PONTIFÍCIA UNIVERSIDADE CATÓLICA DE CAMPINAS

BRUNA ROJO BEZERRA PADOVAN

USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO DE CASOS DE DENGUE NA CIDADE DE CAMPINAS – EPIDEMIA DE 2024

CAMPINAS
2026

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE CAMPINAS
ESCOLA DE CIÊNCIAS DA VIDA
PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU* EM CIÊNCIAS DA SAÚDE
BRUNA ROJO BEZERRA PADOVAN

USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO DE CASOS DE DENGUE NA CIDADE DE CAMPINAS – EPIDEMIA DE 2024

Dissertação apresentada ao Programa de Pós-Graduação Stricto Sensu em Ciências da Saúde da Escola de Ciências da Vida da Pontifícia Universidade Católica de Campinas, como exigência parcial para obtenção do título de Mestre em Ciências da Saúde.

Orientadora: Profa. Dra. Elisa Donalisio Teixeira Mendes
Coorientador: Prof. Dr. Saullo Haniell Galvão de Oliveira

CAMPINAS
2026

Padovan, Bruna Rojo Bezerra

P124u

USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO DE CASOS DE DENGUE NA CIDADE DE CAMPINAS – EPIDEMIA DE 2024 / Bruna Rojo Bezerra Padovan. - Campinas: PUC-Campinas, 2026.

40 f.

Orientador: Elisa Donalisio Teixeira Mendes. Coorientador: Saullo Haniell Galvão Oliveira

Dissertação (Mestrado em Mestrado em Ciências da Saúde) - Pontifícia Universidade Católica de Campinas, Programa de Pós-Graduação em Ciências da Saúde, Escola de Ciências da Vida, Pontifícia Universidade Católica de Campinas, Campinas, 2026.

Inclui bibliografia.

1. Dengue. 2. Inteligência Artificial. 3. Vigilância Epidemiológica. I. Mendes, Elisa Donalisio Teixeira. II. Oliveira, Saullo Haniell Galvão. III. Pontifícia Universidade Católica de Campinas. Escola de Ciências da Vida. Pontifícia Universidade Católica de Campinas, Programa de Pós-Graduação em Ciências da Saúde. IV. Título.

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE CAMPINAS
ESCOLA DE CIÊNCIAS DA VIDA
PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU* EM CIÊNCIAS DA SAÚDE
BRUNA ROJO BEZERRA PADOVAN

USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO DE CASOS DE DENGUE NA CIDADE DE CAMPINAS – EPIDEMIA DE 2024

Dissertação defendida e aprovada em 31 de agosto de 2026, pela Comissão Julgadora constituída pelos seguintes professores:

Profa. Dra. Elisa Donalisio Teixeira Mendes
Orientadora e Presidente da Comissão Julgadora
Pontifícia Universidade Católica de Campinas

Profa. Dra. Glória Maria de Almeida Souza Tedrus
Pontifícia Universidade Católica de Campinas

Prof. Dr. Rodrigo Nogueira Angerami
Universidade Estadual de Campinas

CAMPINAS
2026

AGRADECIMENTOS

Primeiramente, agradeço a Deus, que conhece os sonhos mais profundos do meu coração e, no tempo certo, permitiu que este sonho se realizasse. O mestrado sempre esteve entre os meus maiores objetivos, e tenho a certeza de que foi Ele quem sustentou cada passo dessa caminhada.

À minha orientadora, Professora Dra. Elisa, expresso minha profunda gratidão pela dedicação, paciência, disponibilidade e pelos valiosos ensinamentos compartilhados ao longo desta trajetória. Ao meu coorientador, Professor Dr. Saullo, agradeço pela generosidade em transmitir seus conhecimentos, pela paciência em me conduzir no universo da Inteligência Artificial e pelas contribuições fundamentais para a realização deste trabalho.

À Pontifícia Universidade Católica de Campinas, agradeço por ter me acolhido e proporcionado a oportunidade de realizar este sonho em um momento tão importante da minha vida.

Ao meu marido, meu maior incentivador, obrigada por acreditar em mim, por compartilhar os desafios, oferecer apoio incondicional e me lembrar, nos momentos de dificuldade, do quanto eu amo aprender, pesquisar e crescer. Esta conquista também é sua.

Aos meus filhos, razão do meu viver, agradeço por tornarem esta caminhada ainda mais significativa. Iniciei esta jornada com um filho e a concluo com dois, aprendendo diariamente que é possível conciliar a maternidade com a realização dos próprios sonhos. Que esta conquista seja também um exemplo de perseverança para vocês.

Aos meus pais, Rubens e Vera, e à minha irmã, Júlia, minha eterna gratidão pelo amor, apoio e dedicação. Obrigada por todo o cuidado com minha família, pelos inúmeros gestos de carinho e por tornarem possível minha dedicação aos estudos. Sem vocês, esta conquista não teria sido possível.

Esta dissertação representa muito mais do que a conclusão de um curso. Ela simboliza a realização de um sonho cultivado por muitos anos e reúne aprendizados, desafios, renúncias, crescimento pessoal e profissional, maternidade, amor, apoio e fé. A todos que caminharam ao meu lado e contribuíram, direta ou indiretamente,

para esta conquista, deixo o meu mais sincero agradecimento. Esta vitória é compartilhada com cada um de vocês.

RESUMO

Introdução: A dengue representa um dos principais desafios para a saúde pública em países tropicais, especialmente em cenários epidêmicos caracterizados por elevada demanda assistencial e necessidade de resposta rápida dos sistemas de vigilância epidemiológica. Durante a epidemia de 2024, o Brasil registrou uma epidemia de dengue de magnitude histórica, evidenciando limitações operacionais relacionadas à identificação e notificação oportuna dos casos suspeitos. Nesse contexto, ferramentas baseadas em Inteligência Artificial (IA) apresentam potencial para automatizar a análise de registros clínicos e apoiar as atividades de vigilância epidemiológica. **Objetivo:** Avaliar o desempenho de um modelo de IA baseado em Processamento de Linguagem Natural (PLN) para a identificação automatizada de casos suspeitos de dengue a partir de registros clínicos em texto livre, comparando seu desempenho com a classificação manual (padrão-ouro) e com os registros oficiais da vigilância epidemiológica. **Método:** Trata-se de um estudo observacional retrospectivo realizado a partir dos atendimentos registrados no Pronto-Socorro Adulto e Infantil do Hospital da PUC-Campinas durante a 15ª Semana Epidemiológica de 2024, correspondente ao período de maior incidência da doença no município de Campinas. Inicialmente, todos os registros clínicos foram revisados manualmente por duas profissionais da saúde capacitadas, utilizando os critérios clínico-epidemiológicos estabelecidos pelo *Guia de Vigilância em Saúde* do Ministério da Saúde para definição de caso suspeito de dengue (febre associada a duas ou mais manifestações clínicas compatíveis). Essa classificação constituiu o padrão-ouro do estudo. Posteriormente, os mesmos registros foram submetidos à análise por um modelo de linguagem pré-treinado ModernBERT, ajustado por meio da técnica de *fine-tuning* supervisionado para classificação automatizada dos atendimentos quanto à presença ou ausência de critérios compatíveis com suspeita de dengue. O desempenho do modelo foi inicialmente avaliado por validação cruzada em cinco *folds* e, posteriormente, por meio de métricas de classificação calculadas no conjunto de teste, sendo os resultados comparados aos registros oficiais da Vigilância Epidemiológica. **Resultados**: Foram analisados 2.697 atendimentos. A revisão manual identificou 505 casos suspeitos de dengue (18,7% da amostra), enquanto os sistemas oficiais de vigilância registraram 337 casos no mesmo período. A diferença de 168 casos correspondeu a uma subnotificação de 33,3% em relação ao padrão-ouro. Durante a validação cruzada, o modelo apresentou F1-score médio de 0,890 (DP = 0,004), indicando desempenho consistente entre os diferentes subconjuntos de treinamento. Na avaliação do conjunto de teste, obteve acurácia de 84,9%, F1-score ponderado (*weighted F1*) de 0,831, sensibilidade de 37,3%, especificidade de 96,1%, valor preditivo positivo de 68,5% e valor preditivo negativo de 86,9%. Os resultados demonstram elevada capacidade do modelo para identificar corretamente registros sem critérios compatíveis com suspeita de dengue, além de evidenciar seu potencial como ferramenta de apoio à vigilância epidemiológica por meio da análise automatizada de prontuários eletrônicos. A identificação de um número substancialmente superior de casos suspeitos em comparação aos registros oficiais reforça a existência de subnotificação durante o período analisado. **Conclusão:** O modelo apresentou elevada especificidade e desempenho global consistente, evidenciando seu potencial de utilização como ferramenta complementar de triagem para a identificação automatizada de casos suspeitos de dengue. Esse desempenho é compatível com uma aplicação voltada à priorização inicial dos atendimentos,

podendo contribuir futuramente para estratégias destinadas à identificação oportuna de casos suspeitos e ao aprimoramento dos processos de vigilância epidemiológica.

Palavras-chave: Dengue; Inteligência Artificial; Vigilância Epidemiológica; Processamento de Linguagem Natural; Saúde Digital.

