Journal of Health Informatics

J Health Inform. 2026;18:e1812
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1812

ARTIGO COMPLETO
CBIS 2026

Aplicação de LLMs à visualização de dados: uma revisão sistemática e perspectivas para dashboards em vigilância epidemiológica

Application of LLMs to data visualization: a systematic review and perspectives for epidemiological surveillance dashboards

Antônio Rodrigues Pinto Junior[1], Anita Maria da Rocha Fernandes[1], Wemerson Delcio Parreira[2]

ORCID: 0009-0008-0266-1634 · 0000-0002-2986-5353 · 0000-0003-1896-0520

[1] Universidade do Vale do Itajaí, Itajaí (SC), Brasil.

[2] Pontifícia Universidade Católica de Campinas, Campinas (SP), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1812

DOI
10.59681/2175-4411.v18.iEspecial.2026.1812

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
Antônio Rodrigues Pinto Junior
antonior@edu.univali.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

Introdução: Embora dashboards tenham se consolidado como ferramentas essenciais para decisões baseadas em evidências, sua efetividade ainda é limitada por barreiras de uso, sobrecarga de informação e dificuldades de acesso para diferentes perfis de usuários. Técnicas de Inteligência Artificial (IA), como Modelos de Linguagem de Grande Escala, Modelos Multimodais de Grande Escala, Geração Aumentada por Recuperação e agentes conversacionais, vêm sendo aplicadas a visualizações, embora seu uso em saúde pública permaneça restrito. **Objetivo:** Analisar como técnicas de IA apoiam a visualização de dados em diferentes domínios e avaliar seu potencial de transferência para a vigilância epidemiológica. **Método:** Revisão sistemática conduzida conforme PRISMA. **Resultados:** Dos 705 registros identificados, 35 foram selecionados. Os estudos indicam três níveis de atuação (entrada, suporte analítico e interpretação), viabilizando visualizações por linguagem natural, raciocínio multimodal e sistemas multiagente. **Conclusão:** A ausência de estudos em vigilância epidemiológica evidencia lacuna e demanda validação em contextos reais.

Descritores: Modelos de Linguagem de Grande Escala; Visualização de Dados; Monitoramento Epidemiológico.

ABSTRACT

Introduction: Although dashboards have become essential tools for evidence-based decision-making, their effectiveness remains limited by usability barriers, information overload, and access difficulties for different user profiles. Artificial intelligence (AI) techniques, such as Large Language Models, Multimodal Large Language Models, Retrieval-Augmented Generation, and conversational agents, have been applied to visualizations, although their use in public health remains restricted. **Objective:** To analyze how AI techniques support data visualization across different domains and to assess their transfer potential to epidemiological surveillance. **Method:** Systematic review conducted according to PRISMA. **Results:** Of the 705 records identified, 35 were selected. The studies indicate three levels of operation (input, analytical support, and interpretation), enabling natural language visualizations, multimodal reasoning, and multi-agent systems. **Conclusion:** The absence of studies in epidemiological surveillance reveals a gap and highlights the need for validation in real-world contexts.

Keywords: Large Language Models; Data Visualization; Epidemiological Monitoring.

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: Pinto Junior AR, Fernandes AMR, Parreira WD. Aplicação de LLMs à visualização de dados: uma revisão sistemática e perspectivas para dashboards em vigilância epidemiológica. J Health Inform 2026;18:e1812. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1812

1 INTRODUÇÃO

A Visualização de Dados (DV) transforma dados em representações visuais com o propósito de ampliar capacidades cognitivas humanas e apoiar processos de descoberta e tomada de decisão baseados em evidências [1]. Nesse contexto, o *dashboard* constitui uma das principais ferramentas de DV, atuando como ambiente visual que integra múltiplas fontes e representações de dados em um único espaço interativo, permitindo ao usuário explorar, sintetizar e compreender informações complexas de maneira dinâmica, e funcionando como elemento essencial para transformar dados em conhecimento acionável [2].

Na saúde pública, e em especial na Vigilância Epidemiológica (VE), a aplicação dos *dashboards* tem se mostrado estratégica. A natureza multidimensional dos dados de saúde (abrangendo registros clínicos, fatores demográficos e determinantes sociais e ambientais) exige ferramentas capazes de transformar dados complexos em informações compreensíveis e acionáveis [3]. *Dashboards* interativos permitem o acompanhamento em tempo real de indicadores epidemiológicos, a detecção precoce de padrões e a comunicação eficaz a gestores, pesquisadores e formuladores de políticas [4], consolidando dados heterogêneos e contribuindo para a agilidade das respostas em saúde e para a transparência das decisões públicas [5,6].

Contudo, a adoção efetiva de *dashboards* em VE esbarra em obstáculos estruturais e humanos: a diversidade de formatos e fontes de dados dificulta a integração; a ausência de padrões interoperáveis entre plataformas fragmenta os sistemas; e a combinação de baixa familiaridade com visualizações e alta demanda cognitiva limita a capacidade de interpretação por parte dos profissionais de saúde [7]. Adicionalmente, muitos *dashboards* concentram-se na exibição dos dados, mas carecem de mecanismos de apoio à interpretação e contextualização, o que reduz sua utilidade prática [4,6].

