Journal of Health Informatics

J Health Inform. 2026;18:e1878
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1878

ARTIGO COMPLETO
CBIS 2026

Arquiteturas e técnicas de inteligência artificial para detectar sentimentos depressivos em idosos: revisão sistemática

Artificial intelligence architectures and techniques to detect depressive feelings in older adults: a systematic review

Fabio José Gomes de Sousa[1] ✉, Antonia Neyliane Carneiro Torres[2], Ulisses Dias Freitas[3], João Bastos Freire Neto[4], Augusto Flávio Albuquerque Arraes Freire[5], Cesar Olavo de Moura Filho[3], Ronaldo Fernandes Ramos[3], Luiz Odorico Monteiro de Andrade[6], Antônio Mauro Barbosa de Oliveira[5], Ivana Cristina de Holanda Cunha Barrêto[1]

ORCID: 0000-0003-2168-9647 · 0009-0006-3913-0971 · 0009-0002-0048-6365 · 0000-0002-4557-0029 · 0009-0006-3774-6924 · 0000-0003-4815-1820 · 0000-0003-2841-1787 · 0000-0002-3335-0619 · 0000-0002-7898-9440 · 0000-0001-8447-3654

[1] Fundação Oswaldo Cruz, Fortaleza (CE), Brasil.
[2] Universidade Federal do Ceará, Fortaleza (CE), Brasil.
[3] Instituto Federal do Ceará, Fortaleza (CE), Brasil.
[4] Secretaria Municipal da Saúde de Fortaleza, Fortaleza (CE), Brasil.
[5] Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Fortaleza (CE), Brasil.
[6] Fundação Oswaldo Cruz Ceará, Fortaleza (CE), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1878

DOI
10.59681/2175-4411.v18.iEspecial.2026.1878

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
Fabio José Gomes de Sousa
prof.fabiojose@gmail.com

LICENÇA

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

CC BY 4.0

RESUMO

Objetivo: Identificar quais arquiteturas ou técnicas de inteligência artificial, aprendizado de máquina, aprendizado profundo, processamento de linguagem natural ou outras abordagens são utilizadas para detecção e análise de sentimentos nos serviços e sistemas de saúde, com foco na pessoa idosa. **Método:** Revisão sistemática, com busca de artigos publicados nos últimos 5 anos nas bases de dados PubMed, Web of Science e Scopus. **Resultados:** Foram encontradas 361 publicações, mas apenas 23 artigos foram selecionados para discussão do estudo após utilizar os critérios de inclusão e exclusão. Há uma grande lacuna nesta área, pois nenhum trabalho demonstrou efetivamente a utilização destas técnicas nos serviços e sistemas de saúde. **Conclusão:** Concluímos a necessidade de aplicar as técnicas de IA nos serviços e sistemas de saúde (público e privado), visando detectar e analisar sentimentos na pessoa idosa, promovendo a inclusão digital e social deste público e maior eficiência do cuidado e da gestão da saúde.

Descritores: Saúde Mental; Idoso; Inteligência Artificial.

ABSTRACT

Objective: To identify artificial intelligence, machine learning, deep learning, natural language processing, and related approaches applied to sentiment detection and analysis in healthcare services and systems focused on older adults. **Method:** A systematic review was conducted using studies published in the last five years and indexed in the PubMed, Web of Science, and Scopus databases. **Results:** A total of 361 publications were identified, of which 23 were selected after applying the inclusion and exclusion criteria. The findings revealed a substantial gap in this field, since no study effectively demonstrated the application of these techniques in healthcare services and systems. **Conclusion:** The study highlights the need to implement AI-based techniques in healthcare services and systems to support sentiment detection and analysis among older adults, promoting digital and social inclusion as well as improving healthcare management and delivery.

Keywords: Mental health; Aged; Artificial intelligence.

