



UNIVERSIDADE ESTADUAL VALE DO ACARAÚ – UVA
CENTRO DE CIÊNCIAS DA SAÚDE – CCS
CURSO DE GRADUAÇÃO EM ENFERMAGEM

CAIO SAN RODRIGUES

**UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA O CUIDADO EM SAÚDE
ÀS PESSOAS COM TRANSTORNOS MENTAIS: REVISÃO DE ESCOPO**

SOBRAL – CEARÁ

2025

CAIO SAN RODRIGUES

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA O CUIDADO EM SAÚDE ÀS
PESSOAS COM TRANSTORNOS MENTAIS: REVISÃO DE ESCOPO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Enfermagem, do Centro de Ciências da Saúde, da Universidade Estadual Vale do Acaraú – UVA, Sobral/CE, como requisito parcial à obtenção do grau de Bacharel em Enfermagem.

Orientadora: Prof.^a Dra. Eliany Nazaré Oliveira.

SOBRAL – CEARÁ

2025

Dados Internacionais de Catalogação na Publicação

Universidade Estadual Vale do Acaraú

Sistema de Bibliotecas

Rodrigues, Caio San

Utilização de inteligência artificial para o cuidado em saúde às pessoas com transtornos mentais: revisão de escopo / Caio San Rodrigues. -- Sobral, 2025.

148 f. il. color.

Orientador: Prof. Ph.D. Eliany Nazaré Oliveira.

Trabalho de Conclusão de Curso - Graduação - Universidade Estadual Vale do Acaraú, Bacharelado em Enfermagem , Centro de Ciências da Saúde

1. Inteligência Artificial. 2. Saúde Mental. 3. Tecnologia em Saúde. 4. Assistência Psiquiátrica. I. Título.

CAIO SAN RODRIGUES

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA O CUIDADO EM SAÚDE ÀS
PESSOAS COM TRANSTORNOS MENTAIS: REVISÃO DE ESCOPO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Enfermagem, do Centro de Ciências da Saúde, da Universidade Estadual Vale do Acaraú – UVA, Sobral/CE, como requisito parcial à obtenção do grau de Bacharel em Enfermagem.

Orientadora: Profa. Dra. Eliany Nazaré Oliveira.

Qualificado em: 18 / 03 / 2025

BANCA EXAMINADORA:

Prof.^a Dra. Eliany Nazaré Oliveira (Orientadora)
Universidade Estadual Vale do Acaraú (UVA)

Prof.^a Dra. Maristela Inês Osawa Vasconcelos
Universidade Estadual Vale do Acaraú (UVA)



Documento assinado digitalmente

JOYCE MAZZA NUNES ARAGAO

Data: 27/03/2025 09:19:13-0300

Verifique em <https://validar.itl.gov.br>

Prof.^a Dra. Joyce Mazza Nunes Aragão
Universidade Estadual Vale do Acaraú (UVA)

Às almas inquietas, àquelas que carregam o peso
do mundo nos ombros e ainda assim seguem em
frente, dando o melhor de si em tudo que fazem.
Sei que, por trás da força, há dias de dúvida,
momentos de silêncio que ninguém escuta,
batalhas travadas na solidão da mente. Mas, sigam,
pois sua existência é farol para aqueles que ainda
buscam a luz. Vocês não estão aqui por acaso – são
a mudança que o mundo tanto precisa.

AGRADECIMENTOS

Primeiramente, aos meus pais, Pedro Ferreira Mororó e Francisca Rodrigues Mororó, por todo apoio e confiança em mim. Sou grato a vocês por não medirem esforços ao trabalharem sob muito sol, para que eu pudesse chegar aqui pela sombra. Hoje, este sonho não é apenas meu, mas nosso. Essa conquista é, acima de tudo, um reflexo do amor, da dedicação e dos valores que vocês me ensinaram. O senhor e a senhora sempre me disseram que não tiveram a oportunidade de estudar, mas que sonhavam para mim um futuro diferente, com as oportunidades que não puderam ter. O que talvez não percebam é que, muito além de qualquer diploma, vocês sempre foram os maiores exemplos que a vida poderia me dar. Se um dia eu puder ser metade das pessoas que vocês são, serei um grande homem. E, com o coração transbordando de gratidão e orgulho, posso finalmente dizer: vocês têm um filho com ensino superior. Obrigado por cuidarem de mim e terem escolhido serem meus pais.

À minha amada, Ravena Petra Mororó Ziesemer, entrego não apenas palavras, mas a essência da minha mais profunda gratidão. Seu amor inabalável é farol em meio às sombras, é o guia que me conduz quando a estrada se torna incerta. Nos seus braços, descobri o refúgio onde posso despir minha alma, revelar minhas fragilidades sem temor, pois ali habita alguém que acredita, que vibra pelo meu sucesso com uma intensidade rara e genuína. Sua presença é o sopro que acalma as tormentas, a âncora que me mantém firme, quando os ventos tentam me desviar. E teu sorriso é o sol que ilumina cada vitória, tornando cada conquista ainda mais brilhante.

À minha orientadora, Professora Eliany Nazaré Oliveira, minha mais sincera gratidão por sua dedicação e pelo seu apoio. Desde o terceiro semestre, quando me acolheu, até este momento tão significativo, compartilhamos uma jornada de cinco anos repleta de aprendizado, crescimento e experiências inesquecíveis. Agradeço não apenas pelos ensinamentos e pelas oportunidades que me proporcionou, mas também pelos momentos de leveza e descontração: as festas juninas animadas, as viagens para congressos e as confraternizações que fortaleceram nossos laços. Após tanto tempo trabalhando juntos, acredito que um pouco da sua essência permanece em cada orientando, assim como você leva consigo a essência de cada um de nós. E, como não poderia faltar, sou grato também pelos puxões de orelha ao longo dessa trajetória. São eles que nos moldam, nos fazem refletir e nos preparam para o futuro, ensinando-nos o valor do comprometimento e da dedicação na construção de nossa identidade profissional.

Aos meus companheiros de jornada, Pedro Henrique do Nascimento Costa, Ana Júlia Gomes Magalhães, Antônia Ingrid Freitas Martins Timbó, Maria Clara Basílio da Silva e Maria Isabelle Brito, pelo apoio incondicional ao longo desta jornada. Cada palavra de incentivo, cada conversa motivadora e cada momento de companheirismo fizeram toda a diferença para que eu chegasse até aqui. Vocês foram força nos momentos difíceis e alegria nos momentos de conquista.

Aos companheiros de trincheiras, José Augusto da Cunha Gomes e Francisco Barroso Caetano, agradeço pela amizade e pelo companheirismo nesse caminho trilhado. Às vezes, pego-me refletindo como conhecemos determinadas pessoas e criamos vínculos com elas, como se estivéssemos predestinados a estarmos ali, eu considero que estávamos predestinados a sermos amigos. Muito obrigado por partilharmos os momentos de estudos, aflição, descontração, certezas e incertezas. Tentar tirar um pouco de humor, não importando o quão ruim a situação esteja, é algo que nos é característico, e faz com que todas as dificuldades e obstáculos sejam sempre superados com um sorriso no rosto.

Aos meus queridos companheiros do Grupo de Estudo e Pesquisa Saúde Mental e Cuidado (GESAM) e à Liga Interdisciplinar em Saúde Mental (LISAM), que muito contribuíram na minha formação, estimulando a minha inquietação por conhecimento, criatividade, resiliência e responsabilidade.

Às professoras da minha banca, Joyce Mazza Nunes Aragão e Maristela Inês Osawa Vasconcelos, que representam o corpo docente da Enfermagem, expresse minha gratidão. É uma honra contar com profissionais de tamanha expertise acompanhando minha trajetória acadêmica. Ao longo desses anos, tive o privilégio de aprender com vocês, desde a graduação, participação na extensão até os eventos de iniciação científica. Cada orientação e ensinamento deixaram marcas profundas na minha formação, e sou imensamente grato por todo apoio e dedicação que enriqueceram minha caminhada.

Aos meus colegas de turma. Ao longo dessa jornada, muitos seguiram outros caminhos, perseguindo diferentes sonhos e destinos. Mas, aqui estamos nós, firmes, prontos para nos tornarmos enfermeiros. O percurso foi desafiador, repleto de obstáculos e momentos de aflição, mas juntos superamos cada um deles. Hoje, olho ao redor e sinto orgulho por estarmos concretizando esse objetivo lado a lado. Mais do que colegas, formamos uma família, apoiando-nos mutuamente nos dias difíceis, brigando de vez em quando e celebrando cada pequena vitória. Que essa conquista seja apenas o começo de uma trajetória brilhante para todos nós.

À nossa amada Universidade Estadual Vale do Acaraú (UVA), sei que tivemos muitos momentos de aflições, mas sou extremamente grato e orgulhoso em dizer que sou enfermeiro pela UVA. Posso afirmar que vivi essa universidade em tudo que ela poderia me oferecer, participei de monitorias, ligas acadêmicas, grupo de estudo e pesquisa, representação estudantil, organizei eventos, facilitei ciclos e minicursos, conheci outros estados por meio da iniciação científica, publiquei artigos, ganhei prêmios e fiz amizades que pretendo levar para a vida. A UVA está há mais de 50 anos mudando a realidade de muitas pessoas da região norte do Ceará, e fazer parte dessa história é algo sem igual.

“Não olhe para trás (não é para lá que você vai).”

RESUMO

A Inteligência Artificial (IA) tem revolucionado diversos campos da saúde, destacando-se como ferramenta promissora para otimização da assistência a pessoas com transtornos mentais. A crescente prevalência dessas condições tem exigido novas abordagens para diagnóstico, monitoramento e intervenção, tornando a IA aliada estratégica no aprimoramento da qualidade do cuidado em saúde mental. Assim, este estudo objetivou mapear as evidências científicas sobre a aplicação da IA como ferramenta de suporte na assistência às pessoas com transtornos mentais, analisando potencialidades, limitações e desafios éticos. Trata-se de revisão de escopo, conduzida de acordo com o método do Instituto Joanna Briggs (JBI), utilizando a estratégia *Population, Concept e Context* (PCC) para formular a questão de pesquisa. Definiu-se: P – pessoas com transtornos mentais; C – aplicação da inteligência artificial na saúde mental; C – cuidado em saúde. Tendo em vista essa estratégia, estabeleceu-se como questão norteadora: quais as evidências científicas sobre a utilização de inteligência artificial como ferramenta de cuidado em saúde às pessoas com transtornos mentais? O levantamento bibliográfico ocorreu entre junho e agosto de 2024, abrangendo bases de dados como MEDLINE, LILACS, Scopus e Web of Science, além da literatura cinza (Google Scholar, BDTD e Periódicos CAPES). A seleção dos artigos foi realizada em três etapas. Primeiramente, foram lidos os títulos e resumos, com objetivo de identificar os trabalhos alinhados à proposta da pesquisa. Em seguida, os estudos selecionados passaram por leitura integral, sendo reavaliados conforme os critérios de inclusão estabelecidos. Por fim, na última etapa, procedeu-se à sumarização das informações extraídas dos estudos incluídos, destacando aquelas que atendiam ao objetivo norteador da pesquisa. Foram analisados 960 registros iniciais, dos quais, 70 estudos foram selecionados após as etapas de triagem e avaliação de elegibilidade. A partir disso, identificou-se que a grande maioria dos trabalhos estavam em língua inglesa (n=66). Quanto aos locais em que as pesquisas foram realizadas, destacaram-se Estados Unidos (n=17), China e Canadá (n=5) e, nos Meios Virtuais (n=15), com variabilidade temporal de 2018 a 2024. Para categorização dos principais resultados, os trabalhos foram divididos nas seguintes categorias: Modelos de IA para Diagnóstico e Predição de TM (12,6%); R2 - Aplicações da IA na Saúde Mental e Suporte ao Paciente (9,1%); R3 - Preditores e Fatores de Risco para TM (11,2%); R4 - Impacto das Tecnologias Digitais e Redes Sociais (6,3%); e R5 - Intervenções Digitais e Terapias Assistidas por IA (9,8%). No que se refere às principais conclusões, os trabalhos foram categorizados e distribuídos da seguinte maneira: C1 - Modelos de IA demonstraram alta precisão para diagnóstico, predição ou suporte à saúde mental, incluindo limitações como viés algorítmico e necessidade de mais dados (29,4%); C2 - Transtornos mentais resultam de múltiplos fatores interligados, como genética, ambiente e experiências adversas (14,0%); C3 - IA mostrou potencial para terapias digitais, suporte ao paciente e detecção precoce, abordando também questões éticas e privacidade (18,2%). Desta forma, este estudo contribui para o avanço das discussões sobre o uso da inteligência artificial na saúde mental, incentivando futuras pesquisas que explorem soluções inovadoras para integrar essa tecnologia aos serviços de saúde, de forma ética, segura e humanizada. A IA, quando aplicada corretamente, pode ser ferramenta fundamental para otimizar o atendimento, reduzir a sobrecarga dos profissionais e promover assistência mais eficiente, equitativa e acessível às populações mais vulneráveis.

Palavras-chave: Inteligência Artificial; Saúde Mental; Tecnologia em Saúde; Assistência Psiquiátrica.

ABSTRACT

Artificial intelligence (AI) has revolutionized several areas of health, standing out as a promising tool for optimizing care for people with mental disorders. The increasing prevalence of these conditions has required new approaches to diagnosis, monitoring and intervention, making AI a strategic ally in improving the quality of mental health care. Thus, this study aims to map the scientific evidence on the application of AI as a support tool in the care of people with mental disorders, analyzing its potential, limitations and ethical challenges. This is a scoping review conducted according to the Joanna Briggs Institute (JBI) method, using the strategy Population, Concept and Context (PCC) to formulate the research question. The following were defined: P – people with mental disorders; C – application of artificial intelligence in mental health; C – health care. In view of this strategy, the guiding question was established: “What is the scientific evidence on the use of artificial intelligence as a health care tool for people with mental disorders?”. The bibliographic survey took place between June and August 2024, covering databases such as MEDLINE, LILACS, Scopus and Web of Science, in addition to gray literature (Google Scholar, BDTD and CAPES Journals). The selection of articles was carried out in three stages. First, the titles and abstracts were read, with the aim of identifying the works aligned with the research proposal. Then, the selected studies underwent a full reading and were reassessed according to the established inclusion criteria. Finally, in the last stage, the information extracted from the included studies was summarized, highlighting those that met the guiding objective of the research. A total of 960 initial records were analyzed, of which 70 studies were selected after the screening and eligibility assessment stages. From this, it was identified that the vast majority of the works were in English (n=66). Regarding the locations where the research was carried out, the United States (n=17), China and Canada (n=5) and in Virtual Environments (n=15) stand out, with temporal variability from 2018 to 2024. To categorize the main results, the works were divided into the following categories: “AI Models for Diagnosis and Prediction of MD (12.6%)”; “R2 - AI Applications in Mental Health and Patient Support (9.1%)”; “R3 - Predictors and Risk Factors for MD (11.2%)”; “R4 - Impact of Digital Technologies and Social Networks (6.3%)”; and “R5 - Digital Interventions and AI-Assisted Therapies (9.8%)”. Regarding the main conclusions, the works were categorized and distributed as follows: “C1 - AI models demonstrated high accuracy for diagnosis, prediction or support of mental health, including limitations such as algorithmic bias and the need for more data (29.4%)”; “C2 - Mental disorders result from multiple interconnected factors, such as genetics, environment and adverse experiences (14.0%)”; “C3 - AI showed potential for digital therapies, patient support and early detection, also addressing ethical and privacy issues (18.2%)”. Thus, this study contributes to the advancement of discussions on the use of artificial intelligence in mental health, encouraging future research that explores innovative solutions to integrate this technology into health services in an ethical, safe and humanized way. AI, when applied correctly, can be a fundamental tool to optimize care, reduce the burden on professionals and promote more efficient assistance, equitable and accessible to the most vulnerable populations.

Keywords: Artificial Intelligence; Mental Health; Health Technology; Psychiatric Care.