É nesse cenário que a Inteligência Artificial (IA) surge como potencial agente de transformação. Abordagens baseadas em Modelos de Linguagem de Grande Escala (LLMs) e Modelos Multimodais de Grande Escala (MLLMs), capazes de integrar texto, imagens, áudios e tabelas, bem como a Geração Aumentada por Recuperação (RAG), que combina a geração da LLM com informações recuperadas de fontes externas, vêm sendo exploradas para apoiar a análise de dados e a interpretação de visualizações. Essas abordagens permitem interagir com *dashboards* por linguagem natural (NL), explicar gráficos, responder a perguntas contextuais e sugerir *insights*. Embora ainda não estejam consolidadas na VE, podem contribuir para mitigar desafios de literacia visual, carga cognitiva e compreensão de informações complexas, hipótese que ainda requer validação empírica [5,6].

Constata-se, portanto, uma lacuna científica: são escassos os estudos que investigam a aplicação de técnicas emergentes de IA, como LLMs integradas à DV, no contexto da VE. Diante disso, esta revisão sistemática mapeia e sintetiza o estado da arte das aplicações de LLMs à DV, orientada pelas seguintes questões:

RQ1: Como técnicas emergentes de IA, especialmente LLMs, vêm sendo aplicadas para apoiar a visualização de dados em *dashboards* em diferentes domínios? **RQ2**: Tais técnicas têm potencial de preencher lacunas no contexto da saúde pública, em especial na vigilância epidemiológica?

A relevância da investigação reside em tornar a análise e interpretação de dados epidemiológicos mais acessível, compreensível e acionável, sobretudo para gestores e profissionais com pouca experiência em análise de dados, reduzindo barreiras cognitivas e fortalecendo a decisão baseada em evidências.

2 MÉTODOS

Adotou-se a diretriz PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) [8] como referencial de relato para ampliar a transparência e a rastreabilidade da revisão. O processo compreendeu: (i) formulação das questões de pesquisa; (ii) desenvolvimento da estratégia de busca; (iii) definição dos critérios de elegibilidade; e (iv) seleção e análise dos estudos incluídos (Figura 1).

Figura 1. Etapas principais da revisão sistemática segundo o PRISMA.

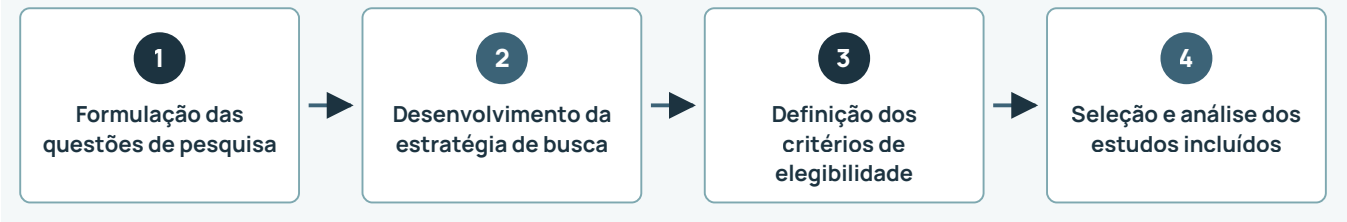

Fonte: Elaborado pelos autores (2026).

2.1 Estratégia de busca, palavras-chave e bases de dados

A estratégia de busca foi elaborada para identificar de forma ampla e sistemática os estudos mais relevantes sobre técnicas emergentes de IA aplicadas à DV. As buscas foram executadas em 19 de outubro de 2025 nas bases ACM Digital Library, IEEE Xplore, PubMed e Scopus, nos campos título e resumo e, no Scopus, também palavras-chave. Utilizou-se a *string* geral:

((dashboard* OR chart* OR plot* OR "data visualization") AND (interpretation OR explanation OR reasoning OR analysis OR question OR answering OR understanding OR "context-aware" OR annotation*) AND (LLM OR "large language model*" OR multimodal OR "generative AI" OR AI OR GenAI OR chat OR chatbot* OR "conversational agent" OR "AI assistant" OR "natural language")).

A sintaxe foi adaptada a cada base. O protocolo, as estratégias completas por base, as listas de estudos e os dados suplementares estão registrados no Open Science Framework (OSF), disponível no link (https://doi.org/10.17605/OSF.IO/DWTV7).