CBIS 2026 XXI CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE

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

COMO CITAR ESTE ARTIGO: de Sousa FJG, Torres ANC, Freitas UD, Freire Neto JB, Freire AFAA, Moura Filho CO, et al. Arquiteturas e técnicas de inteligência artificial para detectar sentimentos depressivos em idosos: revisão sistemática. J Health Inform 2026;18:e1878. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1878

1 INTRODUÇÃO

A integração da Inteligência Artificial (IA) na detecção de emoções e no suporte à saúde mental representa um dos campos mais promissores da computação contemporânea [1,2]. Atualmente, o panorama tecnológico permite a análise de estados afetivos através de uma vasta gama de fontes de dados digitais e biológicos, que incluem desde postagens em redes sociais (como o Twitter) até sinais de radiofrequência (RF) não intrusivos, acústica vocal e expressões faciais capturadas por dispositivos móveis [1-3]. Esse cenário estabelece as bases para a computação afetiva, uma área que busca dotar os sistemas computacionais da capacidade de reconhecer, interpretar e processar emoções humanas, aprimorando expressivamente a interação humano-máquina e a infovigilância em saúde [1,2,4].

A motivação central para o avanço dessas pesquisas reside na crescente prevalência de transtornos de humor e na necessidade urgente de ferramentas de triagem acessíveis e precisas [1,2]. Crises globais, como a pandemia de COVID-19, serviram como um catalisador para estudos que buscam entender reações emocionais e culturais em larga escala, revelando como fatores socioeconômicos, como renda e trabalho, influenciam diretamente o bem-estar psicológico. Além disso, a aplicação clínica da IA é motivada pelo desafio de mitigar o erro de diagnóstico (*misdiagnosis*), que ocorre frequentemente em função da gravidade dos sintomas apresentados pelo paciente, e pela necessidade de monitoramento preventivo em populações vulneráveis, como os idosos, para os quais a detecção precoce de declínio cognitivo e depressão é vital [1,2,4].

No que tange ao estado da arte, observa-se uma transição tecnológica de métodos estatísticos tradicionais para arquiteturas complexas de *Deep Learning* [1,3]. Modelos como Redes Neurais Convolucionais (CNN), *Long Short-Term Memory* (LSTM) e modelos de linguagem baseados em transformadores, como BERT e RoBERTa, têm demonstrado eficácia superior, atingindo níveis de precisão que chegam a 90% na análise de textos e sentimentos [1,2]. O avanço atual foca na abordagem multimodal, que integra simultaneamente sinais de áudio, vídeo e texto através de mecanismos de atenção, permitindo uma compreensão mais granular das emoções [1,3,4]. Inovações recentes incluem ainda o uso de sinais sem fio para monitoramento sem sensores corporais e técnicas de *label-less learning* (LLEC), que automatizam a rotulagem de dados emocionais, reduzindo a dependência de intervenção humana [1,2,4].

Diante deste contexto, o objetivo deste artigo é realizar uma análise abrangente das principais tecnologias de IA voltadas para a detecção de emoções e seu papel no suporte ao diagnóstico e monitoramento da saúde mental. Busca-se investigar quais arquiteturas e técnicas de inteligência artificial são utilizadas para realizar a detecção e análise de sentimentos, sobretudo, em idosos.

2 MÉTODOS

Neste estudo, a metodologia utilizada foi a revisão sistemática da literatura. Este trabalho foi iniciado em maio de 2024 e concluído em dezembro de 2025, protocolado na plataforma PROSPERO, sob o número de registro CRD42024539120, caracterizando-se como pesquisa inédita neste segmento. A pergunta principal da revisão foi “Quais arquiteturas ou técnicas de IA, Aprendizado de Máquina, Aprendizado Profundo, Processamento de Linguagem Natural ou outras abordagens para Detecção e Análise de Sentimentos Nos Serviços e Sistemas de Saúde, com foco na pessoa Idosa?”. A partir desta pergunta primária, outras dez perguntas secundárias e específicas foram elaboradas para embasar a pesquisa nas bases bibliográficas. As dez perguntas foram as seguintes: 1) Quais tipos específicos de sentimentos são detectados em sistemas e serviços de saúde por meio da inteligência artificial? 2) Existem arquiteturas de sistemas computacionais para detecção de sentimentos? 3) Quais técnicas de IA estão sendo utilizadas para a detecção de sentimentos? 4) A detecção de sentimentos em idosos é realizada por IA? 5) Há o uso de técnicas de IA para detectar problemas de saúde mental em idosos? 6) Como a detecção de sentimentos pode ser utilizada para melhorar a qualidade do atendimento ao paciente usando IA? 7) Quais ferramentas de processamento de linguagem natural são mais empregadas nesse contexto? 8) Quais técnicas de aprendizado de máquina são mais eficazes para análise de sentimentos em dados de saúde? 9) Quais são as melhores práticas para garantir a precisão e a confiabilidade dos resultados na detecção de sentimentos em sistemas de saúde? 10) Quais aspectos éticos, morais e legais estão envolvidos na exploração da detecção de sentimentos utilizando IA?