LISTA DE TABELAS

Tabela 1 – Distribuição dos modelos de IA mais utilizados.	73
Tabela 2 – Categorização dos resultados dos estudos selecionados.	105
Tabela 3 – Categorização das conclusões nos estudos selecionados.	116

LISTA DE QUADROS

Quadro 1 – Cruzamento final utilizados para busca nas bases de dados.	39
Quadro 2 – Distribuição dos trabalhos selecionados quanto ao título, à base de dados, ao ano, período e idioma.	45
Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.	56
Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.	78

LISTA DE FIGURAS

Figura 1 – Conjunto de palavras representativas das categorias de transtornos mentais, segundo o DSM-5-TR.....	31
Figura 2 – Imagem ilustrativa sobre IA aplicada à saúde.	34
Figura 3 – Fluxograma PRISMA-ScR descrevendo o processo de seleção dos trabalhos.	44
Figura 4 – Síntese da categorização dos principais resultados dos estudos selecionados.	104
Figura 5 – Síntese da categorização das principais conclusões dos estudos selecionados. ...	115

LISTA DE GRÁFICOS

Gráfico 1 – Distribuição das obras analisadas pelo ano de publicação, no período de 2018 a 2024.....	52
Gráfico 2 – Distribuição dos estudos, segundo o local de realização.....	54
Gráfico 3 – Categorização dos estudos, de acordo com a população participantes.	70
Gráfico 4 – Distribuição em percentuais das categorias dos resultados nos estudos selecionados.	105
Gráfico 5 – Distribuição das categorias das conclusões nos estudos selecionados.	117

LISTA DE ABREVIATURAS E SIGLAS

APS	Atenção Primária à Saúde
AUC	Área Sob a Curva
BPI	Bolsa de Produtividade em Pesquisa, Estímulo à Interiorização e à Inovação Tecnológica
CAPS	Centros de Atenção Psicossociais
CNN	<i>Convolutional Neural Networks</i>
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
DECS	Descritores em Ciências da Saúde
DL	<i>Deep Learning</i>
EDCA-12	Escala de Diagnóstico de Comportamento para Ansiedade e Depressão
FUNCAP	Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico
GESAM	Grupo de Estudos e Pesquisa Saúde Mental e Cuidado
IDH-M	Índice de Desenvolvimento Humano Municipal
JI	Instituto Jonna Briggs
KNN	<i>k-Nearest Neighbors</i>
LAPPSIE	Laboratório de Práticas e Pesquisas em Psicologia e Educação
LISAM	Liga Interdisciplinar em Saúde Mental
MIL	<i>Multiple Instance Learning</i>
ML	<i>Machine Learning</i>
OCDE	Organização para a Cooperação e o Desenvolvimento Econômico
OMS	Organização Mundial da Saúde
PCC	População, Conceito e Contexto
PET-Psicologia	Programa de Educação Tutorial Psicologia
PRISMA-ScR	<i>Preferred Reporting Items for Systematic reviews and Meta-Analyses extension for Scoping Reviews</i>

RF	<i>Random Forest</i>
ROC	<i>Receiver Operating Characteristic</i>
ScR	<i>Scoping Review</i>
SVM	<i>Support Vector Machine</i>
TCC	Terapia Cognitivo-Comportamental
TDAH	Transtorno do Déficit de Atenção e Hiperatividade
TEPT	Transtorno de Estresse Pós-Traumático
TM	Transtornos Mentais
TMC	Transtornos Mentais Comuns
TMG	Transtornos Mentais Graves
UFC	Universidade Federal do Ceará
UTI	Unidade de Terapia Intensiva
UVA	Universidade Estadual Vale do Acaraú
XGBoost	<i>Extreme Gradient Boosting</i>

SUMÁRIO

1	INTRODUÇÃO	20
1.1	APROXIMAÇÃO COM O OBJETO DE ESTUDO	20
1.2	CONTEXTUALIZAÇÃO DO OBJETO DE ESTUDO	21
1.3	JUSTIFICATIVA E RELEVÂNCIA	24
2	OBJETIVOS.....	26
2.1	GERAL.....	26
2.2	ESPECÍFICOS	26
3	REVISÃO DE LITERATURA	27
3.1	TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO APLICADA À SAÚDE	27
3.2	CONCEITOS E CLASSIFICAÇÕES DOS TM.....	29
3.3	INTELIGÊNCIA ARTIFICIAL E OS AVANÇOS TECNOLÓGICOS EM SAÚDE MENTAL.....	31
4	METODOLOGIA	35
4.1	TIPO DE ESTUDO.....	35
4.1.1	ETAPAS DA APLICAÇÃO.....	35
4.1.2	POTENCIALIDADES E LIMITAÇÕES.....	36
4.2	PROCEDIMENTO METODOLÓGICOS	37
4.2.1	Etapa 1 - identificar a questão de pesquisa	37
4.2.2	Etapa 2 - identificar os estudos relevantes.....	38
4.2.3	Etapa 3 – selecionar os estudos	40
4.2.4	Etapa 4 – extração dos dados.....	41
4.2.5	Etapa 5 – mapear os dados.....	41
4.2.6	Etapa 6 – apresentação dos resultados	42
4.3	ASPECTOS ÉTICOS	42
5	RESULTADOS E DISCUSSÃO	43
5.1	ORGANIZAÇÃO, ANÁLISE E INTERPRETAÇÃO DOS DADOS	45
5.2	MODELOS DE IA PARA DIAGNÓSTICO E PREDIÇÃO DE TM	106
5.2.1	Aplicações e interpretação dos modelos	107
5.3	APLICAÇÕES DA IA NA SAÚDE MENTAL E NO SUPORTE AO PACIENTE	108

5.3.1	Plataformas digitais e <i>chatbots</i> terapêuticos.....	108
5.3.2	Monitoramento remoto e predição de episódios psiquiátricos	109
5.4	PREDITORES E FATORES DE RISCO PARA TM.....	110
5.4.1	Fatores biológicos e clínicos	110
5.4.2	Fatores psicossociais e ambientais	111
5.5	IMPACTO DAS TECNOLOGIAS DIGITAIS E REDES SOCIAIS	112
5.6	INTERVENÇÕES DIGITAIS E TERAPIAS ASSISTIDAS POR IA	113
5.7	MODELOS DE IA DEMONSTRARAM ALTA PRECISÃO PARA DIAGNÓSTICO, PREDIÇÃO OU SUPORTE À SAÚDE MENTAL, INCLUINDO LIMITAÇÕES COMO VIÉS ALGORÍTMICO E NECESSIDADE DE MAIS DADOS	117
5.8	TRANSTORNOS MENTAIS RESULTAM DE MÚLTIPLOS FATORES INTERLIGADOS, COMO GENÉTICA, AMBIENTE E EXPERIÊNCIAS ADVERSAS.	119
5.9	IA MOSTROU POTENCIAL PARA TERAPIAS DIGITAIS, SUPORTE AO PACIENTE E DETECÇÃO PRECOCE, ABORDANDO TAMBÉM QUESTÕES ÉTICAS E PRIVACIDADE.....	121
6	CONCLUSÃO	123
	REFERÊNCIAS.....	125
	APÊNDICES	144
	ANEXOS	146

1 INTRODUÇÃO

1.1 APROXIMAÇÃO COM O OBJETO DE ESTUDO

A aproximação com o objeto de estudo ocorreu logo nos primeiros semestres da graduação, mais precisamente no terceiro semestre, ao ser selecionado no processo seletivo da Liga Interdisciplinar em Saúde Mental (LISAM), da Universidade Estadual Vale do Acaraú (UVA). Contudo, esse sentimento de ter conquistado espaço em uma Liga tão importante foi sobreposto pela alta disseminação do Novo Coronavírus (Covid-19) e, conseqüentemente, o fechamento dos setores de atividades não essenciais.

Como boa parte das pessoas, também esperava que essa medida tivesse duração de, no máximo, dois meses e que tudo pudesse voltar ao normal logo depois. Ainda tínhamos muito a desempenhar na LISAM, principalmente com a vontade de ir a campo, conhecer e aprender nos serviços de saúde mental, participar dos ciclos teóricos e interagir com os novos integrantes. Mas, esse contato presencial não foi possível, e o que se esperava que fossem dois meses, acabou por ser cerca de dois anos, mudando completamente as atividades econômicas, políticas, sociais e científicas a nível mundial.

Mesmo como todo esse cenário desanimador, a LISAM não parou, pelo contrário, vimos o período de isolamento social e todas as conseqüências como algo altamente agressivo ao bem-estar populacional. A partir de então, veio um super projeto, o Vida em Quarentena, que contou com parceria do Laboratório de Práticas e Pesquisas em Psicologia e Educação (LAPPSIE) e o Programa de Educação Tutorial – Psicologia (PET-Psicologia), ambos do curso de Psicologia da Universidade Federal do Ceará (UFC).

A experiência com o Projeto Vida em Quarentena proporcionou também oportunidade de ingressar no universo da pesquisa científica, entrei no Grupo de Estudo e Pesquisa Saúde Mental e Cuidado (GESAM-UVA) como bolsista voluntário e, posteriormente, fui bolsista substituto em uma das bolsas do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Ao final do ano, a contemplação da bolsa de Produtividade em Pesquisa, Estímulo à Interiorização e à Inovação Tecnológica (BPI), da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP). Este foi um grande projeto que nos rendeu muitas produções científicas, apresentações, participação em eventos e trabalhos premiados.

Concomitantemente a isso, no meu segundo ano de LISAM, assumi a presidência da Liga. Esta foi uma das experiências mais desafiadoras e, ao mesmo tempo, gratificante na minha trajetória acadêmica. Durante esse período e, em razão do protagonismo estudantil ser base muito forte dentro da LISAM, adquiri bastante experiência em gestão de pessoas e conflitos, na estrutural organizacional e burocrática dos projetos de extensão e, principalmente, no trabalho em equipe. Ao final de cerca de dois anos e meio, finalizei minha passagem na LISAM como integrante e continuei com minhas atividades enquanto bolsista no GESAM, prestando apoio à Liga, sempre que solicitado.

No final de 2022, o GESAM foi contemplado com mais uma bolsa BPI, e sigo como bolsista na pesquisa sobre saúde mental e discriminação nas universidades.

Quanto ao uso de tecnologias, sempre foi algo do meu interesse, seja na época de infância e adolescência, nos campeonatos de videogames com os amigos, até a graduação, com apoio ao jogo interativo sobre redução de danos, suicídio e drogas, o SerTão Bom; idealização e concepção de um programa de *podcast* da LISAM, o Lisamcast; bem como auxílio no desenvolvimento do aplicativo móvel de apoio em saúde mental, o Aconchego. Assim, a crescente discussão sobre a inteligência artificial foi algo que chamou atenção, ainda mais por usá-las no dia a dia. Por isso, tive a ideia de buscar, na literatura científica, como essas ferramentas estão sendo empregadas na área da saúde, especificamente, quanto aos cuidados de saúde mental.

1.2 CONTEXTUALIZAÇÃO DO OBJETO DE ESTUDO

A interação entre saúde e doença é compreendida de forma processual e está intrinsecamente vinculada às particularidades e complexidades da existência humana, caracterizando-se pela essência dinâmica, contraditória e dialética (Dourado Júnior *et al.*, 2023). Neste sentido, ao se analisarem esses fenômenos de forma isolada, é notável o caráter deficitário, no que se refere à assistência em saúde (Oviedo; Delgado; Licon, 2020). Logo, associar holisticamente a existência humana a culturas, trajetórias, atores sociais, crenças espirituais e subjetividades, de modo geral, é de suma importância, ao proporcionar cuidado em saúde (Roche, 2020).

À vista disso, a saúde mental se apresenta com um dos campos da saúde que está intimamente associada à necessidade de sensibilidade pelos profissionais e capacidade de

análise das vulnerabilidades e potencialidades dos sujeitos (Leiva-Peña; Rubí-González; Vicente-Parada, 2021). Essa abordagem tem possibilitado transformações na maneira de planejamento e intervenção na saúde das populações, por intermédio da incorporação dos determinantes em saúde ao fator biológico, potencializando ações de promoção, prevenção e tratamento dos indivíduos (Porter, 2020).

Desse modo, a saúde mental tem, gradativamente, ganhado enfoque mundial, tendo em vista a maior incidência de Transtornos Mentais (TM). Os TM implicam comprometimento psicológico e cognitivo, ocasionando comportamentos atípicos aos habituais (APA, 2013). Esta condição pode se originar de fatores genéticos, biológicos, psicológicos e ambientais, os quais afetam o comportamento e se manifestam pela desorganização psíquica e emocional, repercutindo sistematicamente sobre as atividades diárias de vida (APA, 2013).

Essa conjuntura pode ocorrer a qualquer pessoa, independentemente de idade, produzindo perdas significativas e permanentes no desempenho funcional e mental dos sujeitos (Pires *et al.*, 2023). Assim, os obstáculos sociais são consideráveis, as consequências deletérias aos pacientes e familiares constantemente acarretam exclusão social da pessoa com TM. Esse tipo de discriminação também reverbera de forma prejudicial sobre a participação ocupacional de pessoas que enfrentam o adoecimento psíquico, mesmo quando a capacidade para trabalhar se mantém preservada (Murney *et al.*, 2020).

Conforme esses aspectos, a Lei da Reforma Psiquiátrica no Brasil emerge como ponto essencial para reformulação da atenção psicossocial no país, ao se combater o modelo manicomial e implementar atividades para o tratamento e a reinserção social de pessoas com TM e em uso de álcool e outras drogas (Brasil, 2001). O estabelecimento desse novo cenário político ligado à saúde mental preconizou uma rede de serviços de atenção psicossociais, integrada pelos Centros de Atenção Psicossociais (CAPS) (Mezza; De Torrenté, 2021).

Por conseguinte, o CAPS tem como principal atribuição a reinserção sociocultural de usuários, proporcionando interatividade com os próprios profissionais, estimulando a autonomia do cuidado, busca de objetivos de vida e apoio pelos familiares. O acompanhamento no CAPS envolve, além das orientações e do acompanhamento sobre o uso de medicações, atividades com abordagem grupal e oficinas terapêuticas, psicoterapia individual e práticas de atividades física, artísticas e comunitárias (Brasil, 2004).

Nesse sentido, a reforma psiquiátrica proporcionou nova perspectiva no acompanhamento de pessoas com TM, ressignificando o modelo de assistência e oportunizando avanços no cuidado em saúde de forma geral (De Rossi *et al.*, 2023).

Contudo, as barreiras geográficas ainda são obstáculos que impedem parcela considerável da população de ter acesso a serviços da atenção primária e especializada, dificultando o acompanhamento e o atendimento das necessidades em saúde desses usuários (Oliveira do Ó *et al.*, 2022). Neste cenário, o conceito de telessaúde tem se consolidado e conquistado espaço como meio alternativo de promover saúde e superar as limitações geográficas.

Em vista disso, a OMS define a telessaúde como a disponibilidade completa dos serviços e informações referentes à saúde, por meio de Tecnologias da Informação e Comunicação (TICS), em contextos em que a distância é um componente crítico. Assim, a utilização das TICs para assistência em saúde é um instrumento formidável para potencializar a abrangência de pessoas e localidades, em particular nas áreas cujo acesso é mais restrito (Castro *et al.*, 2020). Outrossim, as intervenções com telessaúde também podem ser empregadas como ferramentas para promoção do acesso equitativo à saúde, tendo-se em consideração a atuação nas mais multifacetadas vertentes, como, cuidados primários, atendimentos remotos, gestão, educação, pesquisa, entre outros (Reis *et al.*, 2021).

Dentre as inúmeras possibilidades do uso das TICS, a Inteligência Artificial (IA) surge como conjunto de técnicas e recursos promissores no suporte aos profissionais na assistência a pessoas com TM, oferecendo o potencial de aprimorar a gestão e prevenção dessas enfermidades. O aprendizado de máquina é a principal vertente da IA e se fundamenta no desenvolvimento e na aplicação de algoritmos, capazes de aprender a partir de dados, identificando padrões gerais e fornecendo informações para tomada de decisão (Fernandes; Chiavegatto Filho, 2019). A habilidade em processar grandes volumes de dados, descobrir padrões ocultos e fazer previsões tem sido relevante em diversos domínios do conhecimento. No contexto da saúde, em razão da complexidade, sensibilidade e importância dos desfechos, incluindo os relacionados aos TM, os avanços científicos têm impulsionado o crescimento dessa área e a compreensão progressiva dos desafios e das limitações para implementação prática desses algoritmos, como questões éticas e operacionais (Moreira; Salerno; Tsunoda, 2020).

Dentre as abordagens, é possível destacar o aprendizado supervisionado. Este envolve o treinamento de algoritmos com conjunto de dados previamente rotulados, ou seja, dados que contêm informações sobre as características dos pacientes e as respostas esperadas, como diagnósticos ou classificações de risco (Ludermir, 2021). Nesse tipo de aprendizado, o objetivo é que o algoritmo seja capaz de mapear os *inputs* (preditores) e atribuir um *output* correto (predição), permitindo a antecipação de novos casos e a tomada de decisão clínica embasada em evidências.

1.3 JUSTIFICATIVA E RELEVÂNCIA

A utilização de IA como ferramenta de cuidado a pessoas com TM é, cada vez mais, importante, devido às diversas vantagens e benefícios. A IA pode auxiliar no diagnóstico precoce, no acompanhamento do tratamento, na prevenção de crises e na identificação de sinais de alerta, contribuindo para melhoria da qualidade de vida dos pacientes. Além disso, a utilização de IA pode reduzir a sobrecarga dos profissionais de saúde, proporcionando atendimento mais eficiente e personalizado (Passos; Gallois, 2024).

Nos últimos anos, os dados da Organização Mundial da Saúde (OMS) têm destacado aumento significativo no número de pessoas em todo o mundo que enfrentam transtornos de saúde mental. Aproximadamente, um, em cada quatro indivíduos, é afetado por esses problemas em algum momento de suas vidas (OMS, 2013). O relatório de 2017 da OMS (OMS, 2017) indica aumento de 18% nos casos de depressão entre 2005 e 2015, totalizando 322 milhões de pessoas afetadas globalmente, com predominância entre mulheres. Prevê-se que até 2030, a depressão se torne a principal causa de incapacidade em todo o mundo. Outro transtorno de grande impacto, afetando 264 milhões de pessoas globalmente, é a ansiedade, caracterizada por sentimentos de medo, pânico e ansiedade social, entre outros. O transtorno bipolar atinge cerca de 60 milhões de indivíduos e, muitas vezes, é confundido com casos de depressão ou ansiedade. Na forma mais grave, esses transtornos podem acarretar suicídio.

Apesar da preocupante estatística, muitas pessoas que enfrentam distúrbios mentais não têm acesso a tratamento adequado. Segundo a OMS, a cada quatro pessoas, apenas uma recebe algum tipo de tratamento, e, em países em que há escassez de psiquiatras, com menos de um profissional para cada 100 mil pessoas, essa situação se agrava (OMS, 2017). Além disso, os sistemas de saúde não estão conseguindo lidar de maneira eficaz com os TM. Em países de baixa e média renda, entre 76% e 85% das pessoas com esses transtornos não recebem tratamento adequado, enquanto em países de alta renda, essa porcentagem varia de 35% a 50% (OMS, 2017).

Esses dados evidenciam a grande disparidade existente no acesso ao tratamento de TM em diferentes países, refletindo as desigualdades sociais e econômicas presentes no mundo. Enquanto em países de alta renda, parcela significativa da população consegue ter acesso a um tratamento adequado para os TM, em países de baixa e média renda, a grande maioria das pessoas fica desassistida, aumentando, assim, o sofrimento e o impacto negativo dessas condições na vida desses indivíduos. Isso levanta questionamentos sobre a justiça social e a

garantia de direitos básicos, como a saúde mental, em diferentes partes do planeta. O acesso a tratamentos adequados para TM não deveria ser um privilégio de alguns, mas um direito de todos, independentemente da condição socioeconômica.

De acordo o último relatório da OMS, o Brasil é o líder na América Latina em termos absolutos e relativos de pessoas que sofrem de depressão (OMS, 2022). Atualmente, mais de 300 milhões de indivíduos em todo o mundo enfrentam essa condição, sendo mais prevalente em mulheres (5,1%) do que em homens (3,6%). O Brasil, junto com a Ucrânia, a Austrália e os Estados Unidos, apresenta uma das maiores taxas de depressão populacional, com 5,9% do total (cerca de 11,5 milhões de pessoas) (OMS, 2022). Dados do Centro de Valorização da Vida (CVV), organização brasileira sem fins lucrativos que oferece suporte telefônico a pessoas com ideações suicidas, revelam que há um caso registrado a cada 43 minutos (CVV, 2022). A OMS alerta que, aproximadamente, 800 mil indivíduos morrem anualmente, devido a essas condições, sendo a segunda principal causa de morte na população brasileira entre 15 e 29 anos (OMS, 2022).