2.2 Critérios de elegibilidade, triagem e extração

Foram incluídos estudos completos revisados por pares, em inglês e publicados a partir de 2017, que abordassem técnicas de IA aplicadas à visualização de dados ou *dashboards* e apresentassem aplicações, modelos, *frameworks*, *datasets* ou avaliações de usabilidade e interpretação. Foram excluídos duplicatas, revisões, resumos, pôsteres, relatórios técnicos, trabalhos puramente teóricos ou fora do escopo e estudos sem texto completo. Admitiu-se explicitamente um *preprint* de 2025 sobre transcriptômica espacial [9], por conter descrição metodológica e resultados completos em tema emergente; essa exceção é identificada nos dados do OSF.

Os 705 registros foram importados no Rayyan, aplicação web utilizada para organizar referências, detectar duplicatas e registrar decisões de triagem. Após a remoção de 32 duplicatas, 673 registros foram avaliados por título e resumo, dos quais 172 seguiram para recuperação do texto completo. Vinte e nove não foram obtidos; entre 143 textos avaliados, 108 foram excluídos (7 revisões, 4 anteriores a 2017 e 97 fora do escopo), resultando em 35 estudos (Figura 2). A triagem, a elegibilidade e a extração foram conduzidas por um revisor e dúvidas interpretativas foram discutidas com os coautores. Não houve triagem independente em duplicata nem cálculo de concordância. Foram extraídos autor, ano, título, técnicas e arquiteturas, propósito, dados, métricas, resultados e limitações. As listas completas dos estudos incluídos e excluídos podem ser consultadas no link do registro no OSF, mencionado anteriormente.

2.3 Avaliação da qualidade e síntese

Não foi aplicado instrumento formal de avaliação da qualidade metodológica ou do risco de viés, devido à heterogeneidade dos desenhos, que incluíram sistemas, *benchmarks* e estudos de usuários. A síntese foi qualitativa e descritiva, sem metanálise ou ponderação dos estudos. Essa ausência limita a certeza das inferências e foi considerada na formulação das conclusões.

3 RESULTADOS

Os 35 estudos incluídos (Tabela 1) foram analisados para responder à RQ1, oferecendo visão integrada sobre o uso de LLMs na DV, com indicação de avanços, lacunas e potenciais direções para sua adoção em *dashboards* de VE.

Figura 2. Fluxograma PRISMA do processo de seleção dos estudos.

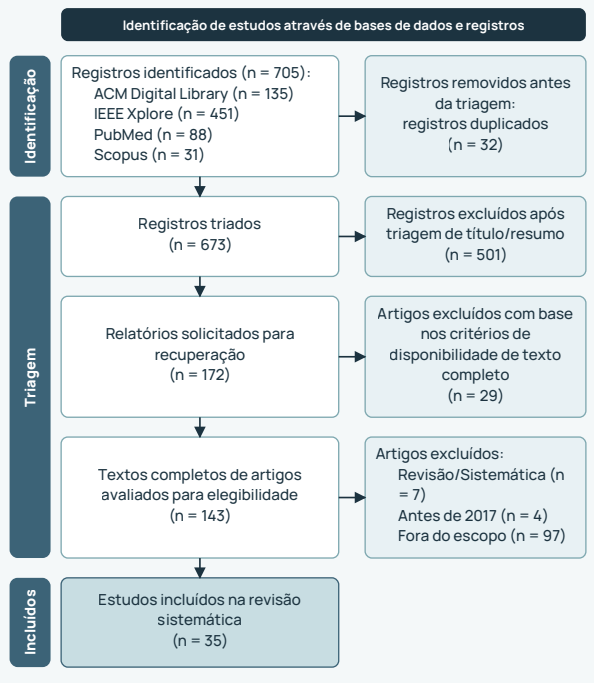

Fonte: Elaborado pelos autores (2026).

3.1 Domínios de aplicação e categorias de contribuição

Os domínios foram definidos pelo contexto de uso, público-alvo, problema e tipo de dado descritos em cada estudo; contribuições genéricas de métodos ou ferramentas foram agrupadas em Visualização e Análise de Dados. Atribuiu-se um domínio predominante a cada estudo. Predominaram Visualização e Análise de Dados, com 21 estudos (60%), Setor Financeiro e Mercado de Capitais, com sete estudos (20%), e Saúde, Biomedicina e Pesquisa Farmacêutica, com três estudos (8,6%), seguidos por Análise Estatística e Econômica, Controle e Automação Industrial, Acessibilidade para Deficientes Visuais e Agronegócio, com 1 estudo cada (11,4% no total) (Figura 3).

Tabela 1. Relação de estudos incluídos.