O objetivo principal deste trabalho foi buscar os artigos sobre a condição específica de detecção de sentimentos nos serviços e sistemas de saúde, especialmente na pessoa idosa. O domínio do estudo foi incluir as arquiteturas de sistemas e técnicas de inteligência artificial usadas para detecção de sentimentos em idosos nos serviços e sistemas de saúde. Os critérios de inclusão foram: estudos observacionais que abordavam resultados e desafios de arquiteturas de sistemas, processamento de linguagem natural, aprendizado de máquina e aprendizado profundo ou outras técnicas de IA para realizar detecção e análise de sentimentos nos sistemas e serviços de saúde. Também foram considerados estudos que abordaram estas técnicas no âmbito da saúde mental do idoso, especialmente na detecção da depressão. Já os critérios de exclusão

foram: artigos de revisão, opinião de especialistas, cartas para o editor, dados incompletos ou inconclusivos, artigos em idiomas diferentes do português ou inglês e artigos que não se encaixam no objetivo da pesquisa.

Figura 1. Uso de Arquiteturas de sistemas, Processamento de Linguagem Natural, Aprendizado de Máquina e Aprendizado Profundo para Realizar Detecção e Análise de Sentimentos nos Sistemas e Serviços de Saúde: Revisão Sistemática

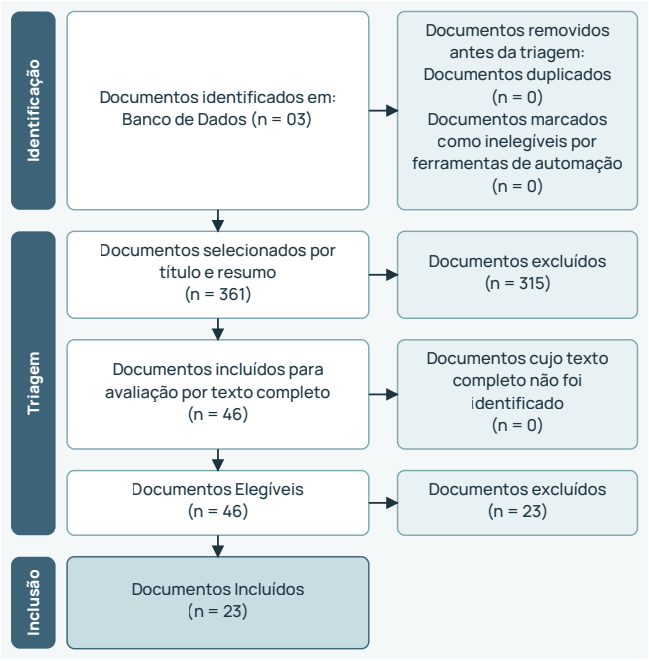

Fonte: Elaborado pelos autores (2026), a partir do modelo PRISMA 2020.

A seleção dos estudos foi conduzida por dois revisores, de forma independente, em todas as etapas da triagem (leitura de títulos e resumos e avaliação dos textos completos), conforme os critérios de inclusão e exclusão previamente estabelecidos. As divergências entre os revisores foram resolvidas por meio de reuniões de consenso, até a obtenção de uma decisão comum.

O gerenciamento das referências bibliográficas foi realizado com o auxílio do Zotero, utilizado para organização e controle das referências recuperadas nas bases de dados. A etapa de triagem foi conduzida na plataforma Rayyan, que também foi utilizada para apoiar o processo de revisão sistemática. Durante a importação das referências para o Rayyan, não foram identificados registros duplicados, não sendo necessária a remoção de duplicatas.

Foram encontrados 361 artigos nessas bases, dos quais foram selecionados 46, após a primeira etapa, que consistiu na leitura dos resumos/*abstracts*. Em seguida, os 46 artigos foram lidos de forma completa e foram identificados 23 que realmente se encaixavam no objetivo do trabalho. A Figura 1 apresenta o fluxograma *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) deste trabalho.