Essas informações trazem à tona realidade preocupante sobre a saúde mental da população em diversos países, incluindo o Brasil. A depressão é uma doença que afeta milhões de pessoas ao redor do mundo, impactando não apenas o indivíduo que sofre, como também família, trabalho e qualidade de vida, de maneira geral.

Esse cenário epidemiológico demonstra que as necessidades em saúde mental crescem de forma exponencial, o que repercute sobre a assistência prestada e a presença de grandes demandas para os serviços de saúde mental. Desta forma, a IA surge como meio alternativo para auxiliar os profissionais de saúde na otimização do cuidado, proporcionando maior agilidade para aplicação de escalas, sistematização de condutas, identificação de padrões clínicos, entre outros fatores.

Logo, este trabalho se justifica por buscar na literatura cinza e científica como aplicação de IA estar ocorrendo por parte dos profissionais e serviços, viabilizando perspectiva geral sobre essas ferramentas. Além disso, pode-se salientar também que, ao buscar mapear as estruturas de *software*, será possível a categorização dessas estruturas tecnológicas. Destarte, ao sistematizar as potencialidades e limitações do uso de IA no cuidado em saúde mental, será possível também traçar até que ponto essa ferramenta pode se caracterizar como instrumento de fomento e das vulnerabilidades da aplicação.

A partir desse panorama, teve-se a questão norteadora: **quais as evidências científicas sobre a utilização de inteligência artificial como ferramenta de cuidado em saúde às pessoas com transtornos mentais?**

2 OBJETIVOS

2.1 GERAL

Mapear as evidências científicas sobre a utilização de inteligência artificial como ferramenta de cuidado em saúde às pessoas com transtornos mentais.

2.2 ESPECÍFICOS

- Descrever os métodos e as abordagens utilizados na literatura cinza e científica sobre a aplicação de inteligência artificial no campo dos transtornos mentais;
- Avaliar a eficácia das ferramentas de inteligência artificial utilizadas no cuidado a pessoas com transtornos mentais;
- Sistematizar as potencialidades e limitações enfrentadas na implementação da inteligência artificial no cuidado em saúde às pessoas com transtornos mentais;
- Identificar as principais tendências, controvérsias e lacunas para direcionar futuras investigações.

3 REVISÃO DA LITERATURA

3.1 TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO APLICADA À SAÚDE

A utilização de TICS possui potencialidades consideráveis para implementação de ações em saúde, desde a prevenção até a disponibilização de respostas imediatas e eficazes de acompanhamento e provisão de *feedback*, interligando as possibilidades de melhorias com as alterações necessárias para melhor cuidado aos usuários dos serviços (Lee; Yi; Lee, 2024).

Somado a isso, salienta-se que a inserção de TICS também viabiliza a organização dos serviços de saúde, ao produzir e prestar novas maneiras de assistência, tem como entendimento que a digitalização é um processo organizacional e cultural, e não somente um processo técnico (Ricciardi *et al.*, 2019). Para Krasuska *et al.* (2020), é necessário que todos os ecossistemas integrem os recursos digitais, bem como forneçam cuidados assertivos de alto nível de qualidade centrados nos usuários.

Ademais, Downes, Horigan e Teixeira (2019) compreendem que a inovação das ferramentas digitais ampliou as alternativas para os pacientes interessados em se envolver ativamente no processo de saúde, ao aprimorar os resultados produzidos, reduzir os custos e melhorar as experiências com serviços e profissionais da saúde. Neste sentido, a concepção de interfaces que avaliem novos processos implementados, por meio dos sistemas de informação e comunicação em saúde, é fundamental para identificação de métricas dos dados analisados, associados à geração de informações que oportunizem orientação na gestão e no gerenciamento da saúde.

O surgimento da pandemia da Covid-19 e a consequente crise sanitária a nível global evidenciaram a necessidade da implementação de tecnologias inovadoras que possibilitassem maior agilidade e eficiência na resolução das intercorrências multidimensionais, mas, principalmente, que atendessem às demandas críticas em saúde (Rosenberg; Antunes, 2024).

Além disso, o estudo de Helou *et al.* (2022) buscou avaliar as experiências dos usuários no uso de aplicativo contendo informações pertinentes para profissionais de saúde em hospitais, durante a pandemia da Covid-19. De acordo com os achados dos autores, os profissionais utilizaram o aplicativo, principalmente para acessar a política hospitalar relacionada às informações de condutas de procedimentos da Covid-19, com também destacam a verificação rápida de informações, seja em trânsito ou em reuniões.

Nesse mesmo contexto pandêmico, o trabalho de De Salles Neto *et al.* (2020) apresenta ferramenta digital para previsão de leitos de Unidades de Terapia Intensiva (UTI), no contexto da pandemia da Covid-19. Conforme apontado no estudo, o aplicativo proporcionou a visualização e o monitoramento das informações dos pacientes que estavam internados em UTI, devido à Covid-19, contribuindo para gestão dos leitos. Somado a isso, o aplicativo ainda promove a simulação de diferentes panoramas de alocação dos pacientes (De Salles Neto *et al.*, 2020).

No âmbito da Atenção Primária à Saúde (APS), a série histórica realizada por Bender *et al.* (2024) a respeito da evolução da disponibilidade de TICS, na APS, de 2012 a 2018, indicou que a disponibilidade do conjunto de equipamentos evoluiu de 9,4%, em 2012, para 17,5%, em 2018, sendo os maiores percentuais provenientes das Regiões Sul e Sudeste, para municípios com densidade populacional de até 10 mil hab.², maior cobertura de saúde da família e Índice de Desenvolvimento Humano Municipal (IDH-M) alto ou muito alto. O acesso à internet foi outro destaque realizado pelos autores, com evolução de 45,2%, em 2012, para 74,0%, em 2018, tendo a Região Nordeste os maiores índices – de 19,1% (2012) para 58,8% (2018).

Por conseguinte, Stephanie e Sharma (2020) definiram três objetivos principais das TICS: a) contribuir para o desenvolvimento da sensibilidade em relação à evolução da saúde digital; b) apoiar a aquisição de um vocabulário essencial em saúde digital; e c) analisar as mudanças de paradigma, comparando modelos anteriores com os atuais, demonstrando interesse em acompanhar a evolução e o desenvolvimento da saúde digital dentro dos sistemas.

A utilização de TICS e a necessidade transformação e adaptação dos serviços sanitários demonstram que esses aspectos ganharam destaque de forma gradativa, tanto ao abranger processos organizacionais nos diversos níveis de atenção à saúde. A literatura científica apresenta inúmeras pesquisas para compreensão de como a incrementação de ferramentas digitais nos serviços ofertados implica reestruturação dos sistemas de saúde (Dourado Júnior *et al.*, 2023; Suárez-Obando *et al.*, 2021). Contudo, a complexidade dos ambientes e as singularidades dos múltiplos atores e tecnologias acarreta obstáculos para o delineamento de abordagens para compreensão do atual cenário da transformação digital nos estabelecimentos de saúde.

A incorporação das TICS tem apresentado significativo potencial na implementação de ações em saúde, ofertando desde a prevenção até intervenções imediatas e eficazes no acompanhamento e na integração. As TICS auxiliam na organização dos serviços de saúde, oportunizando novas formas de assistência que transcendem o aspecto técnico e abrangem o

organizacional e cultural. A integração de recursos digitais é essencial para fornecer cuidados assertivos e de alta qualidade, centrados nos usuários.

3.2 CONCEITOS E CLASSIFICAÇÕES DOS TM

O bem-estar de indivíduos, sociedades e países envolve uma série de fatores biológicos, econômicos, sociais e psicológicos. Deste modo, pode-se destacar que a saúde mental exerce importante influência em todos os aspectos que compõe uma melhor qualidade de vida à população. Contudo, problemas relacionados ao desenvolvimento e acirramento de TM representam cerca de 12% da carga global de doenças (Talão *et al.*, 2020). Um transtorno mental engloba um conjunto de sentimentos, pensamentos e comportamentos de relevância clínica, geralmente associado a mal-estar ou incapacidade. Em virtude da pluralidade de fatores considerados na classificação de um transtorno mental, torna-se difícil o delineamento definitivo de um conceito. Destarte, é importante salientar que uma doença mental implica alterações nos processos cognitivos e afetivos do desenvolvimento, manifestando-se em distúrbios no raciocínio, no comportamento, na compreensão da realidade e adaptação às condições da vida (Gomes *et al.*, 2020).

À vista disso, a terminologia e os critérios de diagnósticos de TM são definidos pelo Diagnóstico e Estatístico de Transtornos Mentais (DSM), predominantemente utilizados nos Estados Unidos, tendo a última atualização em 2022 (DSM-5-TR), em concomitância com a Classificação Internacional de Doenças da OMS, 11ª Revisão (CID-11), habitualmente usada em outros países do mundo. No Brasil, a 10ª Revisão da Classificação Internacional de Doenças (CID-10) ainda é oficialmente utilizada para o diagnóstico de transtornos mentais. No entanto, a implementação da 11ª Revisão (CID-11) está prevista para 2027 (Brasil, 2024).

Quanto ao DSM-5-TR, este apresenta 19 tipos de TM, que podem ser classificados em: 1) Transtornos neurodesenvolvimentais; 2) Espectro da esquizofrenia e outros transtornos psicóticos; 3) Transtorno bipolar e transtornos relacionados; 4) Transtornos depressivos; 5) Transtornos de ansiedade; 6) Transtorno obsessivo compulsivo e transtornos relacionados; 7) Trauma e outros transtornos relacionados com fatores de estresse; 8) Transtornos dissociativos; 9) Transtorno por sintomas somáticos e transtornos relacionados; 10) Transtornos alimentares e de ingestão de alimentos; 11) Transtornos de excreção; 12) Transtornos do sono-vigília; 13) Disfunções sexuais; 14) Disforia de gênero; 15) Transtornos do controle de impulsivos e

comportamentos perturbadores; 16) Transtornos por uso de substâncias e transtornos de dependência; 17) Transtornos neurocognitivos; 18) Transtornos de personalidade; 19) Transtornos parafílicos. Os TM também podem ser classificados quanto a sua incidência e gravidade: Transtornos Mentais Comuns (TMC); e Transtornos Mentais Graves (TMG).

Os TMC foram sistematizados por Goldberg e Huxley (1992), que os definiram como manifestação de sintomas ansiosos, depressivos e somatoformes, que não se enquadram satisfatoriamente nos critérios de diagnóstico de TM. Deste modo, as pessoas com TMC podem apresentar grande variabilidade de sintomas que abrangem queixas somáticas inespecíficas, insônia, irritabilidade, dores de cabeça, nervosismo, esquecimento, fadiga, falta de concentração, como também manifestações de sintomas ansiosos, depressivos e somatoformes (Oliveira *et al.*, 2020).

Somado a isso, a literatura científica aponta que os TMC possuem síndromes mistas em manifestação clínica, de modo que parcela considerável da população com esses transtornos apresenta simultaneamente sintomas de depressão e ansiedade, podendo também ter incidência de sintomas somáticos associados (McGinty *et al.*, 2023). Neste sentido, o conceito de TMC está associado a uma parcela da população que necessita de cuidados em saúde mental, porém não possui diagnóstico preestabelecido a partir dos manuais de diagnóstico atuais (COUTO *et al.*, 2024).

Ademais, estudos evidenciam que a Atenção Primária à Saúde (APS), por ser a porta de entrada do usuário no sistema de saúde, destaca-se por receber inúmeros casos de sofrimento mental relacionado a queixas de tristeza e/ou ansiedade, mesmo que alguns casos se manifestem de forma implícita. Essa demonstração de sintomas ansiosos, depressivos e de somatização tem grande recorrência na APS e podem ser considerados como porção de uma síndrome clínica única com três grupos ou dimensões de se sintomas que se interrelacionam, ou seja, TMC (Brasil, 2013).

Além disso, os TM também pode ser classificado quanto à gravidade. Os TMG podem ser definidos pela apresentação de grave deterioração do funcionamento mental e social do indivíduo. Essas deteriorações podem se manifestar pelas dificuldades e/ou interferências de pensamento, experiências atípicas com sons, toque ou visão, convicções estranhas ou incomuns, esforço para realizar movimentos e ações, diminuição da concentração, inaptidões cognitivas e comportamentais, entre outros fatores. É importante considerar também que essas limitações advindas com o TMG repercutem também sobre o bem-estar social e a qualidade de vida dos sujeitos, como a falta de interação social, desemprego, negligência de cuidados pessoais e sobrecarga dos cuidadores. A definição de TMG abrange transtornos esquizofrênicos,

Quanto à área da saúde, a informatização dos sistemas é um aspecto de crescente discussão global, o emprego de IA estar ocorrendo em muitos países, como forma de proporcionar soluções de aperfeiçoamento da eficiência de trabalho e da qualidade do atendimento. Com um sistema de linguagem em máquina, a IA pode ser utilizada na determinação de metas por usuários, a exemplo de prognósticos, recomendações ou decisões inerentes a ambientes virtuais e reais (OCDE, 2019).

Nesse sentido, a IA em saúde pode ser dividida em dois principais ramos: virtuais e físicos. O primeiro integra aprendizado de máquinas e algoritmos, já o outro inclui dispositivos médicos e robôs para prestação de assistência em saúde. Assim, a IA se mostra promissora na cirurgia robótica, apresentando-se como ferramenta altamente relevante no poder de decisão, tendo em vista a capacidade de analisar os cenários e entrecruzar informações em bancos de dados para escolher a técnica mais adequada à cirurgia, além de auxiliar, concomitantemente, a equipe cirúrgica em suas condutas (Ojeda *et al.*, 2024).

Quanto ao ramo virtual, existe o aprendizado de máquina (*Machine Learning* – ML) e o aprendizado profundo (*Deep Learning* – DL), derivados da neurociência, estes são embasados nos conceitos de circuitos e nas redes neuronais propostos por Donald Hebb e David Marr (Hebb, 2002; Marr; Poggio, 1979). Tratam-se de sistemas em que os computadores conseguem aprender por intermédio de modelos matemáticos que simulam atividades naturais para o cérebro humano. Com fundamentação nesse arquétipo de rede neural artificial, houve a concepção de ferramentas de ML e DL. Neste sentido, o ML utiliza de algoritmos para análise de dados, aprendizagem e, conseqüentemente, determinação ou previsão sobre determinado assunto, logo, a máquina aperfeiçoa o desempenho, conforme adquire mais dados. Já o DL é uma subseção da ML melhor otimizada, que utiliza a hierarquização das redes neurais artificiais para efetuar o processo de aprendizagem de máquina (Olczak *et al.*, 2021).

Outrossim, os países que compõem a Organização para a Cooperação e o Desenvolvimento Econômico (OCDE) estão empregando tecnologias à base de IA em serviços de saúde. Além disso, a utilidade dessas ferramentas em países de baixo e médio rendimento está sendo analisada (Castonguay *et al.*, 2024). Assim, a implementação assertiva e segura de novas tecnologias, a exemplo da IA, possui potencial considerável, para que as Nações Unidas atingiam os Objetivos de Desenvolvimento Sustentável (ONU, 2019).

Em vista desse cenário de expansão exponencial de aplicação da IA nos serviços de saúde, pode-se perceber que a saúde mental também é uma área contemplada. Segundo a análise realizada por Montag *et al.* (2024), a IA pode ser empregada em diversas áreas dentro da saúde mental, com a seguinte categorização: a) fornecimento de assistência, ao iniciar a psicoterapia,

por meio de produtos de IA generativos, a exemplo do ChatGPT; b) Otimização de questões burocráticas tanto pelos profissionais, quanto pelos pacientes; c) fornecimento de informações sobre o curso dos TM – contemplando também as bases neurobiológicas, mediante o estudo de biomarcadores digitais; e d) Concepção de medicamentos psicoterapêuticos para tratamento e cura dos distúrbios mentais.

À vista disso, o estudo realizado por Weng *et al.* (2024) desenvolveu plataforma digital de saúde mental para mudança de comportamento dos residentes em Singapura, na China. Os autores relataram que o site incentivou os usuários a explorarem a plataforma e ler os artigos publicados. Além disso, a realização de exercícios terapêuticos, por meio de um *chatbot* de IA, foi o recurso mais utilizado no site. Contudo, evidenciou-se que os *chatbots* de IA, habitualmente, são direcionados àqueles que estão bem ou apresentam apenas sintomas leves.