ABSTRACT

Introduction: Dengue is one of the major public health challenges in tropical countries, particularly during epidemic scenarios characterized by high healthcare demand and the need for rapid responses from epidemiological surveillance systems. During the 2024 epidemic, Brazil experienced a dengue outbreak of unprecedented magnitude, highlighting operational limitations in the timely identification and notification of suspected cases. In this context, Artificial Intelligence (AI)-based tools have the potential to automate the analysis of clinical records and support epidemiological surveillance activities. **Objective:** To evaluate the performance of an Artificial Intelligence model based on Natural Language Processing (NLP) for the automated identification of suspected dengue cases from free-text clinical records, comparing its performance with manual classification (gold standard) and official epidemiological surveillance records. **Methods:** This retrospective observational study was conducted using records from patients treated at the Adult and Pediatric Emergency Department of the PUC-Campinas Hospital during the 15th Epidemiological Week of 2024, corresponding to the period of highest dengue incidence in Campinas, Brazil. Initially, all clinical records were manually reviewed by two trained healthcare professionals according to the clinical and epidemiological criteria established by the Brazilian Ministry of Health Surveillance Guide for defining suspected dengue cases (fever associated with two or more compatible clinical manifestations). This classification was adopted as the study gold standard. Subsequently, the same records were analyzed using the pre-trained ModernBERT language model, fine-tuned through supervised learning for automated classification of clinical records according to the presence or absence of criteria compatible with suspected dengue. Model performance was initially assessed using five-fold cross-validation and subsequently evaluated on the test set using classification metrics, with the results compared against official epidemiological surveillance records. **Results:** A total of 2,697 patient visits were analyzed. Manual review identified 505 suspected dengue cases (18.7% of the sample), whereas the official surveillance system recorded 337 cases during the same period. The difference of 168 cases corresponded to an underreporting rate of 33.3% compared with the gold standard. During cross-validation, the model achieved a mean F1-score of 0.890 (SD = 0.004), indicating consistent performance across the training subsets. On the test set, the model achieved an accuracy of 84.9%, weighted F1-score of 0.831, sensitivity of 37.3%, specificity of 96.1%, positive predictive value of 68.5%, and negative predictive value of 86.9%. These findings demonstrate the model's high ability to correctly identify records without clinical criteria compatible with suspected dengue and highlight its potential as a complementary tool for epidemiological surveillance through the automated analysis of electronic health records. The substantially higher number of suspected cases identified compared with official surveillance records further reinforces the occurrence of underreporting during the study period. **Conclusion:** The model showed high specificity and consistent overall performance, indicating its potential use as a complementary screening tool for the automated identification of suspected dengue cases. This performance is compatible with an application focused on the initial prioritization of clinical visits, and may contribute in the future to strategies aimed at the timely identification of suspected cases and the improvement of epidemiological surveillance processes.

Keywords: Dengue; Artificial Intelligence; Epidemiological Surveillance; Natural Language Processing; Digital Health.

SUMÁRIO

INTRODUÇÃO.....11

1.1 Vigilância Epidemiológica.....12

1.2 Inteligência Artificial e a Medicina.....13

2 JUSTIFICATIVA.....16

3 OBJETIVOS.....17

3.1 Objetivo Geral.....17

3.2 Objetivos Específicos.....17

4 METODOLOGIA 17

4.1 Tipo e Desenho do Estudo.....17

4.2 Estratégias de Comparação 20

4.3 Local do Estudo.....21

4.4 Comitê de Ética.....21

4.5 Base de Dados.....21

4.6 Especialização do Modelo e Análise de Desempenho 22

5 RESULTADOS 23

5.1 Desempenho por classe 25

6 DISCUSSÃO.....27

7 CONCLUSÃO 33

8 REFERÊNCIAS 35

INTRODUÇÃO

A dengue constitui um dos principais desafios para a saúde pública mundial, especialmente em países tropicais e subtropicais, onde condições climáticas, ambientais e socioeconômicas favorecem a proliferação do *Aedes aegypti*, principal vetor da doença. Estima-se que aproximadamente um terço da população mundial esteja exposta ao risco de infecção pelo vírus da dengue, tornando essa arbovirose uma importante causa de morbidade e mortalidade, com impacto significativo sobre os sistemas de saúde (WORLD HEALTH ORGANIZATION, 2024).

A infecção apresenta amplo espectro clínico, variando desde formas assintomáticas ou oligossintomáticas até manifestações sintomáticas de diferentes níveis de gravidade. Após a infecção, o vírus desencadeia uma resposta inflamatória e imunológica, cuja intensidade influencia a evolução clínica da doença (KULARATNE; DALUGAMA, 2022). As manifestações clínicas mais frequentes incluem febre de início súbito, cefaleia, dor retro-orbitária, mialgia, artralgia, náuseas, vômitos e exantema. A apresentação clínica pode variar conforme fatores relacionados ao vírus e ao hospedeiro, como idade, sorotipo viral, presença de comorbidades e resposta imunológica (KULARATNE; DALUGAMA, 2022).

A persistência da dengue está diretamente relacionada às transformações ambientais e sociais observadas nas últimas décadas. O crescimento urbano desordenado, a ocupação irregular dos espaços urbanos, a deficiência dos serviços de saneamento básico, o manejo inadequado de resíduos sólidos e o armazenamento incorreto de água favorecem a formação de criadouros do *Aedes aegypti*. Somam-se a esses fatores as mudanças climáticas, caracterizadas pelo aumento da temperatura e pelas alterações nos padrões de precipitação, que ampliam a área de dispersão do vetor e prolongam os períodos de transmissão da doença. Nesse contexto, o enfrentamento da dengue exige não apenas ações de controle vetorial, mas também políticas públicas integradas voltadas à melhoria das condições ambientais, urbanísticas e sanitárias da população (MEDEIROS, 2024; WORLD HEALTH ORGANIZATION, 2024).

Nas últimas décadas, a dengue tem apresentado crescimento expressivo em diversos países, culminando, no Brasil, na epidemia histórica registrada em 2024. O

aumento abrupto do número de casos impõe importantes desafios aos serviços de saúde, caracterizados pela superlotação das unidades de pronto atendimento e hospitais, aumento das internações, escassez de leitos e insumos, além da sobrecarga das equipes assistenciais. Esse cenário compromete não apenas a qualidade da assistência prestada aos pacientes, mas também a capacidade dos serviços de identificar, registrar e notificar oportunamente os casos suspeitos, impactando diretamente as ações de vigilância epidemiológica e o planejamento das medidas de controle da doença (KHAN et al., 2023; BRASIL, 2024).

1.1 Vigilância Epidemiológica

A Vigilância Epidemiológica constitui uma das principais estratégias de saúde pública para o monitoramento, prevenção e controle de doenças transmissíveis. Segundo o Ministério da Saúde, trata-se de "*um processo contínuo e sistemático de coleta, análise, interpretação e disseminação de informações relacionadas a eventos de interesse para a saúde, com a finalidade de subsidiar o planejamento, a implementação e a avaliação de medidas voltadas à prevenção e ao controle de riscos, agravos e doenças, bem como à promoção da saúde*" (BRASIL, 2013).

No contexto da dengue, a vigilância epidemiológica desempenha papel fundamental na identificação precoce de surtos e epidemias, permitindo o acompanhamento da evolução da transmissão, a definição de estratégias de controle vetorial, o direcionamento de recursos assistenciais e o planejamento de ações para redução da morbimortalidade. A efetividade dessas medidas depende diretamente da identificação e da notificação dos casos suspeitos, uma vez que as informações registradas pelos serviços de saúde subsidiam a tomada de decisão pelos gestores em todos os níveis do Sistema Único de Saúde (SUS) (ANGELO et al., 2020).

A magnitude da epidemia brasileira de 2024 evidenciou a importância desses sistemas de vigilância. Entre as semanas epidemiológicas 1 e 26 daquele ano, foram registrados 6.455.782 casos prováveis de dengue e 4.269 óbitos confirmados, configurando a maior epidemia da doença já documentada no país. Esse cenário reforça a relevância da dengue como importante problema de saúde pública, especialmente em contextos de elevada circulação viral e sobrecarga dos serviços de saúde (BRASIL, 2024).

No Brasil, a dengue é uma doença de notificação compulsória, devendo todos os casos suspeitos ou confirmados ser comunicados aos serviços de Vigilância Epidemiológica conforme os critérios estabelecidos pelo Ministério da Saúde (BRASIL, 2016). De acordo com o **Guia de Vigilância em Saúde** (BRASIL, 2024), considera-se **caso suspeito de dengue** o indivíduo residente ou procedente de área com transmissão da doença que apresente febre com duração entre dois e sete dias, associada a pelo menos duas manifestações clínicas, como náuseas, vômitos, exantema, mialgia, artralgia, cefaleia, dor retro-orbitária, petéquias ou leucopenia. Os casos podem ser confirmados por critérios clínico-epidemiológicos, quando existe vínculo epidemiológico com caso confirmado, ou por critérios laboratoriais, mediante exames específicos, como detecção do antígeno NS1, RT-PCR, isolamento viral ou sorologia.

Entretanto, durante períodos epidêmicos, a elevada demanda assistencial pode comprometer a qualidade dos registros clínicos e a oportunidade das notificações, favorecendo a ocorrência de subnotificação e de inconsistências nas informações registradas. Estudos nacionais demonstram que a vigilância da dengue ainda enfrenta desafios relacionados à completude das notificações e à identificação adequada dos casos suspeitos, fatores que podem comprometer o monitoramento epidemiológico e a implementação de medidas de controle (SILVA et al., 2016; MARQUES; SIQUEIRA; PORTUGAL, 2020; ANGELO et al., 2020).

Nesse contexto, a incorporação de tecnologias capazes de analisar automaticamente registros clínicos em texto livre surge como uma alternativa promissora para apoiar a vigilância epidemiológica. Ferramentas baseadas em inteligência artificial (IA) podem contribuir para a identificação precoce de casos suspeitos, auxiliar na redução da subnotificação e fornecer informações complementares para o monitoramento da dengue, especialmente em cenários de elevada demanda assistencial.