Tabela 1. Estratégias de Buscas nas Bases Bibliográficas

Fontes de informação	*Strings* de buscas	Nº de registros
PUBMED	"artificial intelligence" OR "machine learning" OR "natural language processing" OR "deep learning" OR "system architecture" AND "elderly" OR "senior citizens" OR "older adults" AND "healthcare systems" OR "health services" AND "sentiment analysis" OR "emotion detection"	189
WEB OF SCIENCE	((ALL=(Sentimental Detecting OR Sentimental Analysis OR Mental Health) AND ALL=(Elderly OR Aged OR Elder) AND ALL=(Health System OR Health Service OR Health Care OR Community Health Services) AND ALL=(Natural Language Processing OR Machine Learning OR Artificial intelligence OR system architecture) NOT ALL=(Systematic Review)))	156
SCOPUS	sentimental AND detecting OR sentimental AND analysis OR mental AND Elderly OR Aged OR Elder AND health AND system OR health AND service OR Health AND Service OR Health AND Care OR Community AND Health AND Services AND natural AND language AND processing OR machine AND learning OR system AND architecture NOT Systematic AND Review	16

Fonte: Elaborado pelos autores (2026).

A Tabela 1 mostra as bases pesquisadas, as *strings* de buscas e o número de artigos encontrados em cada uma delas.

3 RESULTADOS

Para alcançar o objetivo da pesquisa foi elaborado o Quadro 1 com as informações, extraídas dos estudos, organizadas de forma lógica e cronológica e, a partir desses dados, realizaram-se análises e discussões.

4 DISCUSSÕES

A análise dos estudos selecionados revela uma evolução expressiva nas arquiteturas de Inteligência Artificial aplicadas à detecção de emoções, transitando de métodos supervisionados clássicos para modelos complexos de aprendizado profundo (*Deep Learning*) e abordagens multimodais. A eficácia dessas tecnologias é evidenciada pelo alcance de altos níveis de precisão, como observado no uso de modelos *MultiLayer Perceptron*, que atingiram 87% de acurácia na classificação de dados de saúde.