#	Estudo	Título
1	Zeng *et al.* (2025)	Advancing Multimodal Large Language Models in Chart Question Answering with Visualization-Referenced Instruction Tuning
2	Wang *et al.* (2025)	Agricultural Futures Trading Decision Using AI Agent With Multiscale Candlestick Analysis
3	Kharatmol *et al.* (2025)	AI-Driven Finance Advisor for Personalized Investment Strategies
4	Bendeck *et al.* (2025)	An Empirical Evaluation of the GPT-4 Multimodal Language Model on Visualization Literacy Tasks
5	Ajina *et al.* (2025)	An Integrated System for Real-Time Greenhouse Environmental Forecasting and Adaptive Crop Management
6	Jiang *et al.* (2025)	AutoMA: Automated Generation of Multi-level Annotations for Time Series Visualization
7	Ullah *et al.* (2025)	Chart Classification and Text Element Detection: Enhancing Drug Development Workflows with Deep Learning and Contextualized LLMs
8	Tian *et al.* (2025)	ChartGPT: Leveraging LLMs to Generate Charts From Abstract Natural Language
9	Xia *et al.* (2025)	ChartX & ChartVLM: A Versatile Benchmark and Foundation Model for Complicated Chart Reasoning
10	Choe *et al.* (2025)	Enhancing Data Literacy On-Demand: LLMs as Guides for Novices in Chart Interpretation
11	Song *et al.* (2025)	FeVisQA: Free-Form Question Answering over Data Visualizations
12	Hao *et al.* (2025)	FinFlier: Automating Graphical Overlays for Financial Visualizations With Knowledge-Grounding Large Language Model
13	Lo e Qu (2025)	How Good (Or Bad) Are LLMs at Detecting Misleading Visualizations?
14	Jang *et al.* (2025)	ICT-QA: Question Answering Over Multi-Modal Contexts Including Image, Chart, and Text Modalities
15	Lin *et al.* (2024)	InkSight: Leveraging Sketch Interaction for Documenting Chart Findings in Computational Notebooks
16	Vázquez *et al.* (2024)	Are LLMs ready for Visualization?
17	Zhao *et al.* (2024)	CT2C-QA: Multimodal Question Answering over Chinese Text, Table and Chart
18	Jiang *et al.* (2025)	Multimodal retrieval-augmented generation for financial documents: image-centric analysis of charts and tables with large language models
19	Wan *et al.* (2025)	DataVisT5: A Pre-Trained Language Model for Jointly Understanding Text and Data Visualization
20	Wei *et al.* (2026)	mChartQA and mChartQABench: A multimodal-only solution for complex chart question-answering
21	Praneeth *et al.* (2024)	Natural Language Interface for Data Visualization: Harnessing the Power of Large Language Models
22	Wu *et al.* (2024)	ChartInsights: Evaluating Multimodal Large Language Models for Low-Level Chart Question Answering
23	Liu *et al.* (2024)	MMC: Advancing Multimodal Chart Understanding with Large-scale Instruction Tuning
24	Lin *et al.* (2025)	Spatial transcriptomics AI agent charts hPSC-pancreas maturation in vivo
25	Seo *et al.* (2024)	MAIDR Meets AI: Exploring Multimodal LLM-Based Data Visualization Interpretation by and with Blind and Low-Vision Users
26	Kang *et al.* (2025)	AI Agent-Based Operational Data Intelligent Analysis and Practice
27	Zheng *et al.* (2025)	Advancing Chart Question Answering with Robust Chart Component Recognition
28	Xavier *et al.* (2024)	LLM-Powered Multi-Actor System for Intelligent Analysis and Visualization of IEC 61499 Control Systems
29	Lin *et al.* (2025)	Non-Natural Image Understanding with Advancing Frequency-based Vision Encoders
30	Ying *et al.* (2025)	Reviving Static Charts Into Live Charts
31	Wang *et al.* (2025)	Data Formulator 2: Iterative Creation of Data Visualizations, with AI Transforming Data Along the Way
32	Qiu *et al.* (2025)	SmartMLVs: LLM-enabled Multiple Linked Views Generation for Interactive Visualization
33	Huang *et al.* (2024)	Summarizing Charts of Financial Document via Context-Aware Multi-Modeling
34	Tanasă *et al.* (2025)	Rethinking Chart Understanding Using Multimodal Large Language Models
35	Chen *et al.* (2025)	VisEval: A Benchmark for Data Visualization in the Era of Large Language Models

Identificação pelo primeiro autor, ano e título; metadados completos no OSF.

Fonte: Elaborado pelos autores (2026).

Figura 3. Distribuição dos 35 estudos por domínio de aplicação.