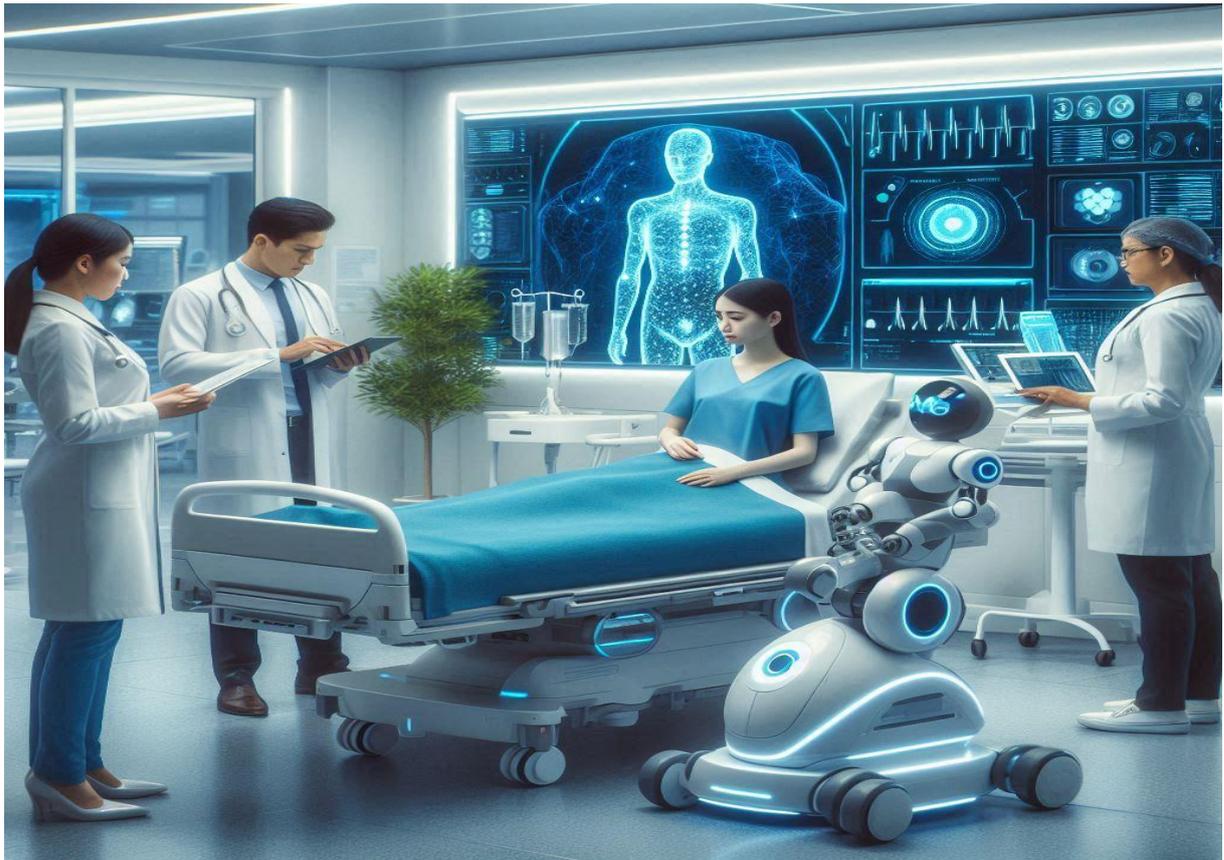
Ademais, a pesquisa de Ghadiri *et al.* (2024) sobre as percepções de médicos da APS sobre sistemas de IA no cuidado à saúde mental de adolescentes, demonstrou que esses profissionais acreditam que a IA tem o potencial de aliviar a carga clínica, potencializando a eficiência e facilitando a relação do paciente com o sistema de saúde. Somado a isso, os médicos da APS também observaram que a IA auxilia na tomada de decisões clínicas, como a escolha adequada do medicamento antidepressivo ou na triagem médica, facilitando o fluxo de pacientes e suprimindo algumas lacunas da equipe clínica.

À vista disso, após dois anos de consultas com vários profissionais previamente selecionados, a OMS lançou, em 2021, o relatório de ética e governança da IA para a saúde. Este relatório orienta e adverte quanto à superestimação dos benefícios da utilização de IA para a saúde, fundamentalmente direcionadas à cobertura universal da saúde (OMS, 2021).

Em consonância a isso, Carr (2020) destaca que a IA tem se expandido e conquistado espaço de forma exponencial, contudo, a autora ressalta que as estruturas éticas globais para IA necessitam de participação ativa dos pacientes e usuários dos serviços nessas discussões. As pessoas que recebem o cuidado em saúde mental e os cuidadores precisam ser integrados, de forma a aperfeiçoar pesquisas, interfaces e desenvolvimento desse tipo de tecnologia. Consoante a isso, Timmons *et al.* (2022) destacam que, conforme as aplicações de IA se expandem, é necessário que se assumam a responsabilidade de prevenção para utilização incorreta, em razão da IA possuir potencial considerável de proporcionar melhores cuidados em saúde mental e auxiliar as populações carentes e desfavorecidas. O autor salienta que a objetividade em captar mais dados, realizar métodos analíticos cada vez mais complexos e negligenciar as particularidades de cada indivíduo ou território, pode implicar perpetuação de preconceitos históricos e acentuamento das desigualdades existentes.

Por se tratar de questão emergente tanto nos serviços de saúde, quanto em outras áreas, a utilização de IA ainda provoca diversas discussões quanto aos quesitos éticos e sociais. Entretanto, é evidente que a literatura científica expõe cenários multifacetados para aplicação, assim como inúmeros benefícios e potencialidades que esse tipo de tecnologia pode gerar, não somente para a saúde mental, mas em perspectiva geral de assistência em saúde.

Figura 2 – Imagem ilustrativa sobre IA aplicada à saúde.



Fonte: elabora pelo autor, via IA Copilot® (2024).

4 METODOLOGIA

4.1 TIPO DE ESTUDO

Trata-se de revisão de escopo, tendo como referencial o método proposto pelo Instituto Jonna Briggs (JBI) que possibilita delinear os conceitos mais relevantes, explanar sobre áreas de pesquisa e identificar lacunas do conhecimento, a partir de etapas metodológicas (Aromataris; Munn, 2020).

Integrado à Faculdade de Saúde e Ciências Médicas da Universidade de Adelaide, Austrália, o JBI é uma organização internacional de pesquisa e desenvolvimento filantrópico. Esse centro colabora globalmente com mais de 70 entidades. Tem-se como intuito – por intermédio da identificação de práticas de saúde factíveis, pertinentes, efetivas e relevantes para o aperfeiçoamento dos resultados da saúde mundial – fomentar e respaldar a síntese, perspicuidade e implementação de evidências científicas (Jordan; Donnelly; Pittman, 2010).

Ademais, o JBI apresenta dez diferentes tipos de revisões, tendo como base as particularidades e os objetivos estipulados. Deste modo, é possível destacar que essas especificidades contemplam desde a elaboração da questão norteadora, até o desenvolvimento e a modalidade de apresentação e análise dos resultados, a exemplo da *Scoping Review* (ScR) (Aromataris; Munn, 2020).

Revisões de escopo são proficientes, no que se refere à sintetização de evidências científicas, além de utilizá-las com intuito de mapear a literatura existente em determinado contexto. Somado a isso, também podem ser adotadas para sintetizar e disseminar resultados de pesquisas. As revisões de escopo possuem ampla abordagem, com a finalidade de explorar questões de pesquisas mais vastas (Khalil *et al.*, 2022).

4.1.1 Etapas da aplicação

À vista disso, esta revisão de escopo foi estruturada metodologicamente, segundo Arksey e O'Malley (2005), com as complementações implementadas por Levac, Colquhoun e O'Brien (2010) e Peters *et al.* (2020), estudiosos do Instituto Joanna Briggs. Salienta-se, também, que

as diretrizes para relatórios foram seguidas, de acordo com o *checklist* do *Preferred Reporting Items for Systematic reviews and Meta-Analyses extension for Scoping Reviews* (PRISMA-ScR), que possui um conjunto de itens mínimos para serem incluídos em relatórios de pesquisa, com intuito de potencializar a transparência da descrição metodológica e depreender os resultados da síntese de evidências (Tricco *et al.*, 2018).

Adequando-se aos propósitos do estudo, a estrutura desta revisão consistiu em seis principais etapas consecutivas: 1) formulação da questão de pesquisa; 2) identificação de estudos; 3) seleção de estudos pertinentes; 4) extração de dados; 5) mapeamento e análise das informações; 6) apresentação dos resultados da pesquisa (Arksey; O'Malley, 2005).

A revisão de escopo contribuirá para construção de argumentos e informações sobre os desafios e as potencialidades referentes à utilização de inteligência artificial como ferramenta de cuidado em saúde às pessoas com transtornos mentais.

4.1.2 Potencialidades e limitações

A SrR tem conquistado espaço na área de síntese de evidências em saúde, com expressivo crescimento a partir de 2012 (Tricco *et al.*, 2018). Diferentemente da revisão sistemática, a revisão de escopo se destaca por ser adequada a tópicos amplos, podendo agrupar várias metodologias de estudos, com o propósito de reconhecer as evidências desenvolvidas.

Por conseguinte, a ScR pode ser utilizada para mapear conceitos-chave que subsidiam um campo de pesquisa, bem como para elucidar definições de trabalhos e os limitantes conceituais de determinada temática (Peters *et al.*, 2022). O trabalho realizado por Tricco *et al.* (2018) evidenciou que explorar a amplitude ou extensão da literatura, resumir e mapear as evidências e informar de pesquisas futuras são os três principais justificativas para produção de uma revisão de escopo. Ademais, a análise de escopo possui as seguintes indicações: a) indicar os tipos de evidências disponíveis conforme cada área; b) identificar e analisar lacunas de conhecimento; c) elucidar conceitos e definições fundamentais apresentados na literatura; d) examinar a condução de pesquisas dentro de um tópico ou campo de estudo definido; e) discernir as características essenciais ou pontos relacionados a um conceito (Munn *et al.*, 2018).

Assim, a elaboração de uma revisão de escopo não se configura, essencialmente, como a busca pela evidência mais apropriada em relação a intervenções ou experiências em saúde, mas em reunir expressivo quantitativo de evidências e apontar as formas de concepção de

maneira atingível e sucinta. Logo, não se tem como objetivo vital categorizar a solidez da evidência, mas monitorar e antecipar as potencialidades, como forma de respaldar pesquisadores da área e, na medida do possível, trabalhadores, gestores e idealizadores de políticas de saúde (Cordeiro; Soares, 2019).

4.2 PROCEDIMENTO METODOLÓGICOS

4.2.1 Etapa 1 - Identificar a questão de pesquisa

A identificação da questão de pesquisa a ser respondida é a etapa inicial que é considerada um caminho norteador que fomenta a base para as etapas subsequentes. Neste sentido, a definição clara e objetiva dos aspectos relevantes da questão é fundamental para viabilizar as ramificações das estratégias de pesquisa. Assim, é necessário que as questões de pesquisa possuam natureza ampla, de forma a fornecer cobertura mais abrangência (Arksey; O'Malley, 2005).

Para formulação da questão de pesquisa, utilizou-se da estratégia *Population, Concept e Context* (PCC), com intuito de estabelecer os elementos-chaves para uma *scoping review* (AROMATARIS; MUNN, 2020). Definiu-se assim: P – Pessoas com transtorno mentais; C – Utilização de inteligência artificial; e C – Cuidado em saúde. Com base nessas definições, estabeleceu-se a pergunta norteadora: o que se tem abordado sobre a utilização de inteligência artificial como ferramenta de cuidado em saúde às pessoas com transtornos mentais? A identificação das potencialidades e limitações, do arcabouço teórico e das pesquisas se configurara objeto de estudo desta pesquisa.

A **POPULAÇÃO** de interesse foram pessoas com transtornos mentais, atendidas nos sistemas de saúde públicos e privados.

À vista disso, os TM possuem características que podem culminar no comprometimento funcional psicológica, implicando em potenciais prejuízos nas diversas fases da vida, desde a infância, idade adulta, até o processo de envelhecimento (APA, 2013). A pessoas afetadas por esses TM, geralmente, incorporam comportamentos de risco à saúde, caracterizados pela alimentação desbalanceada, pouca ou nenhuma prática de atividade física e utilização de tabaco, álcool e/ou outras substâncias psicoativas.

Desse modo, o avanço das TICS demonstra grande potencial de incrementação no cuidado prestado a pessoas com TM, viabilizando assistência direcionada à comunicação e ao processamento de informações – tanto de modo síncrono, como assíncrono – a exemplo das teleconsultas (Correia *et al.*, 2023) e dos aplicativos de *chatboot* e autoavaliação (Vasconcelos *et al.*, 2020; Costa *et al.*, 2023), bem como jogos interativos direcionados ao cuidado em saúde mental (Viana *et al.*, 2023).

Tendo em vista que as TICS englobam grande número de ferramentas, estabeleceu-se como **CONCEITO** a aplicação de IA como ferramenta de cuidado em saúde mental. O termo IA ganhou expressividade nos últimos anos, sendo uma área da computação destinada a desenvolver algoritmos e sistemas capazes de realizar tarefas semelhantes as executadas por seres humanos. Desta forma, o aprendizado em máquina possibilita o reconhecimento de padrões, processamento de linguagem natural, tomada de decisões, entre outros.

Nessa perspectiva, a OMS entende que a IA possui potencial considerável no aprimoramento dos sistemas e serviços de saúde e para o bem-estar da população (OMS, 2021). No que se refere aos cuidados em saúde, essa ferramenta pode ser utilizada tanto para o diagnóstico de doenças, como também para o diagnóstico baseado em previsões. Assim, a IA pode ser empregada na estratificação de riscos à saúde e vulnerabilidades em potencial, no auxílio para tomadas de decisões e em tratamentos de maior complexidade, auxiliando na identificação de erros clínicos. Somado a isso, a IA também pode ser utilizada na previsão de doenças e de acometimentos de críticos em saúde (OMS, 2021).

À vista disso, o **CONTEXTO** desta revisão foi o cuidado em saúde. Entende-se como cuidado em saúde como dimensão de integralidade que tem como intuito permear as práticas em saúde, não tendo o foco direcionado para execução de competências e tarefas técnicas. Deste modo, necessita-se que o acolhimento, o estabelecimento de vínculos e a escuta das particularidades que integram os sujeitos (Correia; Teixeira; Nascimento, 2023).

A aplicabilidade da IA para assistência e nos serviços de saúde tem notável possibilidade de aprimoramento no cuidado prestado, auxiliando os profissionais a terem maior respaldo e segurança no delineamento de condutas e intervenções em saúde.

4.2.2 Etapa 2 - Identificar os estudos relevantes

Esta etapa busca a identificação dos estudos para recuperação e elaboração de estratégia de seleção de fontes de pesquisa (seleção das bases de dados), os descritores a serem

empregados, as fontes de informação, a recorte temporal e a linguagem desempenham aspectos relevantes para amplitude e compreensibilidade da pesquisa. Deste modo, as decisões necessitam ser realizadas prévia e claramente pormenorizadas, deixando evidente o percurso estabelecido e como estes influenciam na busca e nos resultados encontrados (Arksey; O'Malley, 2005).

Desse modo, o levantamento bibliográfico foi realizado de junho a agosto de 2024, nas bases de dados: *Medical Literature Analysis and Retrieval System Online/National Library of Medicine* – via PubMed, *Web of Science*, Literatura Latino-Americana e do Caribe em Ciências da Saúde - LILACS, *Scopus Preview* (SCOPUS), por intermédio da Plataforma Periódicos Capes. Posteriormente, a busca na literatura cinzenta foi realizada no *Google Acadêmico* e na Biblioteca Digital Brasileira de Teses e Dissertações (BDTD) e Periódicos CAPES.

Para adequação às particularidades das bases de dados e plataformas, utilizaram-se dos Descritores em Ciências da Saúde (DeCs) para as bases em português: "Transtornos Mentais" "Doença Mental"; "Transtornos Psiquiátricos"; "Inteligência Artificial"; "IA"; "Inteligência de Máquina"; "Saúde Mental"; "Recuperação de Saúde Mental"; "Assistência à Saúde". Para as bases que utilizam o idioma inglês, os descritores serão: "Mental Disorders"; "Mental disease"; "Psychiatric Disorders"; "Artificial Intelligence"; "IA"; "Machine Intelligence"; "Mental Health"; "Mental Health Recovery"; "Mental Health Assistance". Como forma de potencializar a estratégia de busca, realizou-se a combinação entre descritores e operadores booleanos (AND, OR), conforme orienta o JBI (Aromataris; Munn, 2020). No Quadro 1, observa-se o cruzamento final realizado em cada base de dados.

Quadro 1 – Cruzamento final utilizados para busca nas bases de dados.

Bases de Dados	Cruzamento Final
MEDLINE via Pubmed	(((((("Mental Disorders"[Mesh]) AND "Artificial Intelligence"[Mesh]) AND "Mental Health"[Mesh]) OR "Mental Health Recovery"[Mesh]))
LILACS via BVS	("Mental Disorders" OR "Mental disease" OR "Psychiatric Disorders") AND ("Artificial Intelligence" OR "IA" OR "Machine Intelligence") AND ("Mental Health" OR "Mental Health Recovery" OR "Mental Health Assistance")
Scopus	(TITLE-ABS-KEY ("Mental Disorders") OR TITLE-ABS-KEY ("Mental disease") OR TITLE-ABS-KEY ("Psychiatric Disorders") AND TITLE-ABS-KEY ("Artificial Intelligence") OR TITLE-ABS-KEY ("IA") OR TITLE-ABS-KEY ("Machine Intelligence") AND TITLE-ABS-KEY ("Mental Health") OR TITLE-ABS-KEY ("Mental Health Recovery") OR TITLE-ABS-KEY ("Mental Health Assistance")) AND (LIMIT-TO (OA , "all"))
Web of Science	TS=(Mental Disorders OR Mental disease OR Psychiatric Disorders) AND TS=(Artificial Intelligence OR IA OR Machine Intelligence) AND TS=(Mental Health OR Mental Health Recovery OR Mental Health Assistance)

Fonte: elaborado pelo autor (2024).

No que se refere aos critérios de inclusão, estabeleceram-se: estudos nos idiomas inglês, espanhol e português; com abordagem quantitativa, qualitativa e quantiquantitativa; estudos primários; revisões sistemáticas, metanálises e/ou metassínteses; e livros, publicados ou disponibilizados *on-line*. Não foi realizado nenhum recorte temporal, com intuito de atingir maior amplitude dos achados.

Como critérios de exclusão, foram considerados os estudos ou documentos não disponíveis na íntegra, assim como aqueles que, mesmo tratando da temática, não responderam à questão colocada para a revisão.

Por se tratar de uma *scoping review*, também foram selecionados os trabalhos presentes na literatura cinza. No estudo realizado por Botelho e Oliveira (2015), o qual revisou conceitualmente as expressões “literatura científica” e “literatura cinza”, foi delineado que a documentos convencionais ou formais que apresentem fácil identificação, divulgação e obtenção, produzidos dentro dos sistemas comerciais, são classificados como literatura científica. Já quanto à literatura cinza, esta é referente às publicações não comerciais, não convencionais, difíceis de serem encontradas em canais tradicionais de distribuição e necessitam de pesquisa mais acentuada para localização e recuperação (Botelho; Oliveira, 2015).

Realizou-se a consulta das referências dos estudos selecionados para leitura do texto completo (APÊNDICE A).

A sistematização das fases da busca, identificação e seleção foi representada por meio do Fluxograma PRISMA (Figura 3) (Page *et al.*, 2021).