Quadro 1. Identificação dos Artigos Selecionados Resumidos

Nº	Título Original	Autores / Ano	Objetivo (Resumo)	Principais Resultados
1	Cross-Cultural Polarity and Emotion Detection Using Sentiment Analysis and Deep Learning on COVID-19 Related Tweets	Imran AS, Daudpota SM, Kastrati Z, Batra R. (2020)	Investigar reações culturais à pandemia via redes sociais usando LSTM e BERT.	Alta correlação entre países vizinhos; modelos detectaram variações culturais em lockdowns.
2	Affective Computing for Late-Life Mood and Cognitive Disorders	Smith E, Storch EA, Vahia I, Wong STC, Lavretsky H, Cummings JL, Eyre HA. (2021)	Avaliar distúrbios de humor e cognição em idosos via IA Afetiva.	Identificação de biomarcadores em voz e face para prever a gravidade da depressão.
3	Deep learning framework for subject-independent emotion detection using wireless signals	Khan AN, Ihalage AA, Ma Y, Liu B, Liu Y, Hao Y. (2021)	Propor detecção de emoções via sinais de radiofrequência (RF) sem sensores no corpo.	O uso de RF superou o eletrocardiograma (ECG) em precisão, sendo ideal para ambientes inteligentes não intrusivos.
4	EMOCOV: Machine learning for emotion detection, analysis and visualization using COVID-19 tweets	Kabir MY, Madria S. (2021)	Desenvolver modelo de rede neural para classificar *tweets* da COVID-19 em 10 categorias.	Precisão de 0,89 e extração de frases explicativas; revelou adaptação emocional ao longo do tempo.
5	Deploying Machine Learning Techniques for Human Emotion Detection	Siam AI, Soliman NF, Algarni AD, Abd El-Samie FE, Sedik A. (2022) [5]	Implementar detecção de emoções em tempo real para visão robótica.	Desempenho superior em precisão e processamento em diversos bancos de dados (CK+, JAFFE).
6	A Comparison of Web Services for Sentiment Analysis in Digital Mental Health Interventions	Tan THB, Lim S, Qiu Y, Miao C. (2022) [6]	Comparar 18 serviços web de análise de sentimento para saúde mental.	Serviços de *Big Techs* (Google, Amazon, IBM) se destacaram, mas a escolha depende da métrica.
7	Attention-Enabled Ensemble Deep Learning Models and Their Validation for Depression Detection: A Domain Adoption Paradigm	Singh J, Singh N, Fouda MM, Saba L, Suri JS. (2023) [7]	Usar *Deep Learning* com mecanismos de atenção para detectar depressão em adultos.	A atenção combinada à aprendizagem profunda aumentou a sensibilidade e eficácia diagnóstica.
8	Predicting Psychological Distress During the COVID-19 Pandemic: Do Socioeconomic Factors Matter?	Bakkeli NZ. (2023) [8]	Prever risco de depressão na pandemia considerando fatores socioeconômicos.	*Random Forest* foi mais preciso; fatores econômicos tornaram-se cruciais na fase final da crise.
9	Textual emotion detection utilizing a transfer learning approach	Hadikhah Mozhdehi M, Eftekhari Moghadam A. (2023) [9]	Explorar *Transfer Learning* e *Deep Learning* para reconhecer emoções em textos.	O *Deep Learning* alcançou precisão significativamente maior que métodos tradicionais de aprendizado de máquina (ML).
10	Detection of emotion by text analysis using machine learning	Machová K, Szabóova M, Paralič J, Mičko J. (2023) [10]	Detectar emoções em textos para melhorar a interação humano-máquina.	Eficiência de 90% com redes neurais; superior aos modelos clássicos (SVM, *Naïve Bayes*).
11	Emotion detection for supporting depression screening	Francese R, Attanasio P. (2023) [11]	Desenvolver o aplicativo EDApp para capturar face e voz durante triagem de depressão.	Correlação positiva entre dados multimodais e escores do Inventário de Depressão de Beck (BDI-II) usando Redes Convolucionais.
12	Automatic emotion recognition in healthcare data using supervised machine learning	Azam N, Ahmad T, Ul Haq N. (2021) [12]	Desenvolver detecção automática de emoções em dados de saúde textuais.	Modelo *MultiLayer Perceptron* atingiu 87% de acurácia no conjunto de dados EmoHD.
13	Identification of Predictors of Mood Disorder Misdiagnosis and Subsequent Help-Seeking Behavior in Individuals With Depressive Symptoms	Benacek J, *et al.* (2024) [13]	Identificar fatores que contribuem para o erro de diagnóstico em transtornos de humor.	A gravidade do humor deprimido foi o preditor mais forte de erro diagnóstico.
14	Enhancing Speech Emotion Recognition Using Dual Feature Extraction Encoders	Pulatov I, Oteniyazov R, Makhmudov F, Cho YI. (2023) [14]	Propor modelo que combina MelSpec e GeMAPS para reconhecer emoções na fala.	Avanço no reconhecimento de voz usando abordagem de rede neural profunda (LSTM).