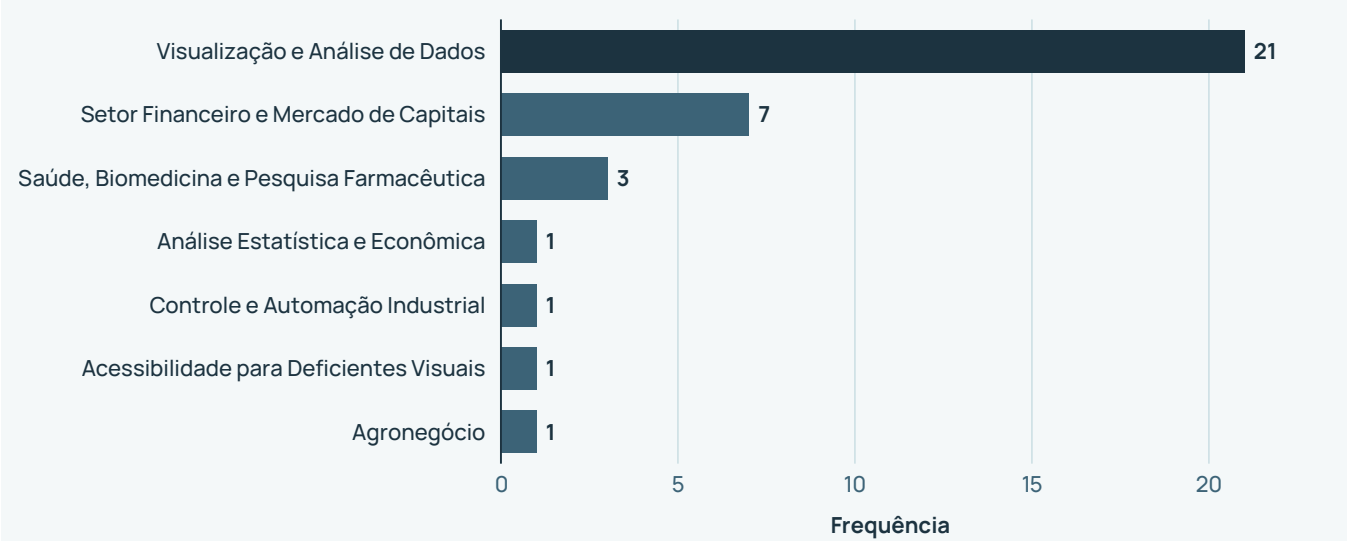

Fonte: Elaborado pelos autores (2026).

Tabela 2. Categoria de Contribuição versus Frequência dos Estudos.

Categoria de Contribuição	Frequência dos Estudos
Técnica/Estratégia	34
Sistema	21
Sistema Multiagente	7
Estudo/Avaliação	22
Modelo	9
Dataset/*Benchmark*	22

Fonte: Elaborado pelos autores (2026).

Em visualização e análise, Lin *et al.* [10] desenvolveram um *plugin* para notebooks computacionais (ambientes interativos, como o Jupyter, que combinam código, texto e resultados) capaz de converter esboços sobre gráficos automaticamente em anotações textuais; Tian *et al.* [11] propuseram um sistema que decompõe solicitações textuais abstratas em etapas de raciocínio estruturadas para sintetizar gráficos. No setor financeiro, Hao *et al.* [12] implementaram a geração automática de sobreposições gráficas que articulam narrativa textual a séries de mercado. Em biomedicina, Lin *et al.* [9] introduziram um agente para Transcriptômica Espacial cuja automação reduz análises de semanas para minutos; Kang *et al.* [13] propuseram um sistema multiagente que converte perguntas em SQL e gera visualizações para gestores hospitalares.

Quanto às categorias de contribuição (Tabela 2), não excludentes, distribuíram-se em Técnica/Estratégia (34), Estudo/Avaliação (22), *Dataset*/*Benchmark* (22), Sistema (21), Modelo (9) e Sistema Multiagente (7). Lo e Qu [14] avaliaram raciocínio passo a passo e Split CoT na detecção de visualizações enganosas. Wang *et al.* [15] avaliaram o Data Formulator 2 com oito participantes em duas tarefas que envolveram 16 visualizações, identificando benefícios para a criação iterativa e também problemas de desempenho e verificação. Em testes iniciais, Kang *et al.* [13] reportaram redução do ciclo pergunta-*insight* de 25–30 minutos para 40–360 segundos. Entre os *benchmarks*, Wu *et al.* [16] disponibilizaram o ChartInsights, com 22.347 amostras em dez tarefas analíticas, e Zhao *et al.* [17], o CT2C-QA para perguntas multimodais em chinês.

3.2 Níveis de aplicação das LLMs no fluxo de visualização

A integração entre LLMs e sistemas de visualização ocorre em três níveis funcionais (Tabela 3): Processamento de Entrada (PE), Suporte à Análise (SA) e Interpretação de Resultados (IR). A taxonomia dialoga com a *pipeline* Data2Vis/Vis2Insight de Lian *et al.* [18], mas foi organizada para destacar competências relevantes a *dashboards* de VE. Em PE, a LLM traduz linguagem natural, imagens ou tabelas em representações estruturadas, como NL2SQL, NL2VIS e componentes gráficos [19,20]. Em SA, atua sobre visualizações existentes: Jiang *et al.* [21] automatizam anotações em séries temporais; Hao *et al.* [12] usam RAG para contextualizar gráficos financeiros; e Lo e Qu [14] avaliam a detecção de visualizações enganosas. Em IR, comunica achados como narrativas: Seo *et al.* [22] desenvolveram o maidrAI para pessoas cegas ou com baixa visão; em experimento com 26 novatos, Choe *et al.* [23] observaram preferência pela assistência de LLM em relação à busca web, mas também menor obtenção de *insights* e menor engajamento direto com a visualização.