1.2 Inteligência Artificial e a Medicina

A IA tem promovido avanços relevantes na área da saúde, especialmente pela capacidade de analisar grandes volumes de dados clínicos e identificar padrões complexos que podem auxiliar profissionais na tomada de decisão. Por meio de algoritmos treinados e validados em diferentes contextos, sistemas baseados em IA

têm sido empregados em atividades como apoio diagnóstico, triagem de pacientes, interpretação automatizada de exames e predição de riscos clínicos. Entretanto, apesar do potencial dessas tecnologias, sua implementação na prática assistencial requer avaliação criteriosa quanto à qualidade dos dados utilizados, presença de vieses, validação externa dos modelos e integração adequada aos processos de trabalho em saúde (HAUG; DRAZEN, 2023).

Sob a perspectiva da saúde global, a IA e o *Machine Learning* (ML) vêm sendo cada vez mais utilizados no âmbito da vigilância epidemiológica de doenças transmissíveis. Essa aplicação envolve a coleta, análise e interpretação de dados para detecção de surtos, monitoramento de doenças, identificação de fatores de risco, avaliação de intervenções de saúde pública e definição de populações mais vulneráveis.

Um estudo desenvolvido em 2024 aplicou modelos de aprendizado de máquina para prever a ocorrência de doenças infecciosas em municípios brasileiros com antecedência de uma semana, integrando dados epidemiológicos, informações geográficas e características socioeconômicas de municípios relacionados. A incorporação dessas informações contribuiu para melhorar o desempenho preditivo dos modelos para algumas doenças, como COVID-19 e Zika, evidenciando o potencial da integração de dados territoriais em estratégias de previsão epidemiológica (LOBER; ROSTER; RODRIGUES, 2024).

Outro estudo aplicou técnicas de ML e *Deep Learning* (DL) para prever internações causadas por dengue em diferentes cidades da Paraíba. Utilizando dados epidemiológicos, climáticos e sanitários, o sistema obteve taxas de erro variando de 0,42 a 9,55 (métrica *Root Mean Squared Error* – RMSE), a depender da localidade, evidenciando a eficácia dessas técnicas na previsão de demandas hospitalares (BATISTA et al., 2023).

Em Taiwan, um estudo comparou modelos de aprendizado de máquina com modelos convencionais de classificação para a identificação de casos confirmados de dengue. O desempenho dos modelos foi avaliado por métricas como sensibilidade, especificidade, valor preditivo positivo e acurácia. Os autores demonstraram que abordagens baseadas em aprendizado de máquina apresentaram desempenho promissor na identificação de casos confirmados,

indicando seu potencial como ferramenta complementar para apoio à vigilância e ao diagnóstico da dengue (HO et al., 2020).

Ainda em Taiwan, outra pesquisa desenvolveu um modelo de IA para predição da gravidade da dengue, demonstrando que a capacidade discriminativa da rede neural artificial apresentou bom desempenho no prognóstico de casos graves, auxiliando os médicos em situações de surto (HUANG et al., 2020).

Sob a perspectiva de *One Health* ou “Saúde Única”, estudo publicado em 2022 avaliou o uso de IA e ML na identificação de fatores de risco para dengue na América Latina. Os resultados mostraram que, em 13 dos 32 estados mexicanos analisados, os modelos de ML apresentaram desempenho superior. Contudo, em outros estados, os modelos obtiveram resultados menos satisfatórios, destacando a variação de eficácia conforme a região. Em alguns cenários, o modelo *Random Forest* (RF) obteve melhor desempenho, enquanto em outros, redes neurais do tipo *Long Short-Term Memory* (LSTM) se mostraram mais eficazes. Tal variação reforça a necessidade de comparações em larga escala para determinar preditores mais robustos no contexto global (CABRERA et al., 2022).

No campo do diagnóstico clínico das arboviroses, um estudo publicado em 2022 investigou o uso de modelos de DL para classificação automática dessas doenças, utilizando dados clínicos, demográficos, laboratoriais e epidemiológicos. Os resultados indicaram que a abordagem foi eficaz, embora ainda em estágio inicial de desenvolvimento, não atingindo níveis elevados de precisão (LIMA et al., 2022).

Um estudo publicado em 2023 utilizou técnicas de PLN para analisar autorizações prévias de procedimentos médicos e identificar pacientes suspeitos de infecção por COVID-19. A abordagem baseada em modelagem de tópicos possibilitou a identificação automatizada de padrões em dados não estruturados, demonstrando o potencial do PLN para apoiar estratégias de vigilância e identificação de eventos de interesse em saúde (DA SILVA; POLLETTINI; PAZIN FILHO, 2023).

Modelos baseados na arquitetura *Transformer*, como o **Bidirectional Encoder Representations from Transformers (BERT)**, desenvolvido por Devlin et al. (2019), representaram um avanço significativo no PLN, permitindo melhor compreensão contextual dos textos. Esses modelos podem ser adaptados para

tarefas específicas por meio do processo de *fine-tuning*, no qual um modelo previamente treinado é ajustado para um conjunto de dados específico. Na área da saúde, essa estratégia tem possibilitado aplicações voltadas à classificação de registros clínicos, extração de informações e identificação automatizada de condições de interesse clínico e epidemiológico (ALSENTZER et al., 2019; LEE et al., 2020).

2 JUSTIFICATIVA

Apesar dos avanços nos sistemas de vigilância epidemiológica e da disponibilidade de informações provenientes dos serviços de saúde, a identificação de casos suspeitos de dengue ainda representa um desafio, especialmente durante períodos epidêmicos, quando o aumento da demanda assistencial pode comprometer a qualidade dos registros e a oportunidade das notificações. Além disso, grande parte das informações clínicas produzidas durante o atendimento permanece registrada em formato de texto livre, contendo dados relevantes para a caracterização dos casos, mas cuja análise sistemática em larga escala é limitada pela necessidade de avaliação manual.

Nesse cenário, técnicas de IA PLN apresentam uma oportunidade para explorar informações clínicas não estruturadas e auxiliar processos de identificação automatizada de condições de interesse em saúde. Embora modelos baseados na arquitetura Transformer tenham demonstrado desempenho relevante em tarefas de análise textual no domínio biomédico e clínico (ALSENTZER et al., 2019; LEE et al., 2020), ainda são necessários estudos que avaliem sua aplicabilidade em cenários reais de vigilância epidemiológica, particularmente para identificação de casos suspeitos de dengue a partir de registros clínicos em texto livre.

Dessa forma, este estudo justifica-se pela necessidade de avaliar o desempenho de um modelo de IA aplicado à classificação automatizada de registros clínicos quanto à suspeita de dengue, comparando seus resultados com a avaliação realizada por profissionais de saúde e com os registros oficiais da vigilância epidemiológica. A investigação dessa abordagem pode contribuir para compreender o potencial e as limitações dessas ferramentas como estratégia complementar aos processos tradicionais de vigilância.

3 OBJETIVOS

3.1 Objetivo Geral

Avaliar o desempenho de um modelo de IA na identificação automatizada de casos suspeitos de dengue a partir de registros clínicos em texto livre.

3.2 Objetivos Específicos

- Avaliar o desempenho do modelo de IA na classificação automatizada dos registros clínicos quanto à presença de suspeita de dengue em comparação com o padrão ouro (revisão manual);
- Comparar os casos identificados pelo modelo com os registros oficiais da Vigilância Epidemiológica;
- Analisar o potencial de aplicação da IA como ferramenta de apoio à vigilância epidemiológica da dengue.

4 METODOLOGIA

4.1 Tipo e Desenho do Estudo

Trata-se de um estudo observacional retrospectivo desenvolvido a partir dos registros clínicos de pacientes atendidos no Pronto-Socorro Adulto e Infantil do Hospital da PUC-Campinas durante a 15ª Semana Epidemiológica de 2024, compreendida entre os dias 7 e 13 de abril, período correspondente ao pico epidêmico da dengue no município de Campinas.

A unidade de análise foi constituída pelos registros clínicos produzidos durante o primeiro atendimento dos pacientes no serviço de emergência. Foram considerados os campos de texto livre registrados por médicos e profissionais de enfermagem, incluindo anamnese, descrição dos sintomas, avaliação clínica inicial e demais informações documentadas durante o acolhimento.

A escolha dos registros em texto livre fundamentou-se na relevância dessas informações para a prática clínica e para a vigilância epidemiológica. Diferentemente dos campos estruturados, textos livres frequentemente contêm detalhes clínicos relevantes, como sinais, sintomas, hipóteses diagnósticas e contexto clínico,

essenciais para a identificação de casos suspeitos de dengue. Entretanto, a utilização de registros clínicos não estruturados apresenta desafios para análise automatizada, incluindo abreviações, variações linguísticas, erros ortográficos e expressões de negação clínica, como “nega febre” ou “sem dor”. Essas características são amplamente reconhecidas como desafios para aplicações de PLN em saúde (RAJPURKAR et al., 2022).

É importante destacar que a identificação dos casos suspeitos, tanto na revisão manual quanto na classificação automatizada pelo modelo, não se fundamentou em buscas por palavras-chave, expressões pré-definidas ou dicionários de termos associados a sintomas (abordagens *rule-based*). O modelo ModernBERT processa a sequência textual completa dos campos de texto livre, Queixa Principal e História Clínica , captando o contexto semântico e sintático em que os termos surgem por meio dos mecanismos de autoatenção (*self-attention*) característicos da arquitetura *Transformer* (VASWANI et al., 2017; DEVLIN et al., 2019). Essa característica distingue a abordagem adotada de estratégias tradicionais de vigilância baseadas em vocabulários controlados ou buscas textuais simples, permitindo a interpretação de variações linguísticas, sinônimos, negações e diferentes formas de descrição clínica presentes nos registros, para além do simples reconhecimento de termos isolados (LIU et al., 2026).