4.2.3 Etapa 3 – Selecionar os estudos

A seleção dos artigos ocorreu em três etapas: a) inicialmente, realizou-se a leitura de título e resumo, como forma de inclusão dos estudos que respondessem ao objetivo da pesquisa; b) posteriormente, os estudos selecionados foram lidos na íntegra e, adicionalmente, as referências destes foram avaliadas, para captação e inclusão de estudos que não foram recuperados no momento da busca nas bases de dados elencadas; c) na terceira e última etapa, realizou-se a leitura completa dos artigos incluídos, no intuito de destacar e sumarizar as informações que respondessem ao objetivo da revisão (Arksey; O’Malley, 2005).

Como forma de complementar a seleção, para além da leitura de título e resumo, foi utilizado para cada estudo, na primeira etapa, um *checklist* de observação (APÊNDICE B). As ferramentas *Zotero* e *Rayyan* também foi empregada para o gerenciamento das referências.

Para a segunda etapa, verificou-se se os trabalhos selecionados atendiam aos critérios de elegibilidade, como também se respondiam ao objetivo deste estudo. Destarte, para os estudos selecionados para a terceira fase, procedeu-se à análise dos estudos potencialmente relevantes em suas referências. Salienta-se ainda que as exclusões realizadas nesta fase foram justificadas na figura do PRISMA (Aromataris; Munn, 2020).

Na terceira e última fase da revisão, na matriz de síntese da extração de dados, os estudos foram preenchidos, a partir dos trabalhos incluídos. Posteriormente, realizou-se o mapeamento dos dados, além de confrontar, resumir e relatar os resultados, como etapas subsequentes na elaboração da revisão proposta (Arksey; O'Malley, 2005).

4.2.4 Etapa 4 – Extração dos dados

Para análise e síntese dos artigos, utilizou-se de formulário sobre extração de dados (APÊNDICE B), que dispõe das informações bibliográficas básicas, características dos estudos e informações que possibilitam compreender como é a utilização de IA no cuidado em saúde às pessoas com TM. O formulário de extração foi preenchido por dois revisores, sendo que as questões e dúvidas sobre as extrações foram tratadas após a discussão com um terceiro revisor (orientador) (Arksey; O'Malley, 2005). Para cumprimento do rigor metodológico da revisão, empregou-se o PRISMA-SCR, com lista de verificação (Tricco *et al.*, 2018) (ANEXO A).

As informações coletadas na fase de extração foram armazenadas em banco de dados eletrônicos, por intermédio do programa *Microsoft Excel for Windows*®, versão 2019.

4.2.5 Etapa 5 – Mapear os dados

A etapa de extração e mapeamento das informações envolve a organização, análise e interpretação dos dados, com intuito de descrever os resultados, de acordo com o objetivo do estudo e as questões norteadoras da revisão.

4.2.6 Etapa 6 – Apresentação dos resultados

A sumarização e apresentação dos resultados devem ser executadas, de modo a evidenciar factualmente o panorama das informações recuperadas, a extensão e a natureza da literatura a respeito do tema revisado. Na revisão de escopo, os resultados foram apresentados descritivamente e por meio de quadros e gráficos que facilitem a visualização, em acordo com as orientações do protocolo PRISMA – extensão para revisão de escopo (Tricco *et al.*, 2018).

O quadro sintético contém resumo dos estudos revisados, a partir das informações contidas/resgatadas no formulário de extração de dados, caracterizando os estudos e apontando os aspectos que dificultam ou potencializam a utilização de IA para o cuidado em saúde às pessoas com TM.

Outrossim, também foi elaborada síntese narrativa dos achados referentes às recomendações e limitações dos trabalhos, com propósito de produzir informações pertinentes para pesquisas subsequentes sobre o tema.

Em conformidade com o método estabelecido pelo instituto JBI e seguindo etapas metodológicas (Aromataris; Munn, 2020), foi elaborado protocolo, com base no projeto desta revisão, o qual está registrado no sistema *Open Science Framework*, no link <https://doi.org/10.17605/OSF.IO/2RG39>.

4.3 ASPECTOS ÉTICOS

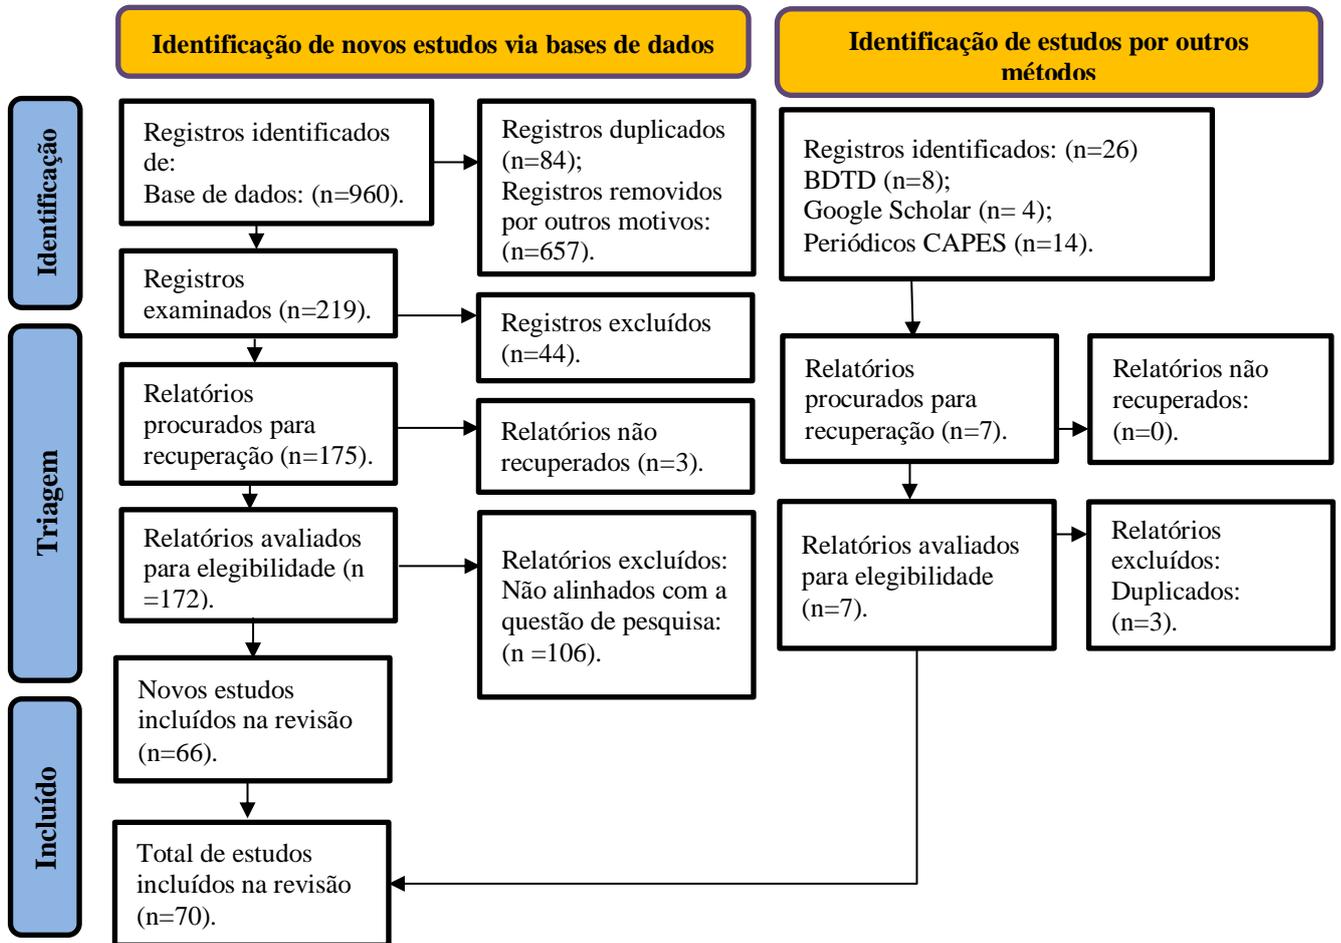
Por se tratar de estudo que se utilizou de informações bibliográficas disponíveis publicamente, não foi necessária apreciação por Comitê de Ética em Pesquisa envolvendo seres humanos. Deste modo, este estudo seguiu criteriosamente as disposições estabelecidas na Resolução n. 510 de abril de 2016, do Conselho Nacional de Saúde, a qual dispõe sobre o uso de dados disponibilizados para domínio público.

5 RESULTADOS E DISCUSSÃO

Esta seção reúne e sintetiza os resultados da revisão de escopo, fornecendo panorama do conhecimento científico e de outras fontes sobre a utilização de inteligência artificial como ferramenta de cuidado em saúde às pessoas com TM. A análise contextualiza os estudos, revelando as principais tendências e lacunas na produção de conhecimento sobre o tema.

A Figura 3 apresenta o fluxograma PRISMA-ScR, que descreve de forma detalhada o processo de seleção dos estudos incluídos na revisão de escopo sobre o uso de inteligência artificial como ferramenta de cuidado em saúde para pessoas com transtornos mentais (TM). Inicialmente, foram identificados 960 registros em bases de dados. Após a remoção de 84 registros por duplicidade e de 657 registros por outros motivos, restaram 219 registros para triagem. Desses, 44 registros foram excluídos, resultando em 175 relatórios para recuperação, dos quais 3 não foram recuperados. Assim, 172 relatórios foram avaliados quanto à elegibilidade, sendo que 106 foram excluídos por não estarem alinhados com a questão de pesquisa. Além disso, foram identificados 26 registros por outros métodos, sendo 8 na BDTD, 4 no Google Scholar e 14 nos Periódicos CAPES. Após a triagem e avaliação, 66 artigos foram incluídos na revisão, juntamente com três dissertações e uma tese, totalizando 70 estudos selecionados para compor a análise final.

Figura 3 – Fluxograma PRISMA-ScR descrevendo o processo de seleção dos trabalhos.



Fonte: Page *et al.* (2021).

5.1 ORGANIZAÇÃO, ANÁLISE E INTERPRETAÇÃO DOS DADOS

Nos quadros referentes aos resultados, a primeira coluna (Nº) segue uma sequência fixa, respeitando a ordem dos achados. Além disso, foram levantadas algumas questões que servem como guias para discussão, abordando os resultados obtidos e as problematizações possibilitadas pelo agrupamento de dados, em análise das metodologias e ferramentas presentes na literatura científica e cinza. Essa análise abrangeu os estudos identificados e o contexto do uso de IA no campo da saúde mental.

No Quadro 2, estão organizados os 70 estudos analisados, com informações como título, base de dados, ano de publicação, título do periódico, idioma e localização.

Quadro 2 – Distribuição dos trabalhos selecionados quanto ao título, à base de dados, ao ano, período e idioma. (continua)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas	Locais
1	A deep learning model for detecting mental illness from user content on social media	2020	Scientific Reports	Inglês	Meio Virtual
2	Identifying COVID-19 survivors living with post-traumatic stress disorder through machine learning on Twitter	2024	Scientific Reports	Inglês	Meio Virtual
3	International Journal of Environmental Research and Public Health	2024	International Journal of Environmental Research and Public Health	Inglês	Estados Unidos
4	Predicting Sex-Specific Nonfatal Suicide Attempt Risk Using Machine Learning and Data From Danish National Registries	2021	American Journal of Epidemiology	Inglês	Dinamarca
5	Detecting individuals with severe mental illness using artificial intelligence applied to magnetic resonance imaging	2023	eBioMedicine	Inglês	China

Quadro 2 – Distribuição dos trabalhos seleccionados quanto ao título, à base de dados, ao ano, período e idioma. (continua)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas	Locais
6	Comparing the Perspectives of Generative AI, Mental Health Experts, and the General Public on Schizophrenia Recovery: Case Vignette Study	2024	JMIR Mental Health	Inglês	Meio Virtual
7	Predicting mental health problems in adolescence using machine learning techniques	2020	PloS One	Inglês	Suécia
8	Correlates of wanting to seek help for mental health and substance use concerns by sexual and gender minority young adults during the COVID-19 pandemic: A machine learning analysis	2022	PloS One	Inglês	Canadá
9	Identifying PTSD sex-based patterns through explainable artificial intelligence in biometric data	2024	Netw Model Anal Health Inform Bioinforma	Inglês	Estados Unidos
10	Sociodemographic Variables in Offender and Non-Offender Patients Diagnosed with Schizophrenia Spectrum Disorders-An Explorative Analysis Using Machine Learning	2024	Healthcare (Basel, Switzerland)	Inglês	Suiça
11	Evaluating generative AI responses to real-world drug-related questions	2024	Psychiatry Research	Inglês	Meio Virtual
12	Revealing the source: How awareness alters perceptions of AI and human-generated mental health responses	2024	Internet Interventions	Inglês	Índia
13	Examining how gamers connect with their avatars to assess their anxiety: A novel artificial intelligence approach.	2024	Acta Psychologica	Inglês	Meio Virtual
14	A pilot study on AI-driven approaches for classification of mental health disorders	2024	Frontiers In Human Neuroscience	Inglês	Espanha
15	Explainable artificial intelligence models for predicting risk of suicide using health administrative data in Quebec	2024	Plos One	Inglês	Canadá
16	Future of ADHD Care: Evaluating the Efficacy of ChatGPT in Therapy Enhancement	2024	Healthcare	Inglês	Meio Virtual
17	Assessing the Effectiveness of ChatGPT in Delivering Mental Health Support: A Qualitative Study	2024	Journal of Multidisciplinary Healthcare	Inglês	Arábia Saudita

Quadro 2 – Distribuição dos trabalhos seleccionados quanto ao título, à base de dados, ao ano, período e idioma. (continua)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas
18	Prediction of Depression Severity and Personalised Risk Factors Using Machine Learning on Multimodal Data	2024	International Journal of Online and Biomedical Engineering	Inglês
19	AI-Led Mental Health Support (Wysa) for Health Care Workers During COVID-19: Service Evaluation	2024	JMIR formative research	Inglês
20	Patient Perspectives on AI-Driven Predictions of Schizophrenia Relapses: Understanding Concerns and Opportunities for Self-Care and Treatment	2024	Proceedings of the SIGCHI conference on human factors in computing systems	Inglês
21	Patient Perspectives on AI-Driven Predictions of Schizophrenia Relapses: Understanding Concerns and Opportunities for Self-Care and Treatment	2024	Proceedings of the SIGCHI conference on human factors in computing systems	Inglês
22	Prediction of patient admission and readmission in adults from a Colombian cohort with bipolar disorder using artificial intelligence	2023	Frontiers Psychiatry	Inglês
23	Predicting individual cases of major adolescent psychiatric conditions with artificial intelligence	2023	Translational Psychiatry	Inglês
24	Effects of an Artificial Intelligence Platform for Behavioral Interventions on Depression and Anxiety Symptoms: Randomized Clinical Trial	2023	Journal of Medical Internet	Inglês
25	Diagnosing attention-deficit hyperactivity disorder (ADHD) using artificial intelligence: a clinical study in the UK	2023	Frontiers Psychiatry	Inglês
26	Machine learning based model for detecting depression during Covid-19 crisis	2023	Scientific African	Inglês
27	Objectively Quantifying Pediatric Psychiatric Severity Using Artificial Intelligence, Voice Recognition Technology, and Universal Emotions: Pilot Study for Artificial Intelligence-Enabled Innovation to Address Youth Mental Health Crisis	2023	JMIR Research Protocols	Inglês
28	Testing domain knowledge and risk of bias of a large-scale general artificial intelligence model in mental health	2023	Digital Health	Inglês
29	A new artificial intelligence-based clinical decision support system for diagnosis of major psychiatric diseases based on voice analysis	2023	Psychiatria Danubina	Inglês
30	Machine Learning in ADHD and Depression Mental Health Diagnosis: A Survey	2023	IEEE Access	Inglês

Quadro 2 – Distribuição dos trabalhos seleccionados quanto ao título, à base de dados, ao ano, período e idioma. (continua)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas
31	Detection and Prediction of Future Mental Disorder From Social Media Data Using Machine Learning, Ensemble Learning, and Large Language Models	2024	IEEE Access	Inglês
32	Understanding Digital Mental Health Needs and Usage With an Artificial Intelligence-Led Mental Health App (Wysa) During the COVID-19 Pandemic: Retrospective Analysis	2023	JMIR Formative Research	Inglês
33	Mental Illness Classification on Social Media Texts Using Deep Learning and Transfer Learning	2024	Computacion y Sistemas	Inglês
34	Prediction of suicidal ideation among korean adults using machine learning: A cross-sectional study	2020	Psychiatry Investigation	Inglês
35	AI-Enhanced Predictive Modeling for Identifying Depression and Delirium in Cardiovascular Patients Scheduled for Cardiac Surgery	2023	Diagnostics (Basel, Switzerland)	Inglês
36	Toward explainable AI (XAI) for mental health detection based on language behavior	2023	Frontiers in Psychiatry	Inglês
37	AIDA: Artificial intelligence based depression assessment applied to Bangladeshi students	2023	Array	Inglês
39	Effects of a Chatbot-Based Intervention on Stress and Health-Related Parameters in a Stressed Sample: Randomized Controlled Trial	2024	JMIR Mental Health	Inglês
40	Evaluating the Clinical Feasibility of an Artificial Intelligence-Powered, Web-Based Clinical Decision Support System for the Treatment of Depression in Adults: Longitudinal Feasibility Study	2021	JMIR Formative Research	Inglês
41	Extracting Mental Health Indicators From English and Spanish Social Media: A Machine Learning Approach	2023	IEEE ACCESS	Inglês
42	Artificial intelligence-based analytics for impacts of COVID-19 and online learning on college students' mental health	2022	Plos One	Inglês
43	Assessing the Impact of Conversational Artificial Intelligence in the Treatment of Stress and Anxiety in Aging Adults: Randomized Controlled Trial	2022	JMIR Mental Health	Inglês
44	Prediction of Mental Health in Medical Workers During COVID-19 Based on Machine Learning	2021	Frontiers in Public Health	Inglês