3.3 Arquiteturas e limitações reportadas

Quanto às arquiteturas, três arranjos se destacam. Na arquitetura multimodal unificada, diferentes modalidades são alinhadas em *embeddings* (representações numéricas em um espaço vetorial) por meio de um codificador visual (*Vision Encoder*), que extrai características da imagem, um módulo de conexão e a LLM;

Tabela 3. Estudos por nível de aplicação das LLMs no fluxo de visualização de dados.

Nível	Função principal	Estudos representativos
Processamento de Entrada (PE)	Traduz NL/imagens/tabelas em representações estruturadas (NL2VIS, NL2SQL, reconhecimento gráfico).	ChartGPT [11]; ChartVLM [19]; mChartQA [20]; Data Formulator 2 [15]; CT2C-QA [17].
Suporte à Análise (SA)	Apoia o raciocínio sobre visualizações: anotação automática, RAG e detecção de erros.	AutoMA [21]; FinFlier [12]; detecção de gráficos enganosos [14]; STAgent [9].
Interpretação de Resultados (IR)	Gera narrativas, explicações e descrições acessíveis a partir de gráficos.	maidrAI [22]; LLMs como guias de novatos [23]; InkSight [10]; agente hospitalar [13].

Fonte: Elaborado pelos autores (2026).

exemplos incluem LLaVA-1.5, Qwen-VL e MMCA. A arquitetura modular desacoplada separa percepção e raciocínio: Chart-to-Text ou DePlot extraem a estrutura, e a LLM realiza o raciocínio textual [19,20]; o mChartQA combina codificador visual e Chart2Text para preservar elementos perdidos pelo reconhecimento óptico de caracteres (OCR) [20]. A arquitetura multiagente orquestra agentes especializados em texto, tabelas, gráficos e NL2SQL, além de um agente decisor [13,17].

Persistem barreiras de percepção (barras empilhadas, rótulos sobrepostos, linhas cruzadas, cores e posições) e de extração estruturada [20]. Também ocorrem ambiguidade semântica [11], vieses de resposta e alucinações, isto é, informações não sustentadas pelo gráfico. No ChartInsights, a acurácia média de 19 MLLMs em tarefas analíticas de baixo nível foi 39,8%, e o melhor resultado sem estratégia adicional, do GPT-4o, foi 69,17%; os autores observaram respostas numéricas alheias ao gráfico [16]. Para pessoas cegas ou com baixa visão, uma descrição incorreta pode ser especialmente danosa [22]. Assim, resultados gerados por LLMs não devem ser tratados como evidência autônoma: exigem validação humana, indicação de proveniência e mecanismos de auditoria, sobretudo em saúde pública.

4 DISCUSSÃO

A discussão responde à RQ2 considerando que os *dashboards* de VE enfrentam limitações de usabilidade e riscos de comunicação, evidenciados durante a pandemia de COVID-19 [24]. LLMs e MLLMs oferecem recursos de interação contextual, personalização e geração de narrativas que podem apoiar esses problemas; contudo, como nenhum dos estudos incluídos avaliou tais recursos em um cenário real de VE, a transferência discutida a seguir constitui inferência indireta, e não evidência de efetividade.

4.1 Auxílio à usabilidade e às necessidades do usuário

Os *dashboards* de VE precisam atender a públicos com diferentes níveis de literacia em dados [24]. No maidrAI, participantes cegos ou com baixa visão personalizaram conhecimento estatístico, detalhamento e forma das respostas, com preferências distintas conforme experiência e finalidade de uso [22]. Quanto à sobrecarga cognitiva [25], LLMs podem oferecer respostas estruturadas, mas o experimento de Choe *et al.* [23] mostrou que a preferência pela assistência não implicou mais *insights* ou maior interação com o gráfico. O Data Formulator 2 [15] combina linguagem natural e interface gráfica para análise iterativa; o ChartGPT [11] decompõe solicitações em etapas. A automação de anotações em séries temporais [21] e as sobreposições em narrativas financeiras [12] exemplificam a integração entre texto e gráfico.

4.2 Auxílio aos riscos de interpretação e comunicação

As limitações de interpretação em VE incluem representações enganosas, granularidade inadequada e pouca clareza sobre a credibilidade da informação [25]. MLLMs podem auxiliar na identificação de eixos truncados e representações desproporcionais [14], e RAG pode incorporar contexto externo às respostas [12]. Entretanto, vieses, erros de percepção e alucinações [16,20,22] podem produzir explicações convincentes, porém incorretas. Em VE, sua adoção deve incluir fontes rastreáveis, exibição de incerteza, validação por especialistas, registros de auditoria e possibilidade de contestação da resposta. Portanto, há paralelos entre as capacidades observadas e as lacunas dos *dashboards* epidemiológicos, mas o potencial de transferência permanece plausível e ainda não validado empiricamente em cenários reais de VE.