Como referência para avaliação do sistema automatizado, foi estabelecido um padrão-ouro baseado na revisão manual dos registros clínicos. Inicialmente, os atendimentos foram extraídos e analisados por uma profissional da saúde, enfermeira, responsável pela identificação dos casos suspeitos de dengue a partir das informações registradas nos campos de texto livre dos prontuários. Posteriormente, a classificação realizada foi submetida à revisão por uma segunda profissional da saúde, médica infectologista, que avaliou os registros clínicos e os critérios utilizados para definição dos casos suspeitos.

A identificação dos casos foi baseada nos critérios clínico-epidemiológicos estabelecidos pelo Ministério da Saúde para definição de caso suspeito de dengue, considerando indivíduos residentes ou procedentes de áreas com transmissão da doença ou presença do vetor *Aedes aegypti*, que apresentassem febre com duração entre dois e sete dias associada a duas ou mais manifestações clínicas, como náuseas, vômitos, exantema, mialgia, artralgia, cefaleia, dor retro-orbitária,

petéquias ou leucopenia (BRASIL, 2024). Após a revisão dos registros pela segunda avaliadora, a classificação final dos casos foi definida e utilizada como padrão-ouro para comparação com os resultados obtidos pelo modelo de IA.

Cabe destacar que o documento *Dengue: diagnóstico e manejo clínico: adulto e criança* do Ministério da Saúde prevê, além do critério geral descrito acima, uma definição específica para a população pediátrica: crianças residentes ou procedentes de área com transmissão de dengue podem ser classificadas como caso suspeito diante de quadro febril agudo, com duração entre dois e sete dias e sem foco de infecção aparente, não sendo exigida a presença de manifestações clínicas adicionais, como ocorre no critério aplicado à população adulta (BRASIL, 2024). Em razão da anonimização dos registros clínicos disponibilizados para este estudo, exigência ética para a realização da pesquisa, não foi possível identificar de forma sistemática, para a totalidade da amostra, quais atendimentos correspondiam a pacientes pediátricos. Embora a faixa etária pudesse ser inferida, em parte dos registros, a partir da descrição da anamnese realizada durante a triagem, essa identificação não estava disponível para todos os casos, o que inviabilizou a aplicação segregada dos dois critérios. Por esse motivo, optou-se pela aplicação do critério geral de caso suspeito, válido tanto para crianças quanto para adultos, ainda que mais conservador para a população pediátrica de maneira uniforme a todos os atendimentos analisados, incluindo aqueles do Pronto-Socorro Infantil.

Cada atendimento recebeu a classificação “APLICA” (caso suspeito de dengue) ou “NÃO SE APLICA”, constituindo o padrão-ouro do estudo. Posteriormente, os registros foram utilizados para realizar o “ajuste fino” (*fine-tuning)* do ModernBERT (WARNER et al., 2024), um modelo de linguagem pré-treinado baseado na arquitetura Transformer. Modelos Transformer utilizam mecanismos de autoatenção (*self-attention*), que permitem capturar relações contextuais entre os elementos de uma sequência textual, favorecendo a representação contextual da linguagem (VASWANI et al., 2017). Essas características têm contribuído para o bom desempenho de modelos de linguagem em diferentes tarefas de processamento de linguagem natural, incluindo aplicações no domínio biomédico e clínico (LEE et al., 2020; ALSENTZER et al., 2019).

O ModernBERT é uma evolução dos modelos BERT tradicionais, incorporando otimizações arquiteturais que aprimoram a eficiência computacional, o

desempenho em tarefas de classificação e a capacidade de processamento de sequências textuais mais longas (WARNER et al., 2024). Assim como outros modelos de linguagem pré-treinados baseados na arquitetura Transformer, o ModernBERT é inicialmente treinado em grandes volumes de dados textuais e, posteriormente, pode ser adaptado a tarefas específicas por meio de ajuste fino (*fine-tuning*) supervisionado, processo no qual seus parâmetros são ajustados utilizando dados rotulados para uma tarefa de interesse, como a classificação binária de textos clínicos (DEVLIN et al., 2019). Para o ajuste fino do modelo, foram utilizados exclusivamente os campos textuais dos prontuários eletrônicos correspondentes à Queixa Principal e a História Clínica.

4.2 Estratégias de Comparação

Foram comparadas três fontes de informação referentes aos atendimentos por suspeita de dengue: a revisão manual dos prontuários clínicos, definida como padrão-ouro; os registros oficiais do sistema de vigilância epidemiológica; e a classificação automatizada realizada pelo modelo especializado para este estudo.

O padrão-ouro foi utilizado como referência principal para identificação dos casos suspeitos, por representar a aplicação direta e padronizada dos critérios do Ministério da Saúde a partir da análise completa dos registros clínicos.

Os registros da vigilância epidemiológica foram utilizados para representar o fluxo oficial de notificação, permitindo avaliar possíveis perdas de informação entre a assistência clínica e a notificação formal dos casos.

Já o modelo especializado foi avaliado como uma ferramenta automatizada de leitura e classificação dos mesmos registros clínicos, com o objetivo de verificar sua capacidade de reproduzir a identificação de casos suspeitos em comparação ao padrão-ouro.

Dessa forma, a análise permitiu tanto a avaliação do desempenho do modelo de IA quanto a identificação de discrepâncias entre a detecção clínica, a notificação oficial e a classificação automatizada, sendo a subnotificação um desfecho decorrente dessas divergências.

4.3 Local do Estudo

O estudo foi realizado no Hospital da PUC-Campinas, hospital geral de alta complexidade localizado no município de Campinas, estado de São Paulo. A instituição possui 339 leitos ativos, dos quais 204 são destinados ao atendimento de pacientes do Sistema Único de Saúde (SUS), com capacidade instalada para até 400 leitos.

O hospital atua como referência regional para atendimentos de média e alta complexidade, atendendo predominantemente a população da região Oeste de Campinas e municípios adjacentes. Com mais de quatro décadas de funcionamento, desempenha papel relevante na assistência, ensino e pesquisa em saúde.

A instituição realiza, em média, aproximadamente 20 mil consultas mensais, 11 mil atendimentos em serviços de urgência e emergência e mais de mil internações por mês. Durante períodos epidêmicos, como o observado em 2024 para dengue, o elevado volume assistencial torna o hospital um cenário estratégico para avaliação de ferramentas baseadas em IA aplicadas à vigilância epidemiológica.

4.4 Comitê de Ética

O projeto foi submetido e aprovado pelo **Comitê de Ética em Pesquisa da Pontifícia Universidade Católica de Campinas**, sob o parecer nº 7.034.336, emitido em 2024.

4.5 Base de Dados

A base de dados utilizada neste estudo foi disponibilizada pela equipe de Tecnologia da Informação (TI) do Hospital da PUC-Campinas. Os registros clínicos foram extraídos do sistema MV Hospitalar, plataforma de gestão integrada utilizada pela instituição para o armazenamento e gerenciamento das informações assistenciais.

Os dados correspondem aos atendimentos realizados no Pronto-Socorro Adulto e Infantil do Hospital da PUC-Campinas durante a 15ª Semana Epidemiológica de 2024, compreendida entre os dias 7 e 13 de abril, período correspondente ao pico epidêmico da dengue no município de Campinas.

Foram incluídos todos os atendimentos realizados no Pronto-Socorro Adulto e Infantil durante o período do estudo, sem aplicação de critérios de exclusão, totalizando 2.697 registros clínicos. A unidade de análise correspondeu ao primeiro atendimento de cada paciente no serviço de emergência. Para o desenvolvimento e a avaliação do modelo de IA, foram utilizados os campos de texto livre registrados pelos profissionais de saúde durante o atendimento, incluindo a Queixa Principal e História Clínica.

Os dados foram previamente anonimizados antes de sua disponibilização aos pesquisadores, de modo que nenhuma informação capaz de permitir a identificação direta ou indireta dos pacientes estivesse acessível. Não foram fornecidos dados pessoais ou identificadores individuais para análise. Para a realização do estudo, foram considerados exclusivamente os registros textuais referentes ao primeiro atendimento dos pacientes no serviço de emergência.

4.6 Especialização do Modelo e Análise de Desempenho

O modelo ModernBERT foi especializado para classificar uma entrada de texto nas classes “Aplica” e “Não se aplica”, indicando quando a suspeita de dengue é aplicável ao texto fornecido. As configurações utilizadas são descritas a seguir. A taxa de aprendizado foi configurada com o valor 5e-5, padrão na comunidade. Para cada *batch* de treinamento utilizamos 4 amostras, para aliviar os requisitos de memória. Como a base de dados apresenta muito mais amostras onde os critérios de suspeita de dengue não são aplicáveis, a métrica otimizada durante o treinamento foi a *F1-score* - que é mais adequada quando há desbalanceamento de classes. Para avaliar a robustez e desempenho do modelo, e mitigar o fenômeno de *overfitting*, utilizamos a estratégia de validação *K-fold*. Nessa estratégia, os dados foram particionados em K subconjuntos mutuamente exclusivos, a nível de paciente. A cada iteração, K-1 subconjuntos são utilizados para ajustar o modelo, enquanto os dados restantes servem como conjunto de validação independente. O processo é então repetido K vezes, garantindo que os dados de cada paciente foram utilizados exatamente uma vez para validação. Em cada iteração o modelo foi ajustado por 5 épocas.