Quadro 2 – Distribuição dos trabalhos seleccionados quanto ao título, à base de dados, ao ano, período e idioma. (continua)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas
45	Acceptability and Effectiveness of Artificial Intelligence Therapy for Anxiety and Depression (Youper): Longitudinal Observational Study	2021	Journal of Medical Internet Research	Inglês
46	Predictive modeling of depression and anxiety using electronic health records and a novel machine learning approach with artificial intelligence	2021	Scientific Reports	Inglês
47	Clinical Advice by Voice Assistants on Postpartum Depression: Cross-Sectional Investigation Using Apple Siri, Amazon Alexa, Google Assistant, and Microsoft Cortana	2021	JMIR Mhealth Uhealth	Inglês
48	Comparison of predicted psychological distress among workers between artificial intelligence and psychiatrists: a cross-sectional study in Tsukuba Science City, Japan	2021	BMJ Open	Inglês
49	Context Deep Neural Network Model for Predicting Depression Risk Using Multiple Regression	2020	IEEE Access	Inglês
50	Detecting Depression Using a Framework Combining Deep Multimodal Neural Networks With a Purpose-Built Automated Evaluation	2019	Psychological Assessment	Inglês
51	Psychological Artificial Intelligence Service, Tess: Delivering On-demand Support to Patients and Their Caregivers: Technical Report	2019	Cureus Journal of Medical Science	Inglês
52	SADXAI: Predicting social anxiety disorder using multiple interpretable artificial intelligence techniques	2024	Tecnologia SLAS	Inglês
53	Automatic Detection of Major Depressive Disorder via a Bag-of-Behaviour-Words Approach	2019	In Proceedings of the Third International Symposium on Image Computing and Digital Medicine	Inglês
54	A pilot study of the perceptions and acceptability of guidance using artificial intelligence in internet cognitive behaviour therapy for perfectionism in young people	2024	Internet Interventions	Inglês
55	Using Psychological Artificial Intelligence (Tess) to Relieve Symptoms of Depression and Anxiety: Randomized Controlled Trial	2018	JMIR Mental Health	Inglês
56	Capacity of Generative AI to Interpret Human Emotions From Visual and Textual Data: Pilot Evaluation Study	2024	JMIR Mental Health	Inglês

Quadro 2 – Distribuição dos trabalhos selecionados quanto ao título, à base de dados, ao ano, período e idioma. (continua)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas
57	An AI-based Decision Support System for Predicting Mental Health Disorders	2023	Information Systems Frontiers	Inglês
58	Exploring factors for predicting anxiety disorders of the elderly living alone in south korea using interpretable machine learning: A population-based study	2021	International Journal of Environmental Research and Public Health	Inglês
59	ChatGPT is not ready yet for use in providing mental health assessment and interventions	2023	Frontiers in Psychiatry	Inglês
60	Development of an AI-Based Web Diagnostic System for Phenotyping Psychiatric Disorders	2020	Frontiers in Psychiatry	Inglês
61	Indonesian Journal of Electrical Engineering and Computer Science	2021	Indonesian Journal of Electrical Engineering and Computer Science	Inglês
62	Artificial intelligence in prediction of mental health disorders induced by the COVID-19 pandemic among health care workers	2020	Croatian Medical Journal	Inglês
63	Exploration and Strategy Analysis of Mental Health Education for Students in Sports Majors in the Era of Artificial Intelligence	2022	Frontiers in Psychology	Inglês
64	Machine learning and natural language processing in psychotherapy research: Alliance as example use case	2020	Journal of Counseling Psychology	Inglês
65	Assessing the Alignment of Large Language Models With Human Values for Mental Health Integration: Cross-Sectional Study Using Schwartz's Theory of Basic Values	2024	JMIR Mental Health	Inglês
66	Identification of Suicidal Ideation in the Canadian Community Health Survey-Mental Health Component Using Deep Learning	2021	Frontiers in artificial intelligence	Inglês
67	Inteligência artificial aplicada no mapeamento de sintomas e tratamento de depressão, ansiedade e estresse	2023	Plataforma UNINOVE	Português
68	Sistema leve: utilizando o aprendizado de máquina para o monitoramento de transtornos mentais comuns no trabalho	2022	Repositório Institucional UFRN	Português
69	Tecnologia digital baseada em técnicas de inteligência artificial para identificar fatores de risco e proteção da depressão em acadêmicos	2023	Plataforma Sucupira	Português

Quadro 2 – Distribuição dos trabalhos selecionados quanto ao título, à base de dados, ao ano, período e idioma. (conclusão)

Nº	Títulos	Ano de publicação	Títulos dos periódicos	Idiomas
70	Um estudo sobre aprendizado de máquina multimodal para identificar a depressão em adolescentes brasileiros usando dados coletados via smartphones	2023	Plataforma Sucupira	Português

Fonte: elaborado pelo autor (2025).

No Quadro 4, observam-se os resultados das informações referentes aos 70 estudos identificados a partir dos critérios de inclusão e exclusão mencionados. Desta forma, é possível observar que, mesmo a IA ganhando destaque recentemente, a literatura científica demonstra, com quantitativo considerável, quanto à utilização no âmbito da saúde mental.

A forma de abordagem da IA se mostrou bastante variada quanto à aplicação com direcionamento à assistência, às pesquisas e à capacitação profissional. Contudo, o grau de aplicabilidade, no que se refere à interação entre profissionais e paciente ainda permanece como questão que necessita de maiores estudos. A análise sistemática realizada por Khoo *et al.* (2020) está em consonância à tendência encontrada no presente estudo, com número crescente de artigos desenvolvendo, discutindo e avaliando o potencial da IA para análise clínica e predição de sinais e sintomas de TM.

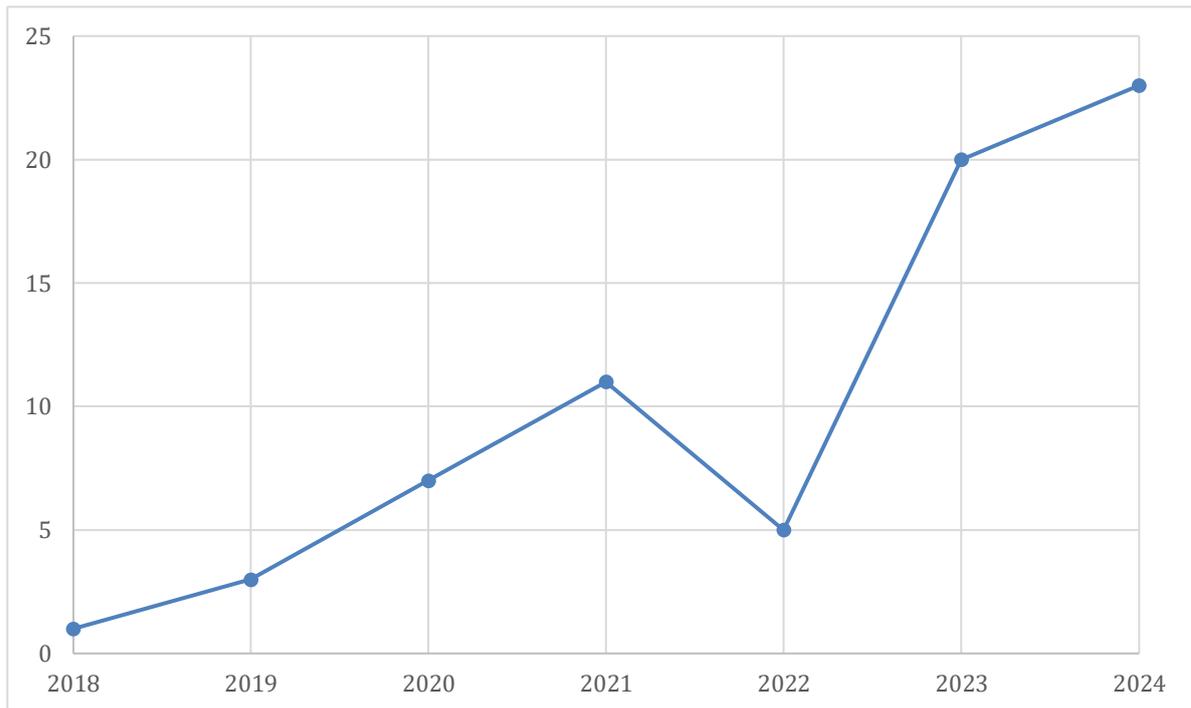
Ademais, outro ponto que gerou bastante discussão nos artigos encontrados foi em relação às questões éticas do uso da IA na saúde mental. O trabalho de Rubin *et al.* (2024) problematiza o papel da empatia humana em terapias orientadas por IA. Nesta perspectiva, os autores salientam que robôs terapêuticos podem se comportar de modo similar aos profissionais, em termos de vínculo terapêutico. Outro estudo também aborda o nível de aceitação dos indivíduos às formas de empatia geradas artificialmente, quando não cientes que as respostas são geradas por robôs, os usuários tendem a considerar as condutas genuínas, profissionais e eficientes. Contudo, ao saberem da procedência das informações, demonstraram certa aversão quanto à autenticidade e confiabilidade (Hohenstein *et al.*, 2023).

Outro aspecto relevante é a predominância de artigos em língua inglesa. Mesmo em países cuja língua nativa não deriva do latim, as pesquisas foram conduzidas e publicadas em inglês. As únicas exceções são os trabalhos encontrados em bibliotecas e repositórios de teses e dissertações, que estão disponíveis em português. Essa predominância da língua inglesa também se reflete em outras pesquisas na área da saúde, como no levantamento bibliográfico

realizado por Alcalá-Albert e Parra-González (2021), em que 95% das produções selecionadas estavam em inglês.

Por conseguinte, o Gráfico 1 expõe a distribuição dos artigos por ano de publicação, como forma de compreender a tendência das produções.

Gráfico 1 – Distribuição das obras analisadas pelo ano de publicação, no período de 2018 a 2024.



Fonte: elaborado pelo autor (2025).

Conforme é possível observar no Gráfico 1, as produções relacionadas à utilização de IA no cuidado à saúde mental se mostra recente, tendo o ano de 2018 (N = 1 | 1,42%) como o marco inicial, crescendo gradativamente pelos anos de 2019 (N = 3 | 4,28%), 2020 (N = 7 | 10%). No ano de 2022 (N = 5 | 7,14%), é perceptível período de leve decréscimo dos estudos selecionados, retornando à disposição de crescimento exponencial em 2023 (N = 20 | 28,57%) e 2024 (N = 23 | 32,85%).

Dessa forma, os achados exibidos no Gráfico 1 seguem perspectiva diretamente proporcional aos avanços tecnológicos, no decorrer dos anos, no que se refere às pesquisas, ao desenvolvimento e à popularização das IAs. Conforme apontado no trabalho de An *et al.* (2024), desde a década de 2010, grandes empresas do ramo da tecnologia, como Google, OpenAI e Tesla, direcionaram amplos investimentos para concepção e aplicação da IA. A Tesla, por exemplo, integrou em seus sistemas de piloto automático rede neurais, como forma de

aprimorar a condução autônoma. Outro exemplo de grande desenvolvimento de IA foi o *Generative Pre-trained Transformer 2* (GPT-2), pela OpenAI que gera textos de modo coerente e contextualizado.

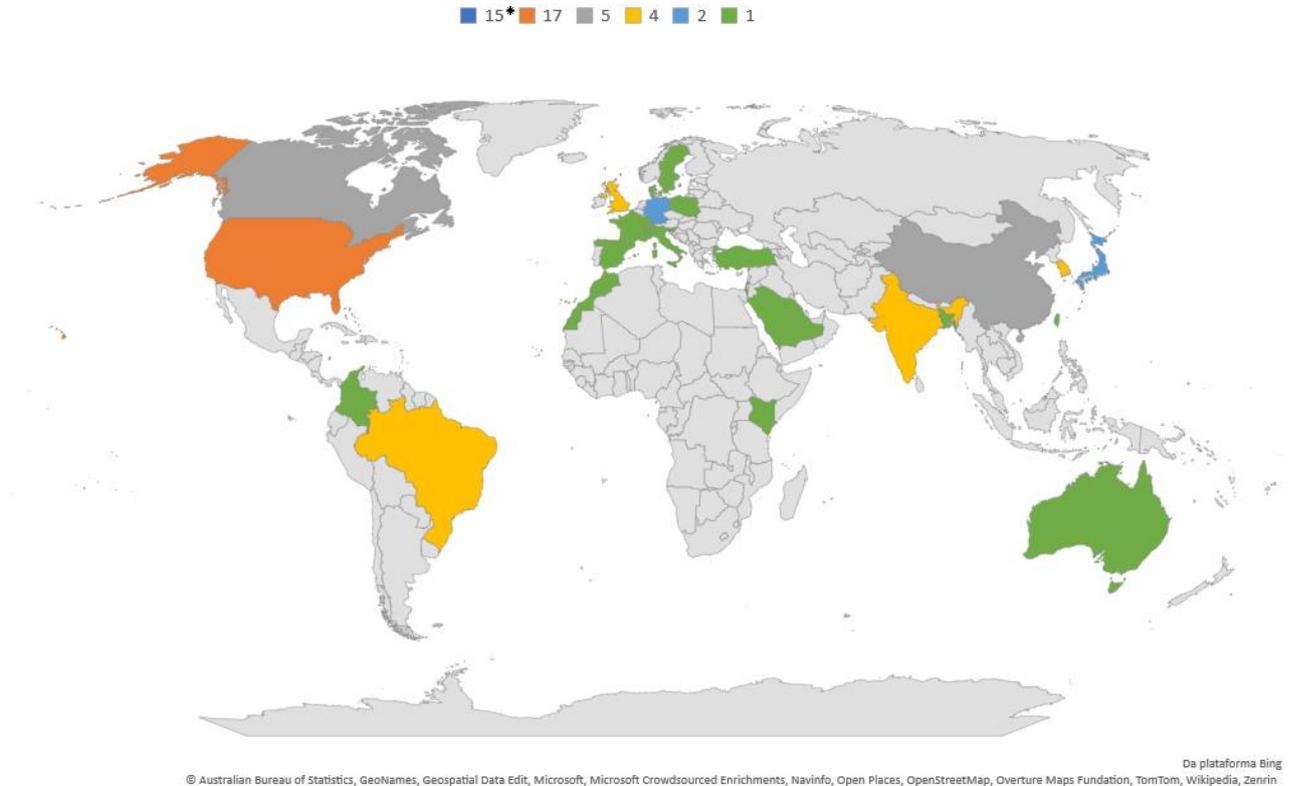
No ano de 2022, com o lançamento do ChatGPT, a IA alcançou novos patamares de avanços tecnológicos, tendo em vista que o ChatGPT-3.5 e ChatGPT-4 se tornaram acessíveis ao público, permitindo que qualquer indivíduo com acesso à internet pudesse interagir com o assistente virtual, abordando os mais diversos assuntos, a exemplo de questões de saúde mental. À vista disso, profissionais e pesquisadores também ingressaram gradativamente na utilização de IA para triagem de pacientes com TM e como forma de complementar as terapias tradicionais (Duong *et al.*, 2024). Neste sentido, o número reduzido de artigos em 2022 pode ser justificado pelo processo de reformulações, aprimoramentos e desenvolvimento de modelos mais avançados de IA que impactaram fortemente diversas áreas do conhecimento e estimularam pesquisas nos anos seguintes.

Outrossim, os anos em que a pandemia da Covid-19 esteve mais emergente também influenciou para aplicação de IA na área da saúde, em razão do potencial de monitoramento, pesquisa, diagnóstico e assistência. Devido à carência de repostas rápidas e exequíveis, a IA foi implementada para análise de perfil epidemiológico, análise de exames e melhor dimensionamento de recursos financeiros (Vaishya *et al.*, 2020). A literatura científica aponta que os algoritmos de aprendizado de máquina foram empregados na detecção precoce da Covid-19, por meio de tomografias e exames laboratoriais (Wang *et al.* 2021), enquanto sistemas de IA auxiliaram no processamento de volumosos quantitativos de dados clínicos para identificar padrões da doença (Majeed; Hwang, 2021).

Ao partir da perspectiva mais direcionada à saúde mental, a IA surge como alternativa de suporte para suprir a alta demanda de investigação e tratamento dos impactos psicológicos e psiquiátricos (He *et al.*, 2022). Nesse cenário, os *chatbots* terapêuticos foram amplamente empregados para fornecer suporte emocional, por intermédio do processamento de linguagem natural para interação máquina-usuário. Somado a isso, no estudo de Jin *et al.* (2023), algoritmos de aprendizado de máquina foram aplicados na análise de padrões comportamentais, auxiliando profissionais a identificarem sinais e sintomas precoces de acirramento de TM.

Por conseguinte, os estudos foram analisados, conforme distribuição geográfica (Gráfico 2).

Gráfico 2 – Distribuição dos estudos, segundo o local de realização.



*Os estudos categorizados como “meio virtual” não estão presentes no mapa.

Fonte: elaborado pelo autor (2025).

Dentre os países com maior quantitativo de pesquisas realizadas, destacam-se os Estados Unidos da América (EUA) com 17 artigos; seguidos de China e Canadá, com cinco artigos cada; Brasil, Coreia do Sul, Reino Unido e Índia, com quatro estudos cada; Japão e Alemanha, com dois artigos cada; e os demais países, Espanha, Arábia Saudita, França, Itália, Eslovênia, Bangladesh, Suíça, Polônia, Dinamarca, Turquia, Colômbia, Suécia, Taiwan, Marrocos, Israel, Quênia e Austrália tiveram um artigo para cada. Salienta-se ainda que alguns trabalhos foram realizados de modo multicêntrico, enquanto 15 estudos ocorreram com dados de redes sociais, grandes bancos de dados ou aplicativos móveis que não possibilitaram a precisão exata de qual país ocorreu a pesquisa, assim, foram classificados como “Meio Virtual”.

À vista disso, a predominância de produções científicas advindas dos EUA se reflete no alto investimento em pesquisas sobre IA e saúde digital. Renomadas empresas de tecnologia possuem sede no conglomerado tecnológico conhecido como Vale do Silício, bem como as atividades de pesquisa e inovação são impulsionadas pelo investimento em importantes universidades, por meio dos incentivos governamentais (Margetts; Dunleavy, 2024). Esses fatores se afirmam também em outras pesquisas nesse âmbito, como a revisão realizada por

Secinaro *et al.* (2021), a respeito de uso de IA na saúde, que evidenciou quantitativo de estudos considerável publicados nos EUA, em comparação a outros países.