5 CONCLUSÕES

Esta revisão sistemática mostrou que técnicas baseadas em LLMs vêm sendo aplicadas à visualização e interpretação de dados, desde consultas em linguagem natural até análise multimodal. Em resposta à RQ1, os 35 estudos evidenciam capacidades para compreender gráficos, gerar explicações e estruturar dados, mas também limitações de percepção, raciocínio, confiabilidade e avaliação em cenários reais. A heterogeneidade dos estudos e a ausência de avaliação formal de qualidade impedem estimar a magnitude ou a certeza dos benefícios.

Quanto à RQ2, há potencial plausível de transferência para a vigilância epidemiológica, especialmente no apoio à literacia, à exploração e à contextualização de *dashboards*; esse potencial, porém, ainda não foi validado empiricamente em cenários reais de VE. Pesquisas futuras devem avaliar usabilidade, segurança, equidade e desempenho com dados epidemiológicos, incluindo supervisão humana,

rastreabilidade das fontes e monitoramento de vieses e alucinações antes de qualquer uso em decisões de saúde pública.

Contribuição dos autores. Antônio Rodrigues Pinto Junior: concepção da temática, sistematização dos dados e escrita do texto. Anita Maria da Rocha Fernandes: concepção da temática, organização do texto e revisão. Wemerson Delcio Parreira: revisão.

Agradecimentos. Ao Programa de Pós-graduação em Computação (PPGC)/UNIVALI.

Financiamento. Os autores não declararam fonte de financiamento.

Disponibilidade de dados e materiais. Os dados e materiais da pesquisa estão disponíveis no Open Science Framework (OSF), em https://doi.org/10.17605/OSF.IO/DWTV7.

Conflitos de interesse. Os autores não declararam conflitos de interesse.

Declaração de uso de IA. Os autores declaram o uso de ferramentas de Inteligência Artificial generativa no preparo deste manuscrito. Foi utilizada a ferramenta ChatGPT (OpenAI) com a finalidade exclusiva de apoio à redação e revisão textual (clareza, gramática e estilo) e à organização e estruturação do manuscrito. A ferramenta também auxiliou na síntese de informações previamente produzidas pelos autores. Não foi utilizada IA para gerar dados, resultados, tabelas, conclusões ou referências, nem para realizar análise científica primária. Todo o conteúdo, interpretações, decisões metodológicas e conclusões são de inteira responsabilidade dos autores, que revisaram e validaram criticamente todas as saídas geradas pela ferramenta. Nenhuma autoria ou coautoria é atribuída a sistemas de IA.

REFERÊNCIAS

1. Chen M, Hauser H, Rheingans P, Scheuermann G, editors. Foundations of Data Visualization. Cham: Springer International Publishing; 2020. doi: https://doi.org/10.1007/978-3-030-34444-3
2. Kharakhash O. Data visualization: transforming complex data into actionable insights. ATBP. 2023;15(2):4-12. doi: https://doi.org/10.15673/atbp.v15i2.2520
3. Ofori MA, Lartey S, Durneva P, Jha N, Mittal N, Roy S, et al. Visual communication of public health data: a scoping review. Front Digit Health. 2025;7:1555231. doi: https://doi.org/10.3389/fdgth.2025.1555231
4. Iftikhar A, Bond R, McGilligan V, J Leslie S, Rjoob K, Knoery C, et al. Role of dashboards in improving decision making in healthcare: Review of the literature. In: Proceedings of the 31st European Conference on Cognitive Ergonomics. New York, NY, USA: ACM; 2019. p. 215-9. doi: https://doi.org/10.1145/3335082.3335109
5. Preim B, Lawonn K. A Survey of Visual Analytics for Public Health. Computer Graphics Forum. 2020;39(1):543-80. doi: https://doi.org/10.1111/cgf.13891
6. Stahlman G, Yanovitzky I, Kim M. Design, Application, and Actionability of US Public Health Data Dashboards: Scoping Review. J Med Internet Res. 2025;27:e65283. doi: https://doi.org/10.2196/65283
7. Zakkar M, Sedig K. Interactive visualization of public health indicators to support policymaking: An exploratory study. Online J Public Health Inform. 2017;9(2):e190. doi: https://doi.org/10.5210/ojphi.v9i2.8000
8. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. PLoS Med. 2021;18(3):e1003583. doi: https://doi.org/10.1371/journal.pmed.1003583
9. Lin Z, Wang W, Marin-Llobet A, Li Q, Pollock SD, Sui X, et al. Spatial transcriptomics AI agent charts hPSC-pancreas maturation in vivo. bioRxiv [Preprint]. 2025. doi: https://doi.org/10.1101/2025.04.01.646731
10. Lin Y, Li H, Yang L, Wu A, Qu H. InkSight: Leveraging Sketch Interaction for Documenting Chart Findings in Computational Notebooks. IEEE Trans Vis Comput Graph. 2024;30(1):944-54. doi: https://doi.org/10.1109/TVCG.2023.3327170
11. Tian Y, Cui W, Deng D, Yi X, Yang Y, Zhang H, et al. ChartGPT: Leveraging LLMs to Generate Charts From Abstract Natural Language. IEEE Trans Vis Comput Graph. 2025;31(3):1731-45. doi: https://doi.org/10.1109/TVCG.2024.3368621
12. Hao J, Yang M, Shi Q, Jiang Y, Zhang G, Zeng W. FinFlier: Automating Graphical Overlays for Financial Visualizations With Knowledge-Grounding Large Language Model. IEEE Trans Vis Comput Graph. 2025;31(9):6353-69. doi: https://doi.org/10.1109/TVCG.2024.3514138
13. Kang Y, Chen J, Wang G, Yang H, Luo W, Wang Q, et al. AI Agent-Based Operational Data Intelligent Analysis and Practice. In: Proceedings of the 2025 International Conference on Software Engineering and Computer Applications. New York, NY, USA: ACM; 2025. p. 93-8. doi: https://doi.org/10.1145/3747912.3747927
14. Lo LY, Qu H. How Good (Or Bad) Are LLMs at Detecting Misleading Visualizations? IEEE Trans Vis Comput Graph. 2025;31(1):1116-25. doi: https://doi.org/10.1109/TVCG.2024.3456333
15. Wang C, Lee B, Drucker SM, Marshall D, Gao J. Data Formulator 2: Iterative Creation of Data Visualizations, with AI Transforming Data Along the Way. In: Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems. New York, NY, USA: ACM; 2025. p. 1-17. doi: https://doi.org/10.1145/3706598.3713296
16. Wu Y, Yan L, Shen L, Wang Y, Tang N, Luo Y. ChartInsights: Evaluating Multimodal Large Language Models for Low-Level Chart Question Answering. In: Findings of the Association for Computational Linguistics: EMNLP 2024. Stroudsburg, PA, USA: Association for Computational Linguistics; 2024. p. 12174-200. doi: https://doi.org/10.18653/v1/2024.findings-emnlp.710

