonte. A base é atualizada periodicamente, respeitando os ciclos de publicação dos IGs de referência.

4 DISCUSSÃO

Os resultados demonstram que, nas três primeiras etapas da Jornada FHIR, a plataforma organiza o processo de modelagem clínica interoperável em um ciclo apoiado por três agentes especializados e nove serviços inteligentes (S2 a S10) com rastreabilidade entre a sugestão gerada, a fonte de origem e a decisão humana.

Essa correspondência entre serviços propostos e problemas identificados fortalece a aderência da solução ao contexto real de trabalho. O Agente ED responde à dificuldade de elicitar demandas clínicas completas e qualificar o entendimento inicial do caso de uso, preenchendo lacunas informacionais que, sem suporte inteligente, dependem exclusivamente da experiência do especialista disponível [7]. O Agente AV contempla a complexidade da análise de viabilidade técnica, semântica e institucional, reduzindo o esforço manual de busca por artefatos existentes e fundamentando a decisão de avanço com maior consistência e rastreabilidade [5]. O Agente MCA apoia a construção do MI: a extração de elementos clínicos, a recomendação de regras de negócio e a vinculação a artefatos FHIR são operações que, sem automação assistida, exigem ciclos extensos de revisão e geram retrabalho recorrente.

A adoção de *Design Sprint* e *Design Thinking* [16,17] como métodos de levantamento de requisitos ampliou a consistência metodológica da concepção da plataforma. As sessões de cocriação garantiram que os serviços S2 a S10 respondessem a necessidades reais, mapeadas a partir das dores operacionais das equipes, e não a suposições sobre as dificuldades da modelagem FHIR, conferindo validade de face à arquitetura.

Do ponto de vista tecnológico, a arquitetura dual adotada, com Google Gemini como motor de geração de linguagem e Qwen3 como motor de pré-processamento semântico, é fundamentada em evidências recentes de desempenho. Saab *et al.* [8] demonstraram que o Gemini apresenta desempenho elevado em avaliações médicas de múltipla escolha, ao passo que o Qwen3 contempla mecanismo de raciocínio adaptativo que permite alternar entre modo de raciocínio profundo e modo direto, conforme a complexidade da tarefa [18]. O mecanismo de recuperação semântica, apoiado por uma base vetorial de conhecimento, fundamenta as respostas dos agentes em padrões FHIR estabelecidos, mitigando o risco de sugestões genéricas ou incompatíveis com o contexto de interoperabilidade nacional. Neha *et al.* [10] confirmam que sistemas baseados em RAG reduzem erros e aumentam a relevância clínica das respostas em comparação com modelos sem recuperação de conhecimento externo.

Frei *et al.* [13] propõem uma estratégia agentiva ponta a ponta para converter narrativas clínicas em recursos FHIR; Li *et al.* [19] demonstram que LLMs transformam narrativas clínicas em recursos FHIR com mínima anotação manual, superando *pipelines* de PLN baseados em regras; Kabak *et al.* [14] exploram a técnica de RAG para recomendações clínicas baseadas em dados de pacientes no formato FHIR. Em todos esses estudos, o foco recai sobre o consumo de dados clínicos já estruturados, para apoio ao clínico ou para transformação automatizada de registros. A Plataforma distingue-se por apoiar uma etapa anterior desse processo, pois não opera sobre dados clínicos já existentes, mas sobre o trabalho do modelador que precede a geração dos artefatos computacionais. Esse deslocamento, do apoio à decisão clínica para o apoio à engenharia dos artefatos de interoperabilidade, constitui contribuição original ao campo da Informática em Saúde.