Após a etapa de ajuste do modelo, seu desempenho foi avaliado por meio da comparação entre sua classificação automatizada dos registros clínicos e o padrão-

ouro definido pela revisão manual dos prontuários. Para isso, foi construída uma matriz de confusão contendo verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.

A partir dessa matriz, foram calculadas as métricas de acurácia, sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN) e F1-score, considerando o desbalanceamento entre as classes e a necessidade de avaliação equilibrada entre detecção de casos e erros de classificação.

A acurácia representa a proporção total de classificações corretas. A sensibilidade avalia a capacidade de identificação dos casos suspeitos de dengue, enquanto a especificidade mede a capacidade de reconhecer corretamente os casos não suspeitos.

Os valores preditivos positivo e negativo indicam a confiabilidade prática das classificações do modelo. O F1-score foi utilizado como métrica síntese por combinar precisão e sensibilidade, sendo especialmente adequado para cenários com classes desbalanceadas.

A estabilidade do modelo foi avaliada por validação cruzada, com cálculo do F1-score médio e desvio-padrão entre diferentes partições dos dados. Por fim, os casos identificados pelo padrão-ouro foram comparados aos registros oficiais de vigilância, permitindo estimar o grau de subnotificação no período analisado.

5 RESULTADOS

Foram analisados 2.697 atendimentos realizados no Pronto-Socorro adulto e infantil do Hospital da PUC-Campinas durante a 15ª Semana Epidemiológica de 2024, período caracterizado por elevada circulação de dengue no município de Campinas e aumento da demanda assistencial relacionada à epidemia.

A classificação dos atendimentos quanto à suspeita de dengue foi realizada por meio da revisão manual dos registros clínicos, considerando as informações disponíveis nos campos de texto livre dos prontuários, incluindo descrição de sintomas, história clínica e avaliação inicial registrada pelos profissionais de saúde. A identificação dos casos suspeitos foi baseada nos critérios clínico-epidemiológicos estabelecidos pelo Ministério da Saúde para definição de caso suspeito de dengue,

considerando indivíduos residentes ou procedentes de áreas com transmissão da doença ou presença do vetor *Aedes aegypti*, que apresentassem febre com duração entre dois e sete dias associada a duas ou mais manifestações clínicas, como náuseas, vômitos, exantema, mialgia, artralgia, cefaleia, dor retro-orbitária, petéquias ou leucopenia (BRASIL, 2024).

A revisão manual identificou 505 atendimentos compatíveis com caso suspeito de dengue, correspondendo a 18,7% do total de atendimentos analisados. Em comparação, os registros oficiais da Vigilância Epidemiológica identificaram 337 casos suspeitos no mesmo período, representando 12,5% da amostra total.

A diferença observada entre os casos identificados pela revisão manual e aqueles registrados oficialmente correspondeu a 168 atendimentos adicionais classificados como suspeitos pelo padrão-ouro. Considerando os casos identificados manualmente como referência, essa diferença representa uma subnotificação estimada de 33,3%. Esse resultado evidencia uma discrepância entre os casos identificados por meio da análise detalhada dos registros clínicos e aqueles incorporados aos sistemas oficiais de vigilância epidemiológica durante o período avaliado, sugerindo possível perda de informações ao longo do fluxo assistencial e de notificação, especialmente em um cenário caracterizado por elevada demanda dos serviços de saúde.

O modelo ajustado foi avaliado quanto à sua capacidade de reproduzir a classificação obtida pelo padrão-ouro. Durante a validação por *K-fold*, o modelo apresentou F1-score médio de 0,890 (DP = 0,004), indicando alta estabilidade do desempenho entre diferentes subconjuntos de dados. O F1-score é uma métrica que combina precisão e sensibilidade, sendo especialmente relevante em cenários com desequilíbrio entre classes, pois penaliza tanto falsos positivos quanto falsos negativos de forma equilibrada.

Na avaliação do conjunto de teste, a acurácia média foi de 84,9% (DP = 0,006), indicando que aproximadamente 85% das classificações realizadas pelo modelo estavam corretas em relação ao padrão-ouro. No entanto, a acurácia isoladamente não é suficiente para avaliar desempenho em bases desbalanceadas, como neste estudo, no qual há maior predominância de casos negativos. Por isso, o

F1-score ponderado de 83,1% (DP = 0,008) fornece uma medida mais robusta do desempenho global, ao considerar o peso proporcional de cada classe.

5.1 Desempenho por classe

A Tabela 1 apresenta as métricas de desempenho do modelo de Inteligência Artificial na classificação automatizada dos registros clínicos quanto à suspeita de dengue.

Métrica	Classe	Média	Desvio-padrão
Acurácia	Geral	0,849293	0,005730
Escore F1	Média ponderada (geral)	0,830709	0,007948
Precisão	**Aplica**	0,684994	0,037314
Sensibilidade (Recall)	**Aplica**	0,372704	0,041861
Escore F1	**Aplica**	0,480785	0,034415
Precisão	**Não se aplica**	0,868525	0,006693
Sensibilidade (Recall)	**Não se aplica**	0,959769	0,009290
Escore F1	**Não se aplica**	0,911813	0,003323

Tabela 1 – Métricas de desempenho do modelo de Inteligência Artificial na identificação automatizada de casos suspeitos de dengue.

Na análise da classe positiva (“Aplica”), correspondente aos registros classificados como suspeitos de dengue, o modelo apresentou precisão de 68,5%. Esse resultado indica que, entre os registros classificados pelo modelo como suspeitos, aproximadamente dois terços correspondiam efetivamente a casos compatíveis com dengue segundo o padrão-ouro. Entretanto, a sensibilidade foi de 37,3%, indicando que o modelo identificou pouco mais de um terço dos casos suspeitos existentes na base analisada.

A menor sensibilidade observada para a classe positiva indica que o modelo apresentou dificuldade em identificar todos os registros classificados como suspeitos de dengue pelo padrão-ouro. Esse resultado demonstra a ocorrência de falsos negativos, ou seja, atendimentos que apresentavam critérios compatíveis com suspeita de dengue na revisão manual, mas que foram classificados pelo modelo como não suspeitos. Essa limitação pode estar relacionada à complexidade dos registros clínicos em texto livre, nos quais há variações na forma de descrição dos sintomas, uso de diferentes expressões clínicas e ausência de informações padronizadas, tornando mais desafiadora a identificação automatizada de todos os casos suspeitos.

Por outro lado, a classe negativa (“Não se aplica”), correspondente aos registros sem critérios compatíveis com suspeita de dengue, apresentou desempenho superior. O modelo alcançou precisão de 86,9%, sensibilidade de 96,0% e F1-score de 91,2%. Esses resultados demonstram elevada capacidade de reconhecer corretamente registros que não apresentavam características compatíveis com dengue. A especificidade estimada foi de 96,1%, indicando baixa ocorrência de falsos positivos e reforçando a capacidade do modelo em excluir registros sem suspeita da doença.

Os baixos valores de desvio-padrão observados entre as métricas demonstram estabilidade do desempenho do modelo nas diferentes partições avaliadas, indicando consistência dos resultados obtidos durante o processo de validação.

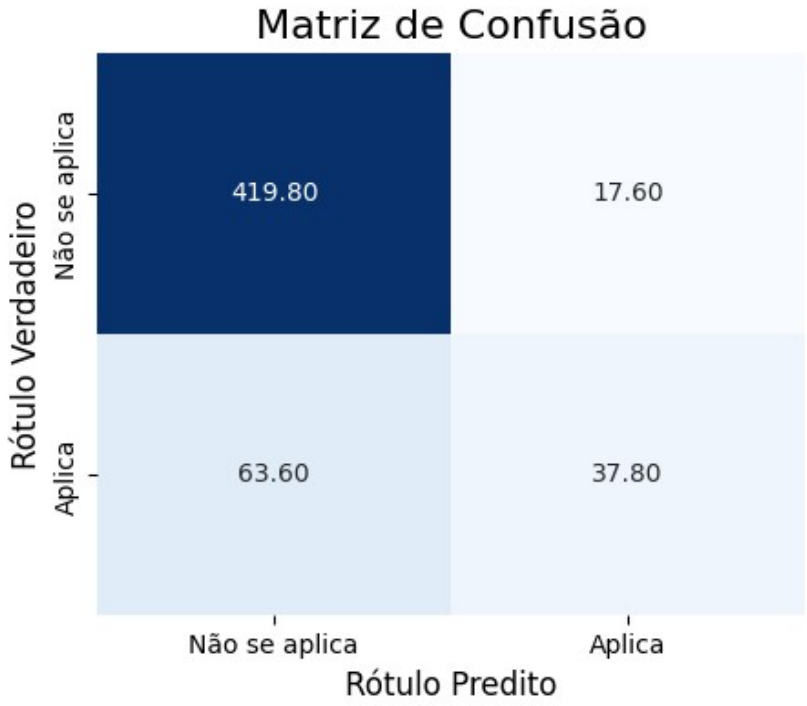

A matriz de confusão apresentada corresponde à média dos resultados obtidos nas cinco partições da validação cruzada estratificada (*5-fold cross-validation*). Nesse procedimento, a base de dados foi dividida em cinco subconjuntos de tamanho semelhante, mantendo a proporção entre as classes avaliadas. Em cada iteração, quatro subconjuntos foram utilizados para treinamento do modelo e um subconjunto foi reservado para avaliação do desempenho. Ao final das cinco etapas, os valores médios de verdadeiros positivos (registros classificados corretamente como suspeitos de dengue), verdadeiros negativos (registros classificados corretamente como não suspeitos), falsos positivos (registros classificados incorretamente como suspeitos) e falsos negativos (registros suspeitos não identificados pelo modelo) foram calculados a partir dos resultados obtidos em cada partição.