17. Zhao B, Cheng T, Zhang Y, Cheng Y, Feng R, Zhang X. CT 2 C-QA: Multimodal Question Answering over Chinese Text, Table and Chart. In: Proceedings of the 32nd ACM International Conference on Multimedia. New York, NY, USA: ACM; 2024. p. 3897-906. doi: https://doi.org/10.1145/3664647.3681053

18. Lian Y, Hao J, Zeng W, Luo Q. A survey of visual insight mining: Connecting data and insights via visualization. Visual Informatics. 2025;9(4):100271. doi: https://doi.org/10.1016/j.visinf.2025.100271

19. Xia R, Ye H, Yan X, Liu Q, Zhou H, Chen Z, et al. ChartX and ChartVLM: A Versatile Benchmark and Foundation Model for Complicated Chart Reasoning. IEEE Trans Image Process. 2025;34:7436-47. doi: https://doi.org/10.1109/TIP.2025.3607618

20. Wei J, Xu N, Chang G, Luo Y, Yu B, Guo R. mChartQA and mChartQABench: A multimodal-only solution for complex chart question-answering. Pattern Recognition. 2026;172:112348. doi: https://doi.org/10.1016/j.patcog.2025.112348

21. Jiang Q, Sun G, Li T, Tang J, Xia W, Wang Y, et al. AutoMA: Automated Generation of Multi-level Annotations for Time Series Visualization. In: 2025 IEEE 18th Pacific Visualization Conference (PacificVis). [s.l.]: IEEE; 2025. p. 80-90. doi: https://doi.org/10.1109/pacificvis64226.2025.00014

22. Seo J, Kamath SS, Zeidieh A, Venkatesh S, McCurry S. MAIDR Meets AI: Exploring Multimodal LLM-Based Data Visualization Interpretation by and with Blind and Low-Vision Users. In: The 26th International ACM SIGACCESS Conference on Computers and Accessibility. New York, NY, USA: ACM; 2024. p. 1-31. doi: https://doi.org/10.1145/3663548.3675660

23. Choe K, Lee C, Lee S, Song J, Cho A, Kim NW, et al. Enhancing Data Literacy On-Demand: LLMs as Guides for Novices in Chart Interpretation. IEEE Trans Vis Comput Graph. 2025;31(9):4712-27. doi: https://doi.org/10.1109/TVCG.2024.3413195

24. Arleo A, Borgo R, Kohlhammer J, Ruddle RA, Scharlach H, Yuan X, et al. Reflections on the Use of Dashboards in the COVID-19 Pandemic. IEEE Comput Graph Appl. 2025;45(2):135-42. doi: https://doi.org/10.1109/MCG.2025.3538257

25. Luz S, Masoodian M. Exploring Environmental and Geographical Factors Influencing the Spread of Infectious Diseases with Interactive Maps. Sustainability. 2022;14(16):9990. doi: https://doi.org/10.3390/su14169990

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