O HITL, adotado como diretriz transversal da Plataforma, responde a um requisito de IA responsável. Olawade *et al.* [12], em uma revisão sobre HITL em saúde, demonstram que sistemas com supervisão

humana apresentam maior precisão e menor incidência de erros em comparação com sistemas totalmente automatizados. Na Plataforma, o HITL não se restringe a uma validação final: ele opera em cada ponto de consolidação de dados ao longo da jornada. Nenhum elemento de dados é incorporado ao MI sem seleção explícita do Autor; nenhum Parecer de Viabilidade é encaminhado ao solicitante sem revisão do Núcleo de Padronização; nenhum artefato FHIR é vinculado ao modelo sem confirmação manual. Esses mecanismos mitigam, mas não eliminam, os riscos de alucinações e imprecisões inerentes a sistemas baseados em LLMs [10], o que reforça a necessidade de avaliação formal dos artefatos produzidos em uso real.

Quanto às implicações práticas, a arquitetura proposta tem potencial para ampliar a capacidade de instituições que precisam produzir artefatos FHIR sem dispor de equipes com perfil técnico multidisciplinar. Em vez de substituir especialistas, a plataforma distribui o conhecimento especializado ao longo de uma jornada guiada: os serviços inteligentes orientam decisões que, sem automação assistida, demandariam horas de pesquisa em repositórios de terminologias, documentação FHIR e artefatos de referência. A rastreabilidade entre sugestão, fonte e decisão humana torna o processo mais auditável e passível de revisão institucional. O reaproveitamento de artefatos existentes, promovido pelos Serviços S4 e S10, reduz redundâncias e favorece a padronização entre projetos de diferentes domínios clínicos.

Para a Saúde Digital, o artigo abre uma direção de pesquisa pouco explorada: a aplicação de agentes de IA generativa à engenharia e governança dos artefatos de interoperabilidade. Enquanto Thirunavukarasu *et al.* [9] documentam o desempenho de LLMs em tarefas clínicas de consumo de dados e Rajpurkar *et al.* [11] discutem as condições para uma IA segura e responsável em medicina, poucos estudos abordam o processo de produção da infraestrutura semântica que torna a interoperabilidade possível. A Plataforma contribui com esse campo, pois demonstra que é possível especificar agentes de IA orientados ao modelador clínico, ao Autor do MI e ao analista de interoperabilidade, integrando recuperação semântica apoiada em bases vetoriais de IGs FHIR, HITL e governança em uma jornada estruturada.

O estudo apresenta limitações. A plataforma encontra-se em estágio inicial, com os agentes das etapas 4 a 7 ainda em especificação, e não foram conduzidas avaliações comparativas entre modelagem manual e assistida nem definidas métricas formais de qualidade dos MIs. Estudos de usabilidade com as equipes ainda são necessários para verificar a aderência do modelo de interação à prática real. A validade interna é parcialmente mitigada pela cocriação estruturada, mas os serviços precisam ser avaliados em uso real; a validade externa é limitada pelo contexto institucional específico, podendo exigir adaptações para outros estados; e a validade de construção e tecnológica depende de métricas objetivas, da disponibilidade das APIs externas, da atualidade da base vetorial de conhecimento utilizada na recuperação semântica e da evolução dos LLMs empregados.

5 CONCLUSÕES

Este artigo apresentou a arquitetura de agentes de inteligência artificial de uma plataforma inteligente para apoio à modelagem clínica interoperável baseada no padrão FHIR. O método de cocriação adotado, com *Design Sprint* e *Design Thinking*, assegurou que os agentes fossem concebidos a partir de dores operacionais reais das equipes de modelagem, e não de pressupostos teóricos isolados. Os três agentes especificados (ED, AV e MCA) e os seus nove serviços inteligentes formam um ciclo auditável de apoio à modelagem, da elicitação do caso de uso à definição de regras de negócio e busca de artefatos semânticos, com rastreabilidade e controle humano garantidos em todas as etapas.

A Plataforma posiciona-se como contribuição à infraestrutura de Saúde Digital do SUS e como modelo replicável para secretarias estaduais que necessitem escalar a produção de artefatos FHIR conformantes. Trabalhos futuros incluem: avaliação formal da qualidade dos MIs gerados em comparação com modelagem manual; estudos de usabilidade com equipes técnicas; especificação e implementação dos agentes das etapas 4 a 7; integração com SUSHI e IG *Publisher* para geração automatizada de IGs publicáveis; e implantação progressiva em casos de uso reais do SUS, com potencial de replicação em outros contextos institucionais.