A matriz de confusão média foi composta por 419,8 verdadeiros negativos, 37,8 verdadeiros positivos, 17,6 falsos positivos e 63,6 falsos negativos. Esses resultados demonstram que o modelo apresentou maior capacidade de reconhecer registros classificados como não suspeitos do que identificar todos os registros compatíveis com suspeita de dengue.

De maneira geral, os resultados demonstram que o ModernBERT apresentou maior capacidade de identificar corretamente registros sem critérios compatíveis

com suspeita de dengue, apresentando elevado desempenho na classificação dos casos negativos. Entretanto, o modelo apresentou menor capacidade para identificar todos os registros classificados como suspeitos pela revisão manual, evidenciada pela sensibilidade reduzida da classe positiva. Dessa forma, os resultados sugerem que o modelo pode atuar como uma ferramenta complementar à vigilância epidemiológica, auxiliando na análise inicial de grandes volumes de registros clínicos e na identificação de atendimentos que possam necessitar de avaliação posterior por profissionais de saúde.

6 DISCUSSÃO

Os resultados deste estudo evidenciaram uma diferença relevante entre os casos suspeitos de dengue identificados por meio da revisão manual dos registros clínicos e aqueles registrados nos sistemas oficiais de vigilância epidemiológica. A análise manual identificou 505 atendimentos compatíveis com os critérios clínico-epidemiológicos para suspeita de dengue, enquanto os registros oficiais apresentavam 337 casos no mesmo período. A diferença de 168 atendimentos correspondeu a uma subnotificação estimada de 33,3% em relação aos casos identificados pelo padrão-ouro, evidenciando uma discrepância entre as informações disponíveis nos registros assistenciais e aquelas incorporadas aos sistemas formais de vigilância epidemiológica.

A subnotificação da dengue representa um desafio reconhecido em diferentes cenários epidemiológicos, inclusive em sistemas de vigilância estruturados. Sistemas baseados predominantemente em notificações passivas dependem da identificação clínica, do registro adequado das informações e da comunicação oportuna dos casos, tornando-se suscetíveis a perdas ao longo do fluxo entre a assistência e a vigilância. Estudos recentes apontam que a subestimação da carga real da dengue está relacionada a múltiplos fatores, incluindo casos não reconhecidos clinicamente, procura variável pelos serviços de saúde, limitações no preenchimento das notificações e diferenças na capacidade de detecção dos sistemas de informação (LESSA et al., 2025; BORGES et al., 2026).

A magnitude da subnotificação estimada neste estudo (33,3%) pode também ser compreendida à luz das regras de confirmação de casos vigentes em cenários de alta incidência. De acordo com orientações da vigilância epidemiológica

brasileira, em situações caracterizadas como epidêmicas, os casos suspeitos de dengue tendem a ser confirmados com base em critério clínico-epidemiológico, sem a exigência de confirmação laboratorial individualizada (CONASS, [s.d.]; BRASIL, 2024). O estado de São Paulo, por exemplo, adota o referencial de 300 casos por 100 mil habitantes como marco para a declaração de situação de epidemia de dengue (AGÊNCIA BRASIL, 2025). Como o período analisado neste estudo corresponde exatamente à semana de maior incidência da doença em Campinas em 2024, esse contexto de alta transmissão soma-se aos demais fatores já discutidos, sobrecarga assistencial e fragmentação entre o registro clínico e a notificação, para explicar a diferença observada entre o padrão-ouro e os registros oficiais de vigilância, reforçando a relevância de ferramentas complementares de identificação de casos, como a avaliada neste estudo, também em cenários de transição entre diferentes lógicas de confirmação adotadas pela vigilância.

Esse fenômeno tende a se tornar mais evidente em períodos epidêmicos, quando o aumento expressivo da demanda assistencial pode comprometer a capacidade operacional das equipes responsáveis pelo atendimento e pela notificação. Embora períodos de alta transmissão possam aumentar a suspeição clínica para dengue, a sobrecarga dos serviços de saúde pode dificultar a documentação completa dos casos e reduzir a oportunidade dos registros epidemiológicos. O cenário brasileiro observado durante a epidemia de dengue de 2024 reforça esse desafio, com grande volume de atendimentos, pressão sobre os serviços assistenciais e necessidade de respostas rápidas dos sistemas de vigilância (SOUZA et al., 2024; BORGES et al., 2026).

Além dos fatores relacionados ao volume assistencial, a integração entre os registros clínicos e os sistemas de vigilância permanece como um desafio estrutural. Em serviços de urgência e emergência, grande parte das informações clínicas é registrada em formato de texto livre, sem padronização suficiente para análise automatizada ou integração direta com sistemas epidemiológicos. Essa fragmentação limita a utilização dos dados produzidos na assistência para identificação oportuna de eventos de interesse em saúde pública e representa uma das barreiras para o desenvolvimento de sistemas de vigilância em tempo real (ANGELO et al., 2020; BORGES et al., 2026).

Durante a construção do padrão-ouro deste estudo, por meio da revisão manual dos registros clínicos, foram observadas limitações relacionadas à qualidade e à heterogeneidade das informações registradas. Identificou-se variabilidade na forma de documentação entre os profissionais de saúde, incluindo uso de abreviações, diferentes formas de descrição dos sintomas, registros incompletos e ausência de informações clínicas relevantes. Essas características são frequentes em registros eletrônicos de saúde produzidos em ambientes assistenciais, especialmente em cenários de alta demanda, nos quais o tempo disponível para documentação pode ser reduzido.

Também foi observada, em alguns registros, a ausência de descrição detalhada dos sinais e sintomas clínicos, com preenchimento predominantemente baseado no diagnóstico final ou hipótese registrada no sistema institucional. Essa prática limita a rastreabilidade do raciocínio clínico e dificulta a aplicação retrospectiva de critérios epidemiológicos padronizados. No presente estudo, foram considerados como suspeitos apenas os registros que atendiam aos critérios definidos pelo Ministério da Saúde, independentemente de diagnósticos previamente registrados no sistema, garantindo maior rigor metodológico na definição do padrão-ouro.

Outro aspecto identificado foi a heterogeneidade na aplicação dos critérios clínicos para suspeita de dengue. Alguns registros apresentavam associação da suspeita diagnóstica com manifestações isoladas, sem a presença do conjunto de critérios recomendado pelo Ministério da Saúde. Esses registros não foram classificados como casos suspeitos no presente estudo, uma vez que a metodologia adotada priorizou a aplicação estrita da definição oficial de caso suspeito, buscando garantir maior consistência e reprodutibilidade na avaliação do desempenho do modelo de IA.

Essas características dos registros clínicos representam um desafio importante para aplicações baseadas em Processamento de Linguagem Natural (PLN). Modelos de Inteligência Artificial dependem da qualidade, representatividade e consistência dos dados utilizados para treinamento e avaliação. A presença de variações linguísticas, abreviações, erros de escrita e informações incompletas pode dificultar a extração de informações clínicas relevantes e comprometer o

desempenho dos modelos em tarefas de classificação clínica (ALSENTZER et al., 2019; WU et al., 2022; TOPOL, 2019).

Os resultados obtidos pelo modelo ModernBERT demonstraram desempenho global satisfatório na classificação automatizada dos registros clínicos, com acurácia de 84,9% e F1-score ponderado de 83,1%. Entretanto, observou-se diferença importante entre o desempenho das classes avaliadas. O modelo apresentou maior capacidade de identificar registros classificados como não suspeitos de dengue, com sensibilidade de 96,0% e especificidade estimada de 96,1%, indicando elevada capacidade de reconhecer corretamente registros sem critérios compatíveis com a doença.

Por outro lado, a sensibilidade observada para a classe positiva foi de 37,3%, demonstrando limitação na identificação de todos os casos classificados como suspeitos pelo padrão-ouro. Esse resultado indica a ocorrência de falsos negativos, ou seja, registros que apresentavam critérios compatíveis com suspeita de dengue na revisão manual, mas que foram classificados pelo modelo como não suspeitos. Essa limitação pode estar relacionada tanto ao desequilíbrio entre as classes analisadas quanto às características dos registros clínicos em texto livre, nos quais diferentes formas de expressão, ausência de sintomas descritos e informações incompletas podem dificultar o reconhecimento automatizado dos casos suspeitos.

Outro aspecto relevante para a interpretação dos resultados refere-se ao momento do curso clínico da doença em que o atendimento é registrado. Uma parcela dos pacientes atendidos no Pronto-Socorro pode ter sido encaminhada de outros serviços de saúde, chegando à unidade em estágio mais avançado da doença, quando parte da sintomatologia inicial, como febre associada a manifestações inespecíficas, já não é mencionada no relato da chegada. Esse fenômeno é discutido na literatura internacional: em estudo conduzido na Colômbia durante o surto de dengue de 2023-2024, observou-se que pacientes provenientes de áreas mais distantes tendem a ser encaminhados aos serviços de referência apenas quando a doença já se encontra em estágio mais avançado, o que pode influenciar a associação entre origem geográfica, sintomas documentados e gravidade (TORRES-HERNÁNDEZ et al., 2025). De forma semelhante, estudo realizado em Burkina Faso durante o surto de 2023 demonstrou associação independente entre o tempo decorrido até a procura por atendimento médico e a

gravidade da dengue (OUEDRAOGO et al., 2026). Neste estudo, optou-se deliberadamente por basear a classificação de suspeita de dengue nas informações registradas no momento do primeiro atendimento na unidade de emergência, de forma coerente com o objetivo de avaliar a identificação precoce de casos suspeitos logo na porta de entrada do serviço. A incorporação de sinais e sintomas documentados em etapas posteriores da assistência, contemplando também as particularidades de pacientes encaminhados de outros serviços, representa uma extensão natural e complementar desta investigação, com potencial para ampliar a compreensão do desempenho do modelo ao longo de diferentes momentos do curso clínico da doença.