Nessa perspectiva, China e Canadá aparecem logo após os EUA. A China, em particular, tem realizado investimentos massivos na área, consolidando-se como um dos principais líderes globais na aplicação da IA na medicina. Recentemente, reforçou sua posição com o lançamento da *Deepseek*, inteligência artificial desenvolvida para competir com a estadunidense OpenAI, criadora do ChatGPT (Chowdhury; Wei; Min, 2024). Já o Canadá foi considerado um dos pioneiros a promover políticas públicas e estratégias relacionadas à pesquisa em IA. Os incentivos financeiros é outro fator em consonância com os EUA e China, tendo em vista que, em 2017, o poder executivo do país lançou a Estratégia Pan-Canadense de Inteligência Artificial, com intuito de atrelar plano orçamentário de investimento no setor e posicionar o Canadá como um dos líderes de IA (Attard-Frost; Brandusescu; Lyons, 2021).

Outrossim, a presença de países como Coreia do Sul, Índia, Reino Unido, com quatro artigos cada, pode agir como indicativo de uma emergente interface entre a aplicação de IA na saúde mental. No caso do Brasil, denota-se que os estudos recuperados se tratam de tese e dissertações, o que pode sugerir desafios quanto aos investimentos direcionados à infraestrutura e ao financiamento de pesquisas e desenvolvimentos de IAs, principalmente quando associadas a lacunas presentes nos serviços de saúde (Da Costa *et al.*, 2024). Ao encontro dessa perspectiva, Leandro (2021) destaca os obstáculos na implantação da digitalização no sistema de saúde, considerando que regiões desenvolvidas possuem maior facilidade de implantação dessas tecnologias do que regiões rurais ou subdesenvolvidas.

Destarte, os 15 artigos que utilizaram dados de redes sociais, grandes bancos de dados ou aplicativos móveis sem definição precisa do país de origem, tornam evidente a globalização da pesquisa em IA e saúde mental. Esse achado assevera que os estudos têm utilizado gradativamente grandes volumes de dados disponíveis nos meios virtuais, permitindo análises em grande escala, até mesmo em nível global.

No Quadro 3, estão dispostas as características gerais dos estudos, categorizados quanto aos autores, objetivos, participante e às IAs empregadas.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
1	Kim <i>et al.</i> , (2020).	Detectar os transtornos mentais potenciais dos usuários pelas postagens destes nas mídias sociais.	Usuários do Reddit	O modelo principal foi uma rede neural convolucional (CNN). A arquitetura incluiu camadas de embedding, convolução e pooling.
2	Baqir <i>et al.</i> , (2024)	Criar um modelo de aprendizado de máquina que possa classificar indivíduos como portadores de TEPT ou não, com base na exposição à Covid-19, com alto grau de precisão.	Usuários do X (antigo Twitter)	Support Vector Machine (SVM); Naïve Bayes; K-Nearest Neighbors (KNN); Random Forest (RF).
3	Banerjee <i>et al.</i> , (2024)	Investigar como a popularidade da IA na saúde mental é um reflexo da alfabetização em IA no público em geral, especialmente na área da saúde mental.	Padrões de busca de estadunidenses, no Google Trends, sobre saúde mental.	ChatGPT.
4	Gradus <i>et al.</i> , (2021)	Identificar os principais preditores e desenvolver algoritmos de aprendizado de máquina para tentativas de suicídio não fatais, em grande amostra nacional, usando dados dos registros nacionais de saúde e sociais dinamarqueses.	Pessoas com tentativas de suicídio, em dados de registro nacional dinamarquês.	Árvores de Classificação e Regressão (CART) e RF.
5	Zhang <i>et al.</i> (2023)	Desenvolver versão inicial de um modelo eficiente e prático para triagem de saúde mental entre populações em risco.	Pacientes e participantes do Clínica Ambulatorial Psiquiátrica, do Centro de Saúde Mental, Hospital da China Ocidental, da Universidade de Sichuan e do Terceiro Hospital de Mianyang/Centro de Saúde Mental de Sichuan.	Multiple Instance Learning (MIL), ResNet, DenseNet e EfficientNet.
6	Elyoseph; Levkovich, (2024)	Avaliar a capacidade de grandes modelos de linguagem (LLMs), em comparação com profissionais de saúde mental, para avaliar o prognóstico da esquizofrenia com e sem tratamento profissional e os resultados positivos e negativos de longo prazo.	Profissionais da saúde	ChatGPT-3.5; ChatGPT-4; Google Bard e Claude.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
7	Tate <i>et al.</i> , (2020)	Desenvolver um modelo que possa prever problemas de saúde mental na adolescência média e investigar várias técnicas de aprendizado de máquina junto com regressão logística padrão para determinar qual tem melhor desempenho, usando questionário combinado e dados de registro.	Participantes do Child and Adolescent Twin Study in Sweden (CATSS), estudo longitudinal em andamento, contendo 15.156 pares de gêmeos nascidos na Suécia.	RF; SVM; neural network e XGBoost.
8	Kundu <i>et al.</i> , (2022)	Identificar os correlatos importantes e os efeitos no risco previsto de querer buscar ajuda para problemas de saúde mental e uso de substâncias entre jovens adultos 2SLGBTQI+, durante a pandemia.	Jovens adultos 2SLGBTQI+, com idades entre 16 e 29 anos que viviam no Canadá, durante dezembro de 2020 a março de 2021.	RF
9	Garcia-Valdez <i>et al.</i> , (2024)	Identificar automaticamente padrões relacionados ao sexo, associados a indicadores de TEPT, por meio da análise de dados biométricos: movimentos faciais, fala ou transcrições de voz para texto.	189 participantes com idades entre 18 e 70 anos, todos falantes nativos de inglês.	RF, Redes Neurais e SVM e aplicação do algoritmo SHAP.
10	Hoffmann <i>et al.</i> , (2024)	Delinear procedimentos, benefícios e limitações da ML na pesquisa psiquiátrica, em uma questão de pesquisa paradigmática, com objetivo de discriminar entre infratores e não infratores com SSDs, com base apenas em variáveis sociodemográficas.	Pacientes infratores (OP, n = 370) e grupo de comparação de pacientes não infratores (NOP, n = 370), todos diagnosticados com SSDs, de acordo com o CID-9 ou CID-10.	LR, Decision Trees; RF; Gradient Boosting; KNN) Support Vector Machines (SVMS) e Naïve Bayes.
11	Giorgi <i>et al.</i> , (2024)	Avaliar a IA generativa com perguntas geradas por usuários do mundo real, para entender como esses sistemas respondem em um ambiente naturalista, o que pode ajudar a informar desenvolvedores e pesquisadores quando e como esses sistemas podem falhar.	Usuários do Reddit	ChatGPT-4 e LLaMA-2
12	Jain; Pareek; Carlbring, (2024)	Compreender como a conscientização sobre a origem das respostas (se geradas por IA ou por humanos) influencia a percepção das respostas fornecidas no contexto de suporte à saúde mental para jovens.	140 Jovens Adultos da Comunidade Acadêmica	ChatGPT
13	Hein <i>et al.</i> , (2024)	Investigar o vínculo usuário-avatar dentro da estrutura da hipótese fenótipo digital, com foco no potencial vínculo usuário-avatar com a ansiedade.	565 adolescentes e adultos de uma comunidade virtual	LASSO; k-NN; SVM-K; XGBoost, RF, Naïve Bayes e LR.
14	Dhariwal <i>et al.</i> , (2024)	Analisar abordagens baseadas em IA para classificação de transtornos de saúde mental.	Moradores de Barcelona	LR; Decision tree; RF; Gradient boosting; SVM; kNN; XGBoost e LightGBM.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
15	Kharrat <i>et al.</i> , (2024)	Desenvolver modelos de ML supervisionados de predição de risco de suicídio específicos por sexo e aplicar abordagem de explicação global post-hoc para interpretar os resultados.	População da província de Quebec, por meio do Sistema Integrado de Vigilância de Doenças Crônicas de Quebec (QICDSS), contendo dados de mais de 20.000 suicídios entre 2002 e 2019.	LR; RF; Extreme Gradient Boosting (XGBoost), e Multilayer Perceptron (MLP).
16	Berrezueta-Guzman <i>et al.</i> , (2024)	Explorar a integração de grandes modelos de linguagem (LLMs), como o ChatGPT, para melhorar os tratamentos do Transtorno do Déficit de Atenção e Hiperatividade (TDAH).	Pessoas em tratamento do Transtorno do Déficit de Atenção e Hiperatividade (TDAH).	ChatGPT personalizado.
17	Alanézi, (2024)	Avaliar o uso do ChatGPT para suporte à saúde mental.	Pacientes ambulatoriais (18 anos ou mais), com condições de saúde mental, incluindo ansiedade, depressão e transtornos comportamentais do hospital da King Fahad University, Arábia Saudita.	ChatGPT (versão 3.5).
18	Ayodele; Adetunla; Akinlabi, (2024).	Investigar a predição da gravidade da depressão e a identificação de fatores de risco personalizados, usando um conjunto de dados multimodais.	Dados multimodais de informações de 14.332 participantes do <i>National Health and Nutrition Examination Survey</i> (NHANES).	Regressão Linear, Random Forest (RF), SVM, XGBoost e LASSO.
19	Chang <i>et al.</i> , (2024)	Explorar a viabilidade do uso do Wysa, aplicativo de saúde mental, baseado em inteligência artificial, entre profissionais de saúde.	Equipe de saúde de um cluster nacional de assistência médica terciária.	Aplicativo Wysa.
20	Yoo <i>et al.</i> , (2024)	Explorar como os pacientes percebem as previsões baseadas em IA, no contexto de recaída da esquizofrenia, e avaliar o papel e o impacto potencial dessas previsões nas estratégias de autocuidado adotadas por esses pacientes.	Participantes que tinham sido diagnosticados com esquizofrenia, tinham 18 anos ou mais e viviam nos Estados Unidos.	SVM.
21	Palacios-Ariza <i>et al.</i> , (2023)	Desenvolver modelos de predição para admissão/readmissão hospitalar dentro de cinco anos do diagnóstico em pacientes com transtorno bipolar, usando técnicas de aprendizado de máquina.	Candidatos a preditores foram selecionados de Registros Eletrônicos de Saúde (EHRs) e incluíram variáveis sociodemográficas e clínicas.	Decision Trees, RF, LR e SVM.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
22	De Lacy <i>et al.</i> , (2023).	Explorar a previsão de casos individuais de grandes condições psiquiátricas em adolescentes com inteligência artificial.	Jovens com pelo menos uma preocupação comportamental, com idades entre 5 e 21 anos, na área da cidade de Nova York.	Adam; XGBoost; LR; Integrated Evolutionary Learning (IEL).
23	Sadeh-Sharvit <i>et al.</i> , (2023)	Determinar viabilidade, aceitabilidade e eficácia preliminar de uma plataforma de IA para saúde comportamental na facilitação de melhores resultados clínicos para pacientes recebendo terapia ambulatorial.	Adultos encaminhados para terapia cognitivo-comportamental individual ambulatorial, com diagnóstico de transtorno depressivo ou de ansiedade, e os clínicos que os tratavam.	Eleos Health
24	Chen <i>et al.</i> , (2023)	Explorar diagnosticando o Transtorno do Déficit de Atenção e Hiperatividade (TDAH), usando inteligência artificial.	Pacientes com TDAH registrados no conjunto de dados do <i>South West Yorkshire Partnership Foundation Trust (SWYPFT)</i> .	LR; Linear Discriminant Analysis; Multiple Layer Perceptron; KNN; SVM; Gaussian Naive Bayes; RF; Extreme Gradient Boosting.
25	Sofia <i>et al.</i> , (2023)	Desenvolver um modelo baseado em aprendizado de máquina para detectar depressão em indivíduos, durante a pandemia da Covid-19.	Indivíduos afetados pela pandemia da Covid-19, com foco na identificação de depressão, em diferentes faixas etárias, níveis educacionais, status de renda e condições sociais.	Naive Bayes; KNN; Árvores de Decisão.
26	Caulley <i>et al.</i> , (2023)	Desenvolver e avaliar métodos automatizados para detectar a intensidade das emoções (raiva, medo, tristeza e felicidade), em gravações de áudio da fala dos pacientes.	Crianças de 5 a 18 anos e aquelas encaminhadas para serviços de saúde comportamental, por meio de escolas, DJJ e agências de proteção à criança.	Transformers (Wav2Vec 2.0 e HuBERT); CNNs, incluindo AlexNet e GoogleNet); SpeechBrain Framework; Demucs (para denoising).
27	Heinz <i>et al.</i> , (2023)	Avaliar o conhecimento do domínio da saúde mental de um grande modelo geral de IA.	População em geral dos EUA com algum transtorno mental.	GPT-3.
28	Cansel <i>et al.</i> , (2023)	Desenvolver um sistema de suporte à decisão clínica, baseado em Inteligência Artificial (IA) para diagnosticar transtornos psiquiátricos (bipolar, depressivo, de ansiedade e espectro da esquizofrenia), a partir da análise de sinais de voz.	104 indivíduos, sendo 79 pacientes diagnosticados com transtornos psiquiátricos (15 com transtorno do espectro da esquizofrenia, 24 com transtornos de ansiedade, 25 com transtornos depressivos e 15 com transtorno bipolar) e 25 indivíduos saudáveis como grupo controle.	kNN e SVM.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
29	Nash; Nair; Naqvi, (2023)	Investigar o uso de técnicas de aprendizado de máquina (Machine Learning - ML) na detecção de Transtorno de Déficit de Atenção e Hiperatividade (TDAH) e depressão, dois dos transtornos mentais mais prevalentes. O foco está em métodos de detecção, utilizando dados vestíveis e não vestíveis para melhorar o diagnóstico e as intervenções clínicas.	Indivíduos diagnosticados com TDAH ou depressão e controles saudáveis, abrangendo adultos e crianças.	SVM; CNNs; RF e ElasticNet.
30	Lee <i>et al.</i> , (2023)	Avaliar o desempenho de LLMs, especificamente o transformador generativo pré-treinado 4 (GPT-4) da OpenAI, na previsão de episódios atuais e futuros de crise de saúde mental, usando informações fornecidas pelo paciente na admissão entre usuários de uma plataforma nacional de telessaúde mental.	Psiquiatras e psicólogos clínicos empregados na Brightside Health foram recrutados e todos consentiram em participar do estudo.	GPT-4.
31	Abdullah; Negied, (2024)	Determinar se algoritmos de aprendizado de máquina (ML), algoritmos de aprendizado de conjunto (EL) e modelos de linguagem ampla (LLMs) podem detectar se uma pessoa sofre de um transtorno de doença mental, a partir de suas postagens, em um contexto clínico nas mídias sociais. Detectar se uma pessoa sofre de um transtorno de doença mental, a partir de suas postagens, mas, desta vez, em um contexto não clínico nas mídias sociais, usando os mesmos algoritmos. Determinar se algoritmos de aprendizado de máquina podem ser usados para prever a ocorrência futura de doença mental antes que uma pessoa tenha consciência suficiente de seu caso.	Usuários do de mídias sociais.	LR, SVM, KNN, Decision Tree, Stochastic Gradient Descent (SGD), Multinomial Naive Bayes, Voting Classifiers, RF, Bagging Meta-Estimator, AdaBoost, XGBoost, Gradient Boosting, and Light Gradient Boosting Machine (LightGBM), Bert, RoBERTa , GPT e GPT2.
32	Sinha; Meheli; Kadaba, (2023)	Avaliar a utilização e a eficácia do aplicativo de saúde mental Wysa, durante a pandemia da Covid-19.	Usuários do aplicativo Wysa que buscaram suporte em saúde mental, durante a pandemia.	Wysa
33	Arif <i>et al.</i> , (2024)	Desenvolver um sistema automatizado para detectar e classificar transtornos mentais, usando textos de mídias sociais.	Indivíduos que usam mídias sociais para expressar emoções ou buscar apoio relacionado a transtornos mentais.	LR, Naive Bayes, Random Forest, LSTM, BiLSTM, CNN, BERT, RoBERTa, AIBERT.
34	Oh <i>et al.</i> , (2020)	Identificar os fatores associados à IS e construir modelos de previsão em adultos coreanos, usando métodos de aprendizado de máquina.	Casos de adolescentes com Ideação Suicida (IS), provenientes da Pesquisa Nacional de Exame de Saúde e Nutrição da Coreia (KNHANES).	Bayesian network (BN); LogitBoost with logistic regression (LB); SVM; decision tree (DT) of J48; artificial neural network (ANN) e LR.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
35	Nowakowska <i>et al.</i> , (2023)	Identificar depressão e delírio em pacientes cardiovasculares programados para cirurgia cardíaca, por meio da modelagem preditiva aprimorada por IA.	224 pacientes adultos que foram qualificados para cirurgia de CABG isolada ou cirurgia de CABG com reparo ou substituição de válvula cardíaca (CVR), no Departamento de Cirurgia Cardíaca, do Hospital Clínico Central, da Universidade Médica de Lodz.	AdaBoost, XGBoost e RF e kNN.
36	Kerz <i>et al.</i> , (2023)	Desenvolver abordagens de inteligência artificial explicável (XAI) para detecção de transtornos mentais, com base em comportamentos linguísticos, utilizando dados textuais de redes sociais.	Comunidade em geral com transtornos mentais, como TDAH, ansiedade, bipolaridade, depressão e estresse psicológico, com foco em textos publicados em redes sociais como Reddit.	Modelos baseados em BiLSTM; MentalRoBERTa e Modelos Multi-Tarefa.
37	Siddiqua <i>et al.</i> , (2023)	Desenvolver um sistema para avaliação e predição de depressão em estudantes universitários de Bangladesh, utilizando abordagem baseada em Inteligência Artificial (IA).	684 estudantes universitários, com idades entre 19 e 35 anos, como participantes.	RF; Gradient Boosting (GB); KNN; SVM; LR; Naive Bayes; Decision Tree; ANN; CNN; XGBoost; LightGBM; Explainable AI (LIME).
38	Na <i>et al.</i> , (2021)	Construir um modelo de classificação para diferenciar o transtorno do pânico de outros transtornos de ansiedade, por meio do aprendizado de máquina.	Pessoas com idadeS entre 20 e 65 anos, diagnosticadas com transtorno de pânico (de acordo com a 10ª edição da Classificação Estatística Internacional de Doenças e Problemas Relacionados à Saúde (CID-10), código para F41.0) ou outros transtornos de ansiedade (F41.1 a F41.9) e tiveram a variabilidade da frequência cardíaca (VFC) medida no primeiro mês de visitas ao hospital.	LR; ANN); Gradient Boosting Machine (GBM), RF e SVM.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
39	Schillings <i>et al.</i> , (2024)	Investigar os efeitos de uma intervenção de três semanas, baseada em <i>chatbot</i> , guiada pelo <i>chatbot</i> ELME, especificamente com relação à capacidade de reduzir o estresse e melhorar vários parâmetros relacionados à saúde em uma amostra estressada.	Indivíduos com 18 anos ou mais, que dominavam o alemão, possuíam um smartphone com acesso à internet e um número de telefone válido. Além disso, era necessário ter um endereço de correspondência, apresentar um nível de estresse moderado a alto (PSS-10 \geq 14), não possuir diagnóstico de transtornos mentais, não estar em psicoterapia e não participar de outras intervenções de saúde mental <i>on-line</i> .	Chatbot ELME
40	Popescu <i>et al.</i> , (2021)	Examinar a viabilidade de um CDSS alimentado por inteligência artificial, que combina as diretrizes operacionalizadas da Rede Canadense de Tratamentos de Humor e Ansiedade de 2016, com previsão de remissão de tratamento individualizada baseada em rede neural.	A amostra do estudo incluiu dois grupos populacionais: (1) médicos, incluindo médicos de família e psiquiatras e (2) pacientes desses médicos. A meta de recrutamento foi de 10 médicos e 3-4 pacientes por médico (30-40 pacientes no total).	CDSS Aifred
41	Villa-Pérez <i>et al.</i> , (2023)	Usar algoritmos de aprendizado de máquina, incluindo redes neurais profundas, para detectar automaticamente nove condições de saúde mental em usuários de Twitter que falam inglês e espanhol.	A amostra incluiu 3.200 usuários, sendo 1.500 diagnosticados com transtornos, como ansiedade, depressão e TDAH, e 1.700 do grupo de controle, com os dados coletados entre 2020 e 2021.	XGBoost; SVM; CNN; Gated Recurrent Units (GRU); Long Short-Term Memory (LSTM) e CNN-LSTM (combinação de redes convolucionais e LSTM).
42	Rezapour; Elmshaeuser, (2022)	Analisar, com base em inteligência artificial, os impactos da Covid-19 e do aprendizado <i>on-line</i> na saúde mental de estudantes universitários.	Os dados foram coletados por meio de pesquisa global realizada pela Universidade de Ljubljana, na Eslovênia, em colaboração com um consórcio internacional de universidades e associações estudantis.	RF; XGBoost; CatBoost; LightGBM; SVM e Redes Neurais Profundas (Deep Neural Networks).