Nº	Título Original	Autores / Ano	Objetivo (Resumo)	Principais Resultados
15	Implementing machine learning techniques for continuous emotion prediction from uniformly segmented voice recordings	Diemerling H, Stresemann L, Braun T, von Oertzen T. (2024) [15]	Prever seis emoções principais em tempo real a partir de dados de voz.	Redes neurais (DNN e CNN) apresentaram desempenho comparável à precisão humana.
16	Label-less Learning for Emotion Cognition	Chen M, Hao Y. (2020) [16]	Propor o método LLEC para rotular dados emocionais sem intervenção humana.	Utiliza multimodalidade para melhorar a precisão na detecção sem necessidade de rótulos manuais.
17	LEIA: Linguistic Embeddings for the Identification of Affect	Aroyehun ST, *et al.* (2023) [17]	Estudar o afeto por meio de textos em mídias sociais e pistas digitais.	O modelo LEIA demonstrou desempenho equilibrado na identificação de emoções no Twitter.
18	Multimodal Emotion Detection via Attention-Based Fusion of Extracted Facial and Speech Features	Mamieva D, *et al.* (2023) [18]	Integrar características faciais e de fala usando um mecanismo de atenção.	Sistema multimodal eficaz utilizando redes convolucionais (CNN) e recorrentes.
19	Speech Emotion Recognition Using Attention Model	Singh J, Saheer LB, Faust O. (2023) [19]	Avaliar modelo de voz com autoatenção (CNN e LSTM).	Houve dificuldade em distinguir emoções semelhantes, como tristeza/neutralidade e medo/surpresa.
20	Transformer transfer learning emotion detection model: synchronizing socially agreed and self-reported emotions	Lee SJ, Lim J, Paas L, Ahn HS. (2023) [20]	Treinar sistema em duas etapas usando o modelo RoBERTa-large.	Desempenho forte na detecção de 6 emoções em *tweets* utilizando aprendizado de transferência.
21	Determination of Patient Sentiment and Emotion in Ophthalmology: Infoveillance Tutorial	Nguyen AX, Trinh XV, Wang SY, Wu AY. (2021) [21]	Analisar sentimentos em textos de fóruns de saúde baseados na web.	Medição eficaz de emoções de médicos e pacientes em fóruns como o MedHelp.
22	Linguistic based emotion analysis using softmax over time attention mechanism	Roshan M, *et al.* (2024) [22]	Capturar sinais de voz e processar paralelamente o tipo de emoção e a conversão em texto.	Desenvolvimento de modelo com mecanismo de atenção modificado (*softmax* ao longo do tempo).
23	Predicting persistent depressive symptoms in older adults: A machine learning approach	Hatton CM, *et al.* (2019) [23]	Investigar a utilidade da IA para prever a persistência da depressão em idosos.	Abordagem eficaz na previsão de sintomas persistentes após 12 meses (*Dataset* CASPER).

Fonte: Elaborado pelos autores (2026).

Um ponto central na discussão é a capacidade da IA de processar diferentes tipos de sinais biológicos e comportamentais. Enquanto alguns estudos focam na análise linguística em redes sociais e fóruns de saúde para identificar o afeto e sentimentos de pacientes, outros exploram a acústica vocal. A utilização de redes neurais profundas, como LSTM e CNN, permitiu que a predição de emoções a partir da voz alcançasse um desempenho comparável à precisão humana. No entanto, a literatura também aponta desafios técnicos: modelos baseados em autoatenção ainda encontram dificuldades para distinguir emoções com espectrogramas semelhantes, como a neutralidade e a tristeza.

Além da precisão técnica, os resultados sublinham o potencial clínico dessas ferramentas. A IA tem se mostrado capaz de identificar preditores de erro de diagnóstico (*misdiagnosis*) em transtornos de humor, revelando que a gravidade dos sintomas depressivos é um fator crítico que pode levar a avaliações clínicas equivocadas. Outro avanço notável é a capacidade de predição de longo prazo, em que algoritmos de aprendizado de máquina conseguiram prever a persistência de sintomas depressivos em idosos com um horizonte de 12 meses, oferecendo uma via para o cuidado personalizado e preventivo.

Por fim, observa-se uma tendência para a automação do aprendizado. O surgimento de métodos como o LLEC propõe a rotulagem de dados emocionais sem intervenção humana, utilizando a multimodalidade para superar a barreira da escassez de dados rotulados. Isso, somado ao uso de modelos de linguagem de grande escala, como o RoBERTa, indica que a sincronização entre emoções autorrelatadas e observadas socialmente está se tornando cada vez mais refinada.

5 CONCLUSÃO

Os estudos apresentados permitem concluir que a integração da Inteligência Artificial na detecção de emoções representa uma mudança de paradigma na saúde mental contemporânea. A transição para modelos de transformadores e mecanismos de atenção tem permitido uma compreensão mais profunda e granular dos estados afetivos humanos a partir de textos, voz e expressões faciais. A evidência sugere que estas tecnologias não apenas otimizam a triagem e o monitoramento em tempo real, alcançando resultados comparáveis aos de especialistas humanos em tarefas

específicas de reconhecimento de voz, mas também oferecem ferramentas cruciais para reduzir o atraso na busca por ajuda e mitigar erros diagnósticos. Apesar dos sucessos, a área ainda enfrenta o desafio de aprimorar a distinção entre nuances emocionais sutis. Contudo, o desenvolvimento de sistemas multimodais e de aprendizado por transferência aponta para um futuro em que a IA servirá como um suporte de decisão clínica robusto, capaz de prever trajetórias de doenças mentais e personalizar intervenções terapêuticas, especialmente em populações vulneráveis como os idosos. Em suma, a IA estabelece-se como um pilar fundamental para uma infovigilância ética e eficaz, promovendo uma saúde mental mais preditiva e acessível. Conclui-se, ainda, com base nos artigos investigados, o período de busca, os critérios de inclusão e exclusão estabelecidos, que não foram encontradas soluções digitais utilizando IA para detecção e análise de sentimentos nos serviços e sistemas de saúde, sobretudo depressão em pessoas idosas, que demonstrassem um apoio ao cuidado deste público, mas apenas soluções isoladas dentro de um contexto específico.