Dessa forma, os resultados indicam que o ModernBERT não deve ser interpretado como uma ferramenta autônoma para diagnóstico ou substituição da avaliação profissional, mas como um recurso complementar aos processos de vigilância epidemiológica. Sua principal contribuição está relacionada ao potencial de analisar grandes volumes de registros clínicos em texto livre e auxiliar na priorização de atendimentos que possam necessitar de avaliação epidemiológica posterior.

Nesse contexto, a utilização de modelos de IA pode contribuir para otimizar estratégias de busca ativa e revisão automatizada de registros clínicos, especialmente em períodos de elevada demanda assistencial, nos quais a análise manual integral dos atendimentos pode ser operacionalmente limitada. Essas ferramentas apresentam potencial para auxiliar na identificação de registros clínicos com características compatíveis com casos suspeitos de dengue, favorecendo a priorização de avaliações posteriores e o aprimoramento dos processos de vigilância epidemiológica. Entretanto, o desempenho e a aplicabilidade desses modelos estão diretamente relacionados à qualidade dos dados disponíveis, à padronização dos registros clínicos e à adequada integração com os sistemas de informação em saúde. Além disso, os resultados gerados pela IA devem ser interpretados como suporte à tomada de decisão, permanecendo associados à avaliação dos profissionais de saúde e às características clínicas e epidemiológicas de cada cenário. Dessa forma, antes de sua incorporação aos processos de vigilância, esses modelos devem ser continuamente avaliados e validados em diferentes contextos assistenciais e epidemiológicos, acompanhados por estratégias voltadas à melhoria da qualidade, completude e padronização dos registros clínicos.

Uma perspectiva relevante para a continuidade desta linha de pesquisa é a aplicabilidade do modelo em Unidades Básicas de Saúde (UBS) e Unidades de Pronto Atendimento (UPA), que compõem, junto aos serviços hospitalares, a rede de atenção à saúde do município de Campinas e utilizam prontuário eletrônico em sua rotina assistencial. Por se constituírem como a porta de entrada preferencial do sistema de saúde no território e por atenderem volumes assistenciais ainda maiores do que os observados em serviços de pronto-socorro hospitalar, as UBS representam um cenário potencialmente mais desafiador e, ao mesmo tempo, mais estratégico para a aplicação de ferramentas de IA voltadas à vigilância epidemiológica. A literatura recente sobre uso de PLN e aprendizado de máquina em registros eletrônicos da atenção primária demonstra ganhos relevantes na identificação de condições clínicas a partir de texto não estruturado, especialmente para condições sub-registradas em campos estruturados (ZHANG et al., 2026), ao mesmo tempo em que reforça a necessidade de validação externa dos modelos em diferentes contextos assistenciais antes de sua incorporação a fluxos de vigilância em tempo real (LI et al., 2026). O treinamento e a validação do modelo com dados provenientes especificamente da atenção primária constituem, portanto, uma direção promissora para estudos futuros, podendo inclusive revelar padrões de desempenho distintos em razão das características próprias dos registros produzidos nesse nível de atenção.

7 CONCLUSÃO

Este estudo demonstrou a viabilidade da utilização de um modelo de IA baseado em PLN e arquitetura ModernBERT para a identificação automatizada de casos suspeitos de dengue a partir de registros clínicos em texto livre. O modelo apresentou desempenho consistente quando comparado ao padrão-ouro estabelecido pela revisão manual, com estabilidade entre os diferentes subconjuntos de dados avaliados. Entretanto, observou-se maior capacidade de classificação dos casos negativos em comparação aos casos positivos, evidenciada pela elevada especificidade e sensibilidade limitada. Esses achados indicam que o modelo apresenta potencial para aplicação como ferramenta de triagem e apoio à identificação de casos suspeitos, embora ainda sejam necessários aprimoramentos para ampliar sua capacidade de detecção.

A comparação entre os casos identificados pela revisão manual, pelo modelo de IA e pelos registros oficiais da Vigilância Epidemiológica evidenciou uma importante subnotificação de casos suspeitos de dengue no período analisado. A diferença observada entre os casos compatíveis com os critérios clínico-epidemiológicos e aqueles registrados nos sistemas oficiais demonstra possíveis limitações no processo de transição das informações produzidas na assistência para os sistemas de vigilância, especialmente em períodos de elevada demanda assistencial. Esses resultados reforçam a necessidade de estratégias que contribuam para a qualificação dos processos de identificação e notificação de casos.

A análise dos registros clínicos também evidenciou limitações relacionadas à qualidade e à padronização das informações disponíveis em texto livre. Foram identificadas inconsistências como erros ortográficos, utilização de abreviações não padronizadas, ausência de descrição completa de sinais e sintomas e registros baseados exclusivamente em diagnósticos finais. Somam-se a essas limitações a ausência de avaliação da robustez do modelo a variações sinonímicas dos sintomas, de testes em períodos de baixa incidência da doença e de análises segmentadas por faixa etária, aspectos que constituem direções relevantes para o aprofundamento desta linha de pesquisa.

Além disso, foram observadas diferenças na aplicação dos critérios utilizados para definição de casos suspeitos de dengue, incluindo registros que não contemplam integralmente as recomendações do Ministério da Saúde. Essas limitações podem comprometer tanto a qualidade das informações epidemiológicas quanto o desempenho de modelos automatizados, destacando a importância da melhoria contínua dos registros clínicos.

Os resultados obtidos indicam que modelos de IA possuem potencial para atuar como ferramentas complementares às estratégias tradicionais de vigilância epidemiológica, especialmente na análise de grandes volumes de registros clínicos e na identificação automatizada de atendimentos potencialmente subnotificados. Sua utilização pode contribuir futuramente para estratégias destinadas à identificação oportuna de casos suspeitos, ao aprimoramento dos processos de busca ativa e ao fortalecimento das ações de vigilância epidemiológica, especialmente em períodos de elevada demanda assistencial.

A aplicação de IA associada ao PLN mostrou-se uma abordagem promissora para auxiliar a análise automatizada de registros clínicos não estruturados. Entretanto, sua incorporação aos processos de vigilância epidemiológica depende de validação prospectiva, aprimoramento contínuo dos modelos e melhoria da qualidade dos registros clínicos.

8 REFERÊNCIAS

AGÊNCIA BRASIL. Com 300 casos por 100 mil habitantes, SP entra em epidemia de dengue. Brasília: Empresa Brasil de Comunicação, 21 fev. 2025. Disponível em: https://agenciabrasil.ebc.com.br/saude/noticia/2025-02/com-300-casos-por-100-mil-habitantes-sp-entra-em-epidemia-de-dengue.

ALSENTZER, Emily; MURPHY, John R.; BOAG, Willie; WENG, Wei-Hung; JIN, Di; NAUMANN, Tristan; MCDERMOTT, Matthew B. A. Publicly available clinical BERT embeddings. In: *PROCEEDINGS OF THE 2ND CLINICAL NATURAL LANGUAGE PROCESSING WORKSHOP*, 2019, Minneapolis. *Proceedings [...]*. Minneapolis: Association for Computational Linguistics, 2019. p. 72-78. DOI: 10.18653/v1/W19-1909.

ANGELO, Marco; RAMALHO, Walter Massa; GURGEL, Helen da Costa; BELLE, Nayara; PILOT, Eva. Dengue surveillance system in Brazil: a qualitative study in the Federal District. *International Journal of Environmental Research and Public Health*, Basel, v. 17, n. 6, p. 2062, 2020. DOI: 10.3390/ijerph17062062.

BATISTA, Ewerthon Dyego de Araújo et al. Uso de machine learning e de deep learning para prever internações causadas por dengue na Paraíba. *Revista de Sistemas e Computação*, Salvador, v. 11, n. 3, 2021. DOI: 10.36558/rsc.v11i3.7475.

BORGES, Marcelo E.; CODEÇO, Cláudia Torres; MACHADO, Diógenes; ALMEIDA, Antônio. Epidemiological and digital syndromic surveillance data on dengue, chikungunya, and SARI in Brazil. *Scientific Data*, London, v. 13, art. 68, 2026. DOI: 10.1038/s41597-025-06155-6.

BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde e Ambiente. Departamento de Doenças Transmissíveis. *Dengue: diagnóstico e manejo clínico: adulto e criança*. 6. ed. Brasília: Ministério da Saúde, 2024. 81 p. Disponível em: https://bvsms.saude.gov.br/bvs/publicacoes/dengue_diagnostico_manejo_clinico_6ed.pdf.

BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde e Ambiente. *Guia de Vigilância em Saúde*. 6. ed. Brasília: Ministério da Saúde, 2024.

CABRERA, Manuel; LEAKE, Jonathan; NARANJO-TORRES, Jorge; VALERO, Nelson; CABRERA, Juan Carlos; RODRÍGUEZ-MORALES, Alfonso J. Dengue prediction in Latin America using machine learning and the One Health perspective: a literature review. *Tropical Medicine and Infectious Disease*, Basel, v. 7, n. 10, p. 322, 2022. DOI: 10.3390/tropicalmed7100322.

CONSELHO NACIONAL DE SECRETÁRIOS DE SAÚDE (CONASS). *Nota técnica: dengue – indicadores epidemiológicos*. Brasília: CONASS, [s.d.]. Disponível em: https://www.conass.org.br/guiainformacao/notas_tecnicas/NT14-DENGUE-Indicadores-epidemiologicos.pdf.