Contribuição dos autores. Todos os autores contribuíram para a concepção do estudo e para a análise e interpretação dos resultados, revisaram criticamente o manuscrito e aprovaram a versão final.

Agradecimentos. Os autores agradecem à Secretaria de Estado da Saúde de Goiás (SES-GO) e à Universidade Federal de Goiás (UFG) pelo apoio institucional ao desenvolvimento deste estudo.

Financiamento. Este estudo foi financiado pela Secretaria de Estado da Saúde de Goiás (SES-GO), por meio do Convênio nº 16/2026-SES (Processo nº 202600010001407), firmado com a Universidade Federal de Goiás (UFG), no âmbito do projeto "Núcleo de Padronização de Informação em Saúde no Estado de Goiás: Expansão, Governança e Desenvolvimento do HUB Saúde", com concessão de bolsas de pesquisa.

Disponibilidade de dados e materiais. Os autores não declararam a disponibilidade dos dados e materiais da pesquisa.

Conflitos de interesse. Os autores declaram não haver conflitos de interesse. A plataforma é desenvolvida no âmbito da Secretaria de Estado da Saúde de Goiás, sem finalidade comercial; parte dos autores atua na instituição, que também financia o projeto, conforme declarado em Financiamento.

Declaração de uso de IA. No desenvolvimento desta pesquisa, ferramentas de inteligência artificial generativa foram utilizadas nos seguintes contextos: (i) Google Gemini e GitHub Copilot como apoio à geração e revisão de código durante a implementação da Plataforma; (ii) Figma Make como ferramenta de prototipação assistida de interfaces por descrições textuais; (iii) assistente de linguagem como apoio à revisão linguística do manuscrito; e (iv) o ChatGPT foi utilizado como apoio à elaboração das Figuras 1 e 2. Todo o conteúdo técnico-científico, as análises e as conclusões são de responsabilidade exclusiva dos autores.