Contribuição dos autores. Os autores contribuíram igualmente em todas as etapas de construção do artigo: concepção e delineamento do estudo; coleta, análise e interpretação dos dados; redação e revisão crítica do manuscrito; e aprovação da versão final.

Agradecimentos. Agradecemos ao Polo IFCE-Embrapii e às empresas Bureau Tecnologia e Energy Telecom, patrocinadores deste projeto. E ainda ao grupo de pesquisadores do LARIISA da Fiocruz/CE e ao Instituto Federal do Ceará pela relevante colaboração multiprofissional.

Financiamento. Este trabalho recebeu apoio do Polo IFCE-Embrapii e das empresas Bureau Tecnologia e Energy Telecom, patrocinadores do projeto.

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

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

Declaração de uso de IA. Neste trabalho, foram utilizadas ferramentas de Inteligência Artificial, como o ChatGPT, para o apoio complementar ao processo de desenvolvimento científico, especialmente para auxílio na redação e revisão textual, visando maior clareza, correção gramatical e adequação do estilo acadêmico. Também foi admitido o uso de IA, especialmente o NotebookLM, para auxiliar na síntese de informações previamente produzidas pelos próprios autores, bem como no apoio à análise exploratória de dados, metodologicamente justificado e sem comprometer a interpretação crítica, a originalidade e a responsabilidade intelectual dos autores sobre o conteúdo final do trabalho. Além disso, essas ferramentas puderam ser utilizadas na organização e estruturação do manuscrito, contribuindo para a melhor disposição das seções e coerência do conteúdo apresentado. O ChatGPT foi ainda utilizado para realizar a tradução do resumo e organizar as referências.

REFERÊNCIAS

1. Imran AS, Daudpota SM, Kastrati Z, Batra R. Cross-Cultural Polarity and Emotion Detection Using Sentiment Analysis and Deep Learning on COVID-19 Related Tweets. IEEE Access. 2020;8:181074-90. doi: https://doi.org/10.1109/ACCESS.2020.3027350
2. Smith E, Storch EA, Vahia I, Wong STC, Lavretsky H, Cummings JL, et al. Affective Computing for Late-Life Mood and Cognitive Disorders. Front Psychiatry. 2021;12:782183. doi: https://doi.org/10.3389/fpsyt.2021.782183
3. Khan AN, Ihalage AA, Ma Y, Liu B, Liu Y, Hao Y. Deep learning framework for subject-independent emotion detection using wireless signals. PLoS One. 2021;16(2):e0242946. doi: https://doi.org/10.1371/journal.pone.0242946
4. Kabir MY, Madria S. EMOCOV: Machine learning for emotion detection, analysis and visualization using COVID-19 tweets. Online Soc Netw Media. 2021;23:100135. doi: https://doi.org/10.1016/j.osnem.2021.100135
5. Siam AI, Soliman NF, Algarni AD, Abd El-Samie FE, Sedik A. Deploying Machine Learning Techniques for Human Emotion Detection. Comput Intell Neurosci. 2022;2022:8032673. doi: https://doi.org/10.1155/2022/8032673
6. Tan THB, Lim S, Qiu Y, Miao C. A Comparison of Web Services for Sentiment Analysis in Digital Mental Health Interventions. In: Lecture Notes in Computer Science. Cham: Springer International Publishing; 2022. p. 389-407. doi: https://doi.org/10.1007/978-3-031-05061-9_28
7. Singh J, Singh N, Fouda MM, Saba L, Suri JS. Attention-Enabled Ensemble Deep Learning Models and Their Validation for Depression Detection: A Domain Adoption Paradigm. Diagnostics (Basel). 2023;13(12):2092. doi: https://doi.org/10.3390/diagnostics13122092
8. Bakkeli NZ. Predicting Psychological Distress During the COVID-19 Pandemic: Do Socioeconomic Factors Matter? Social Science Computer Review. 2023;41(4):1227-51. doi: https://doi.org/10.1177/08944393211069622
9. Hadikhah Mozhdehi M, Eftekhari Moghadam A. Textual emotion detection utilizing a transfer learning approach. J Supercomput. 2023:1-15. doi: https://doi.org/10.1007/s11227-023-05168-5
10. Machová K, Szabóova M, Paralič J, Mičko J. Detection of emotion by text analysis using machine learning. Front Psychol. 2023;14:1190326. doi: https://doi.org/10.3389/fpsyg.2023.1190326
11. Francese R, Attanasio P. Emotion detection for supporting depression screening. Multimed Tools Appl. 2023;82(9):12771-95. doi: https://doi.org/10.1007/s11042-022-14290-0
12. Azam N, Ahmad T, Ul Haq N. Automatic emotion recognition in healthcare data using supervised machine learning. PeerJ Comput Sci. 2021;7:e751. doi: https://doi.org/10.7717/peerj-cs.751