DA SILVA, Rildo Pinto; POLLETTINI, Juliana Tarossi; PAZIN FILHO, Antonio. Processamento de linguagem natural não supervisionado na identificação de pacientes suspeitos de infecção por COVID-19. *Cadernos de Saúde Pública*, Rio de Janeiro, v. 39, n. 11, e00243722, 2023. DOI: 10.1590/0102-311XPT243722.

DEVLIN, Jacob; CHANG, Ming-Wei; LEE, Kenton; TOUTANOVA, Kristina. BERT: pre-training of deep bidirectional transformers for language understanding. In: *PROCEEDINGS OF THE 2019 CONFERENCE OF THE NORTH AMERICAN CHAPTER OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS: HUMAN LANGUAGE*

TECHNOLOGIES. Minneapolis: Association for Computational Linguistics, 2019. p. 4171-4186. DOI: 10.18653/v1/N19-1423.

HAUG, Charlotte J.; DRAZEN, Jeffrey M. Artificial intelligence and machine learning in clinical medicine. *New England Journal of Medicine*, Boston, v. 388, n. 13, p. 1201-1208, 2023. DOI: 10.1056/NEJMra2302038.

HO, T. S.; WENG, T. C.; WANG, J. D.; HAN, H. C.; CHENG, H. C.; YANG, C. C.; YU, C. H.; LIU, Y. J.; HU, C. H.; HUANG, C. Y.; CHEN, M. H.; KING, C. C.; OYANG, Y. J.; LIU, C. C. Comparing machine learning with case-control models to identify confirmed dengue cases. *PLoS Neglected Tropical Diseases*, San Francisco, v. 14, n. 11, e0008843, 2020. DOI: 10.1371/journal.pntd.0008843.

HUANG, Shih-Wei; TSAI, Hsiao-Ping; HUNG, Shih-Jen; KO, Wen-Chien; WANG, Jen-Ren. Assessing the risk of dengue severity using demographic information and laboratory test results with machine learning. *PLoS Neglected Tropical Diseases*, San Francisco, v. 14, n. 12, e0008960, 2020. DOI: 10.1371/journal.pntd.0008960.

KHAN, M. B.; YANG, Z. S.; LIN, C. Y.; HSU, M. C.; URBINA, A. N.; ASSAVALAPSAKUL, W.; WANG, W. H.; CHEN, Y. H.; WANG, S. F. Dengue overview: An updated systematic review. *Journal of Infection and Public Health*, Amsterdam, v. 16, n. 10, p. 1625-1642, 2023. DOI: 10.1016/j.jiph.2023.08.001.

KULARATNE, Saman A.; DALUGAMA, Chamila. Dengue infection: global importance, immunopathology and management. *Clinical Medicine*, London, v. 22, n. 1, p. 9-13, 2022. DOI: 10.7861/clinmed.2021-0791.

LEE, Jinhyuk; YOON, Wonjin; KIM, Sungdong; KIM, Donghyeon; KIM, Sunkyu; SO, Chan Ho; KANG, Jaewoo. BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*, Oxford, v. 36, n. 4, p. 1234-1240, 2020. DOI: 10.1093/bioinformatics/btz682.

LESSA, C. L. S.; FIUZA, B. S. D.; HODEL, K. V. S.; MINAFRA, C.; GONÇALVES, M. S.; MACHADO, B. A. S. Understanding Dengue Underreporting: An Analysis of the Impacts for the World, Latin America and Brazil. *The Scientific World Journal*, v. 2025, art. 9993911, 2025. DOI: 10.1155/tswj/9993911.

LI, Jin-Hua; TSENG, Yi-Ju; CHEN, Shu-Hui; CHEN, Kuan-Fu. Artificial intelligence in infection surveillance: data integration, applications and future directions. *Biomedical Journal*, Amsterdam, v. 49, n. 2, art. 100929, 2026. DOI: 10.1016/j.bj.2025.100929.

LIMA, Carlos L. et al. Temporal and spatiotemporal arboviruses forecasting by machine learning: a systematic review. *Frontiers in Public Health*, Lausanne, v. 10, p. 900077, 2022. DOI: 10.3389/fpubh.2022.900077.

LIU, Leibo; BLAKE, Victoria; BARMAN, Matthew; GALLEGO, Blanca; CHURCHES, Timothy; KENNEDY, Georgina; OOI, Sze-Yuan; DELANEY, Geoffrey P.; JORM, Louisa. Using natural language processing to extract information from clinical text in electronic medical records for populating clinical registries: a systematic review. *Journal of the American Medical Informatics Association*, Oxford, v. 33, n. 2, p. 484-499, 2026. DOI: 10.1093/jamia/ocaf176.

LOBER, L.; ROSTER, K. O.; RODRIGUES, F. A. Forecasting infectious diseases in Brazilian cities: Integrating socio-economic and geographic data from related cities through a machine

learning approach. *Chaos, Solitons & Fractals*, Amsterdam, v. 187, art. 115417, 2024. DOI: 10.1016/j.chaos.2024.115417.

MARQUES, Carla Adriana; SIQUEIRA, Marluce Mechelli de; PORTUGAL, Flávia Batista. Avaliação da não completude das notificações compulsórias de dengue registradas por município de pequeno porte no Brasil. *Ciência & Saúde Coletiva*, Rio de Janeiro, v. 25, n. 3, p. 891-900, 2020. DOI: 10.1590/1413-81232020253.16162018.

MEDEIROS, Eduardo Alexandrino. Challenges in controlling the dengue epidemic in Brazil. *Acta Paulista de Enfermagem*, São Paulo, v. 37, eEDT012, 2024. DOI: 10.37689/acta-ape/2024EDT012.

OUEDRAOGO, Dramane; DIENDERE, Eric Arnaud; KY/BA, Absatou; KABORE, Rose; OUÉDRAOGO, Souleymane; DIALLO, Ismael; OUEDRAOGO/SONDO, Apoline. Impact of delayed medical consultation on dengue severity and mortality during the 2023 outbreak in Burkina Faso. *IJID Regions*, Amsterdam, v. 20, art. 100939, 2026. DOI: 10.1016/j.ijregi.2026.100939.

RAJPURKAR, Pranav; CHEN, Emma; BANERJEE, Oishi; TOPOL, Eric J. AI in health and medicine. *Nature Medicine*, New York, v. 28, n. 1, p. 31-38, 2022. DOI: 10.1038/s41591-021-01614-0.

SILVA, Monaise M. O.; RODRIGUES, Moreno S.; PAPLOSKI, Igor A. D. et al. Accuracy of dengue reporting by National Surveillance System, Brazil. *Emerging Infectious Diseases*, Atlanta, v. 22, n. 2, p. 336-339, 2016. DOI: 10.3201/eid2202.150495.

SOUZA, C. D. F.; NASCIMENTO, R. P. S.; BEZERRA-SANTOS, M. et al. Space-time dynamics of the dengue epidemic in Brazil, 2024: an insight for decision making. *BMC Infectious Diseases*, London, v. 24, art. 1056, 2024. DOI: 10.1186/s12879-024-09813-z.

TOPOL, Eric J. High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, New York, v. 25, n. 1, p. 44-56, 2019. DOI: 10.1038/s41591-018-0300-7.

TORRES-HERNÁNDEZ, Daniela; GRUBAUGH, Nathan D.; MURILLO-ORTIZ, Mónica A.; HURTADO, Isabel C.; HILL, Verity; BREBAN, Mallery I.; GÓMEZ-ZAMBRANO, Mara; LÓPEZ, Pio; CANTOR, Erika; DÁVALOS, Diana M.; LÓPEZ-MEDINA, Eduardo. Epidemiology and severity risk factors of dengue virus infection during the 2023-2024 outbreak in Colombia. *PLOS Neglected Tropical Diseases*, San Francisco, v. 19, n. 12, p. e0013115, 2025. DOI: 10.1371/journal.pntd.0013115.

VASWANI, Ashish et al. Attention is all you need. In: *ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS*. Long Beach: Curran Associates, 2017. v. 30, p. 5998-6008. DOI: 10.48550/arXiv.1706.03762.

WARNER, Benjamin; CHEN, Antoine; HOSSEINI, Bardia et al. Smarter, better, faster, longer: a modern bidirectional encoder for fast, memory efficient, and long context finetuning and inference. *arXiv preprint*, arXiv:2412.13663, 2024.

WORLD HEALTH ORGANIZATION. *Global strategic preparedness, readiness and response plan for dengue and other Aedes-borne arboviruses*. Geneva: World Health Organization, 2024.

WORLD HEALTH ORGANIZATION. *Dengue and severe dengue*. Geneva: World Health Organization, 2024. Disponível em: https://www.who.int/news-room/fact-sheets/detail/dengue-and-severe-dengue.

WU, Shuying; ROBERTS, Kirk; DATTA, Sandeep; DU, Jiayu; JI, Zongcheng; SI, Yanshan; SERCU, Tom; WU, Yonghui. Natural language processing in clinical research and practice: an overview. *NPJ Digital Medicine*, London, v. 5, art. 75, 2022. DOI: 10.1038/s41746-022-00730-6.

ZHANG, Na; ABBASI, Marjan; KHERA, Sheny; BAZRAFKAN, Mehrnoosh; ABBASI-DEZFOULY, Reza; KONG, Linglong. Leveraging natural language processing and machine learning to identify chronic conditions from primary care electronic medical records. *Scientific Reports*, London, v. 16, art. 8441, 2026. DOI: 10.1038/s41598-026-38594-5.