REFERÊNCIAS

1. Lehne M, Sass J, Essenwanger A, Schepers J, Thun S. Why digital medicine depends on interoperability. NPJ Digit Med. 2019;2:79. doi: https://doi.org/10.1038/s41746-019-0158-1
2. World Health Organization. Global strategy on digital health 2020-2025 [Internet]. Geneva: World Health Organization; 2021 [citado 2026 out 18]. Disponível em: https://www.who.int/publications/i/item/9789240020924
3. Donida B, da Costa CA, Scherer JN. Making the COVID-19 Pandemic a Driver for Digital Health: Brazilian Strategies. JMIR Public Health Surveill. 2021;7(6):e28643. doi: https://doi.org/10.2196/28643
4. Benson T, Grieve G. Principles of Health Interoperability: FHIR, HL7 and SNOMED CT. 4th ed. Cham: Springer; 2021. doi: https://doi.org/10.1007/978-3-030-56883-2
5. Nopour R. Using FHIR for data sharing: A scoping review of challenges and facilitators in healthcare settings. Int J Med Inform. 2026;205:106128. doi: https://doi.org/10.1016/j.ijmedinf.2025.106128
6. Ghaffari Heshajin S, Sedghi S, Panahi S, Takian A. A framework for health information governance: a scoping review. Health Res Policy Syst. 2024;22(1):109. doi: https://doi.org/10.1186/s12961-024-01193-9
7. Baslyman M. Requirements Engineering in Healthcare: Lessons Learned from Practice. In: SOFTENG 2022: The Eighth International Conference on Advances and Trends in Software Engineering; 2022 Apr 24-28; Barcelona, Spain. IARIA; 2022. p. 21-7. ISBN 978-1-61208-946-1. Disponível em: https://www.thinkmind.org/articles/softeng_2022_1_40_90011.pdf
8. Saab K, Tu T, Weng WH, et al. Capabilities of Gemini Models in Medicine. arXiv:2404.18416. 2024.
9. Thirunavukarasu AJ, Ting DSJ, Elangovan K, Gutierrez L, Tan TF, Ting DSW. Large language models in medicine. Nat Med. 2023;29(8):1930-40. doi: https://doi.org/10.1038/s41591-023-02448-8
10. Neha F, Bhati D, Shukla DK. Retrieval-Augmented Generation (RAG) in Healthcare: A Comprehensive Review. AI. 2025;6(9):226. doi: https://doi.org/10.3390/ai6090226
11. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. Nat Med. 2022;28(1):31-8. doi: https://doi.org/10.1038/s41591-021-01614-0
12. Olawade DB, Plabon SB, Ojo A, Ogunbona MA, Makanjuola BD, Olasilola OR. Human in the loop artificial intelligence in healthcare: applications, outcomes, and implementation challenges. Int J Med Inform. 2026;213:106362. doi: https://doi.org/10.1016/j.ijmedinf.2026.106362
13. Frei J, Feldhus N, Raithel L, Roller R, Meyer A, Kramer F. Infherno: End-to-end Agent-based FHIR Resource Synthesis from Free-form Clinical Notes. In: Proceedings of the 19th Conference of the European Chapter of the Association for Computational Linguistics (Volume 3: System Demonstrations). Stroudsburg, PA, USA: Association for Computational Linguistics; 2026. p. 163-74. doi: https://doi.org/10.18653/v1/2026.eacl-demo.13
14. Kabak Y, Laleci Erturkmen GB, Gencturk M, Namli T, Sinaci AA, Alcantud Corcoles R, et al. FHIR-RAG-MEDS: Integrating HL7 FHIR with Retrieval-Augmented Large Language Models for Enhanced Medical Decision Support. MDPI AG [Preprint]. 2026. doi: https://doi.org/10.20944/preprints202602.1807.v1
15. Paili V. Enhancing Healthcare Data Interoperability with AI-Driven Synthetic Datasets Using FHIR Standards. Int J Comput. 2025;56(1):297-308. Disponível em: https://ijcjournal.org/InternationalJournalOfComputer/article/view/2474
16. Knapp J, Zeratsky J, Kowitz B. Sprint: How to Solve Big Problems and Test New Ideas in Just Five Days. New York: Simon & Schuster; 2016.
17. Brown T. Change by Design: How Design Thinking Transforms Organizations and Inspires Innovation. New York: Harper Business; 2009.
18. Yang A, Li A, Yang B, Zhang B, Hui B, Zheng B, et al. Qwen3 technical report. arXiv [Preprint]. 2025. doi: https://doi.org/10.48550/arXiv.2505.09388
19. Li Y, Wang H, Yerebakan HZ, Shinagawa Y, Luo Y. FHIR-GPT Enhances Health Interoperability with Large Language Models. NEJM AI. 2024;1(8). doi: https://doi.org/10.1056/aics2300301

NOTAS EDITORIAIS

O Journal of Health Informatics é uma publicação científica mantida pela Sociedade Brasileira de Informática em Saúde, associação científica sem fins lucrativos dedicada ao desenvolvimento da Informática em Saúde e da Saúde Digital no Brasil. O processo editorial é conduzido com independência científica, sem interferência institucional, comercial ou de patrocinadores, e segue as boas práticas internacionais de ética em publicação científica.

Este artigo foi avaliado por pares, em sistema duplo-cego, por especialistas da área. A equipe editorial usou ferramentas de inteligência artificial, com supervisão humana, na triagem inicial, na conferência do texto, das referências e dos números e, quando necessário, no redesenho de figuras, quadros e tabelas, aprovado pelos autores na prova. As ferramentas e as salvaguardas estão na Política de uso de inteligência artificial da revista. As decisões editoriais foram tomadas por pessoas.

SBIS Sociedade Brasileira de Informática em Saúde