13. Benacek J, Lawal N, Ong T, Tomasik J, Martin-Key NA, Funnell EL, et al. Identification of Predictors of Mood Disorder Misdiagnosis and Subsequent Help-Seeking Behavior in Individuals With Depressive Symptoms: Gradient-Boosted Tree Machine Learning Approach. JMIR Ment Health. 2024;11:e50738. doi: https://doi.org/10.2196/50738

14. Pulatov I, Oteniyazov R, Makhmudov F, Cho YI. Enhancing Speech Emotion Recognition Using Dual Feature Extraction Encoders. Sensors (Basel). 2023;23(14):6640. doi: https://doi.org/10.3390/s23146640

15. Diemerling H, Stresemann L, Braun T, von Oertzen T. Implementing machine learning techniques for continuous emotion prediction from uniformly segmented voice recordings. Front Psychol. 2024;15:1300996. doi: https://doi.org/10.3389/fpsyg.2024.1300996

16. Chen M, Hao Y. Label-less Learning for Emotion Cognition. IEEE Trans Neural Netw Learn Syst. 2020;31(7):2430-40. doi: https://doi.org/10.1109/TNNLS.2019.2929071

17. Aroyehun ST, Malik L, Metzler H, Haimerl N, Di Natale A, Garcia D. LEIA: Linguistic Embeddings for the Identification of Affect. EPJ Data Sci. 2023;12(1):52. doi: https://doi.org/10.1140/epjds/s13688-023-00427-0

18. Mamieva D, Abdusalomov AB, Kutlimuratov A, Muminov B, Whangbo TK. Multimodal Emotion Detection via Attention-Based Fusion of Extracted Facial and Speech Features. Sensors (Basel). 2023;23(12):5475. doi: https://doi.org/10.3390/s23125475

19. Singh J, Saheer LB, Faust O. Speech Emotion Recognition Using Attention Model. Int J Environ Res Public Health. 2023;20(6):5140. doi: https://doi.org/10.3390/ijerph20065140

20. Lee SJ, Lim J, Paas L, Ahn HS. Transformer transfer learning emotion detection model: synchronizing socially agreed and self-reported emotions in big data. Neural Comput Appl. 2023;35(15):10945-56. doi: https://doi.org/10.1007/s00521-023-08276-8

21. Nguyen AX, Trinh XV, Wang SY, Wu AY. Determination of Patient Sentiment and Emotion in Ophthalmology: Infoveillance Tutorial on Web-Based Health Forum Discussions. J Med Internet Res. 2021;23(5):e20803. doi: https://doi.org/10.2196/20803

22. Roshan M, Rawat M, Aryan K, Lyakso E, Mekala AM, Ruban N. Linguistic based emotion analysis using softmax over time attention mechanism. PLoS One. 2024;19(4):e0301336. doi: https://doi.org/10.1371/journal.pone.0301336

23. Hatton CM, Paton LW, McMillan D, Cussens J, Gilbody S, Tiffin PA. Predicting persistent depressive symptoms in older adults: A machine learning approach to personalised mental healthcare. J Affect Disord. 2019;246:857-60. doi: https://doi.org/10.1016/j.jad.2018.12.095

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