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
45	Mehta <i>et al.</i> , (2021)	Examinar a aceitabilidade e eficácia do Youper.	Usuários que pagaram por acesso total ao Youper e que baixaram o aplicativo entre 4 de março de 2020 e 10 de julho de 2020.	Youper.
46	Nemesure <i>et al.</i> , (2021)	Prever Transtornos Depressivos Maiores (TDM) e Transtornos de Ansiedade Generalizada (TAG), em registros eletrônicos de saúde de estudantes universitários, utilizando abordagem de aprendizado de máquina.	Participaram 4.184 estudantes de graduação com idades entre menores de 18 até mais de 20 anos da Universidade de Nice Sophia-Antipolis, na França.	RF; XGBoost; Support SVM; KNN; redes neurais e LR.
47	Yang <i>et al.</i> , (2021)	Avaliar a capacidade de quatro assistentes virtuais de voz (Apple Siri, Amazon Alexa, Google Assistant e Microsoft Cortana) em fornecer respostas precisas, verbalizadas e clinicamente apropriadas sobre questões relacionadas à Depressão Pós-Parto (DPP).	Foram mães com depressão pós-parto ou pessoas em busca de informações confiáveis sobre o tema.	Apple Siri; Amazon Alexa; Google Assistant e Microsoft Cortana
48	Doki <i>et al.</i> , (2021)	Desenvolver e avaliar um modelo de Inteligência Artificial (IA) para prever sofrimento psicológico entre trabalhadores, utilizando dados sociodemográficos, de estilo de vida e sono, excluindo informações subjetivas, como humor e emoções.	Participaram 7.251 trabalhadores de diversas ocupações, predominantemente pesquisadores e profissionais de escritório.	Modelos de redes neurais com três camadas, configurados para identificar padrões nos dados fornecidos pelos participantes e prever sofrimento psicológico. Foram usadas funções de otimização e ativação avançadas (Adam e ReLU).
49	Baek; Chung, (2020)	Desenvolver uma IA modelo de rede neural profunda contextual (context-DNN) para prever o risco de depressão com base em variáveis contextuais, usando análise de regressão múltipla.	População da Coreia, com foco em pacientes vulneráveis à depressão, em várias faixas etárias.	Deep Neural Networks (DNN); Adam e ReLU.
50	Victor <i>et al.</i> , (2019)	Desenvolver ferramenta baseada em inteligência artificial para detectar e classificar a depressão em indivíduos, usando redes neurais multimodais profundas (deep multimodal neural networks).	População em geral dos EUA em risco de depressão clínica.	Deep Multimodal Neural Networks; LSTM Bidirecional (BiLSTM); Embeddings de Palavras (GloVe).
51	Joerin; Rauws; Ackerman, (2019)	Explorar a implementação do chatbot tess, uma solução de Inteligência Artificial (IA) psicológica, para oferecer suporte emocional acessível e personalizado para cuidadores, paciente e profissionais de saúde.	Cuidadores familiares, profissionais de saúde, pacientes (especialmente idosos) e pessoas que enfrentam desafios de saúde mental, como depressão, ansiedade e isolamento social.	Tess; Elizbot; Amazon Alexa e Google Home.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
52	Chadaga <i>et al.</i> , (2024)	Prever Transtorno de Ansiedade Social (SAD), utilizando técnicas de aprendizado de máquina e Inteligência Artificial Explicável (XAI).	O estudo utilizou um conjunto de dados de 214 pacientes (111 positivos para SAD e 103 negativos), extraído do Mendely Data, repositório público.	LR; RF; Decision Tree; KNN; AdaBoost; CatBoost; LightGBM; XGBoost; Modelo de Ensemble (Custom STACK).
53	Qian <i>et al.</i> , (2019)	Desenvolver abordagem baseada em aprendizagem de máquina, chamada "Bag-of-Behaviour-Words" (BoBW), para detectar automaticamente o Transtorno Depressivo Maior (TDM), a partir de dados de Atividade Física Espontânea (SPA), registrados por dispositivos portáteis do tipo relógio.	83 participantes ao total, sendo 14 pacientes diagnosticados com Transtorno Depressivo Maior (TDM) e 69 participantes saudáveis.	Método BoBW e SVM.
54	Egan <i>et al.</i> , (2019)	Entender as percepções e a aceitabilidade de uma intervenção Terapia Cognitivo-Comportamental para Perfeccionismo (TCC-P) suplementada por Inteligência Artificial (IA-TCC-P), em jovens com experiência vivida de ansiedade e depressão.	Grupo Consultivo de Jovens com experiência vivida de ansiedade e depressão.	ChatGPT
55	Fulmer <i>et al.</i> , (2018)	Avaliar a eficácia da inteligência artificial psicológica integrativa, Tess, na redução dos sintomas de depressão e ansiedade, em estudantes universitários de forma envolvente.	Estudantes universitários com idade igual ou superior a 18 anos, matriculados em universidades dos Estados Unidos e capazes de compreender a língua inglesa.	Tess
56	Elyoseph <i>et al.</i> , (2024)	Avaliar criticamente as capacidades do ChatGPT-4 e do Google Bard, em relação à competência em discernir indicadores de mentalização visual em contraste com as habilidades de mentalização baseadas em texto.	O estudo envolveu idosos com 60 anos ou mais, residentes em três áreas urbanas e rurais específicas de uma província da China.	ChatGPT-4 e Bard (Gemini).
57	Tutum <i>et al.</i> , (2023)	Desenvolver um sistema de apoio à decisão baseado em Inteligência Artificial (IA) para diagnosticar de forma eficiente e precisa transtornos mentais, utilizando número reduzido de perguntas, em comparação aos métodos tradicionais.	O estudo utilizou dados coletados de mais de 6.000 participantes desde 2019, por meio da plataforma Psikometrist, usada por profissionais de saúde mental, como psicólogos e psiquiatras.	Networked Pattern Recognition (NEPAR); RF; SVM; Regressão Logística Regularizada (L-LR e R-LR).

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
58	Byeon, (2021)	Desenvolver modelo de inteligência artificial interpretável (X-AI) para prever o risco de transtorno de ansiedade, em idosos, na Coreia do Sul.	Foram analisados 1.558 idosos com 60 anos ou mais (695 homens e 863 mulheres), participantes do Korean Psychosocial Anxiety Survey, conduzido em 17 cidades e províncias da Coreia do Sul.	SVM; RF; LightGBM; Adaboost; XGBoost (como meta-modelo no stacking ensemble).
59	Dergaa <i>et al.</i> , (2023)	Avaliar a eficácia, confiabilidade e segurança do ChatGPT, no auxílio a pacientes com problemas de saúde mental, e avaliar o potencial como ferramenta colaborativa para profissionais de saúde mental, por meio de interação simulada com três pacientes imaginários distintos.	Os participantes deste estudo são três pacientes imaginários distintos: o paciente A era um estudante universitário de 22 anos, a paciente B era uma mulher de 58 anos com Lúpus Eritematoso Sistêmico (LES); e a paciente C era uma mulher de 23 anos no pós-parto. Todos os três pacientes apresentaram e buscaram eliminar a mesma queixa principal, que é dificuldade para adormecer e acordar frequentemente durante a noite, nas últimas duas semanas.	ChatGPT

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
60	Chang <i>et al.</i> , (2020)	Desenvolver um sistema de diagnóstico web, baseado em IA, para fenotipagem de transtornos psiquiátricos.	Este estudo incluiu duas coortes independentes, totalizando 532 indivíduos, para construção e validação de modelos preditivos. O conjunto de construção do modelo utilizou dados de 200 pacientes com esquizofrenia e 200 controles saudáveis da coorte "Taiwan Aging and Mental Illness" (TAMI), divididos em 350 participantes para treinamento (87,50%) e 50 para teste (12,50%).	Rede Neural Profunda Explicável (EDNN) e Análise de Informação Mútua.
61	Salhi <i>et al.</i> , (2021)	Desenvolver um chatbot de apoio psicológico adaptativo, capaz de ajudar pessoas, especialmente estudantes, que sofrem de transtornos mentais agravados pela pandemia da Covid-19.	Estudantes que enfrentam desafios de saúde mental, durante e após a pandemia, com intuito de fornecer suporte emocional e psicológico.	Modelo sequência-a-sequência (Seq2Seq) com redes neurais LSTM bidirecionais. Redes neurais recorrentes (RNN) Frameworks TensorFlow e Keras.
62	Ćosić <i>et al.</i> , (2020)	Prevenir transtornos de saúde mental em profissionais de saúde, por meio da previsão precoce de indivíduos em risco de desenvolver condições mentais crônicas, devido ao alto nível de estresse enfrentado, durante a pandemia da Covid-19.	Profissionais de saúde, como médicos e enfermeiros, que estiveram na linha de frente durante a pandemia e enfrentaram altos níveis de estresse.	ANN e SVM.
63	Liang <i>et al.</i> , (2022)	Explorar e propor estratégias de educação em saúde mental para estudantes de educação física, utilizando tecnologias de Inteligência Artificial (IA) e big data para criar um modelo de educação adaptativo e eficaz.	A pesquisa envolveu cerca de 200 estudantes universitários de educação física em quatro universidades da província de Shaanxi, na China.	CNN e FastText.

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(continua)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
64	Goldberg <i>et al.</i> , (2020)	Explorar como métodos de aprendizado de máquina (ML) e processamento de linguagem natural (NLP) podem ser aplicados para prever a aliança terapêutica, a partir de gravações de sessões de psicoterapia, promovendo a automação na avaliação de processos terapêuticos.	Os dados foram coletados no centro de aconselhamento de uma grande universidade no Oeste dos Estados Unidos. Foram incluídas gravações de 1.235 sessões realizadas por 40 terapeutas com 386 clientes.	Sent2Vec; Kaldi Speech Recognition Toolkit; Ridge Regression.
65	Hadar-Shoval <i>et al.</i> , (2024)	Investigar os valores motivacionais embutidos em modelos de linguagem ampla (LLMs), como GPT-3.5, GPT-4, Bard e Claude 2, usando a Teoria dos Valores Básicos de Schwartz.	Não houve participação direta de humanos no estudo. Os dados foram coletados exclusivamente a partir das respostas simuladas de quatro LLMs comerciais. As comparações com valores humanos foram feitas, utilizando dados de 53.472 indivíduos provenientes de 49 países que completaram o <i>Portrait Values Questionnaire-Revised</i> (PVQ-RR) entre 2017 e 2020.	GPT-3.5; GPT-4; Bard e Claude.
66	Desai <i>et al.</i> , (2021)	Desenvolver um modelo de aprendizado profundo para identificar ideias suicidas na população geral, utilizando dados da Pesquisa de Saúde Comunitária Canadense- Componente de Saúde Mental.	Foram analisadas respostas de 23.859 pessoas de 15 anos ou mais residentes nas dez províncias do Canadá. Os dados foram coletados, em 2012, por telefone ou pessoalmente.	Boosting por Gradiente; Deep Learning (Rede Neural) e RF.
67	Delgado, (2023)	Desenvolver um método baseado em Inteligência Artificial (IA) para mapear sintomas e auxiliar no tratamento de depressão, ansiedade e estresse.	O banco de dados foi cedido por Vignola e Tucci (2013), contendo 242 pacientes brasileiros, cujos dados foram coletados a partir do teste DASS-21. A amostra incluiu indivíduos com variados níveis de sintomas de depressão, ansiedade e estresse.	Decision Trees; Apriori Algorithm; Fuzzy Inference System (FIS).

Quadro 3 – Características gerais dos estudos, objetivos, participantes, IAs empregadas.

(conclusão)

Nº	Autores	Objetivos	Público Participante	IAs utilizadas
68	Martins (2022)	Desenvolver o sistema LEVES (Levantamento de Emoções e Sentimentos), utilizando técnicas de aprendizado de máquina para monitorar Transtornos Mentais Comuns (TMC), em servidores públicos, de uma universidade federal.	A pesquisa foi realizada na Universidade Federal do Rio Grande do Norte (UFRN), Brasil, com a participação de 263 servidores ativos que responderam ao formulário do sistema LEVES, abrangendo informações sociodemográficas, dados laborais e indicadores de saúde mental.	K-means e WEKA.
69	Do Pinho (2023)	Desenvolver tecnologia digital, baseada em técnicas de Inteligência Artificial (IA), para identificar fatores de risco e proteção associados ao Transtorno Depressivo Maior (TDM), em estudantes universitários.	O estudo foi realizado no Brasil e incluiu 60 estudantes universitários de diversas instituições, que forneceram dados para validação do modelo proposto.	Logistic Regression (LR); Linear Discriminant Analysis (LDA); KNN; Decision Tree Classifier (CART); Gaussian Naive Bayes e SVM.
70	De Melo (2023)	Desenvolver e avaliar modelo de aprendizado de máquina multimodal, capaz de prever a depressão, em adolescentes brasileiros, usando dados coletados, via smartphones.	A pesquisa utilizou dados do banco IDEA-RiSCo, composto por 150 adolescentes brasileiros com diferentes níveis de risco de depressão (baixo risco, alto risco ou diagnosticados).	1D Convolutional Neural Network (1DCNN); RF; SVM e CatBoost.

Fonte: elaborado pelo autor (2025).

Os achados evidenciados no Quadro 3 demonstraram a crescente aplicação da inteligência artificial na saúde mental, com foco na detecção, no diagnóstico e monitoramento de transtornos psicológicos. As pesquisas analisadas empregaram gama de técnicas de aprendizado de máquina e aprendizado profundo para identificar padrões associados a condições, como depressão, ansiedade, Transtorno de Estresse Pós-Traumático (TEPT), Transtorno do Déficit de Atenção e Hiperatividade (TDAH) e esquizofrenia. Modelos como Redes Neurais Convolucionais (CNN), Redes Recorrentes de Longa Memória (LSTM), Support Vector Machines (SVM) e Random Forest (RF) se destacaram pela capacidade de analisar grandes volumes de dados provenientes de diversas fontes, como mídias sociais, registros eletrônicos de saúde e sinais biométricos.

A análise de textos publicados em redes sociais, como Twitter (atualmente X) e Reddit, tem sido extensivamente analisada, no intuito de prever e identificar TM, a partir de padrões linguísticos e emocionais. O uso de modelos de linguagem, como ChatGPT, BERT e RoBERTa, também, ganharam destaque nos métodos utilizados, devido à possibilidade de processamento automatizado de quantitativos consideráveis de texto, também desempenhando importantes papéis preditivos e auxiliando na triagem precoce de indivíduos com risco de desenvolver condições psiquiátricas. Em trabalho, Chandra e Krisha introduziram estrutura que utiliza métodos de linguagem com base em aprendizado profundo, por intermédio de memória de curto prazo longa (LSTM), para análise sentimental no momento do aumento de casos de Covid-19, na Índia. Deste modo, essa estrutura apresenta o método de linguagem LSTM, modelo recente de Representações de Codificador Bidirecional de Transformadores (BERT) e incorporação de vetor global. Neste sentido, salienta-se que abordagens baseadas em aprendizado profundo têm sido aplicadas na análise de dados biométricos, incluindo expressões faciais, entonação vocal e registros de variabilidade da frequência cardíaca, permitindo correlação mais intrínseca e compreensão acentuada dos sinais físicos associados à saúde mental.

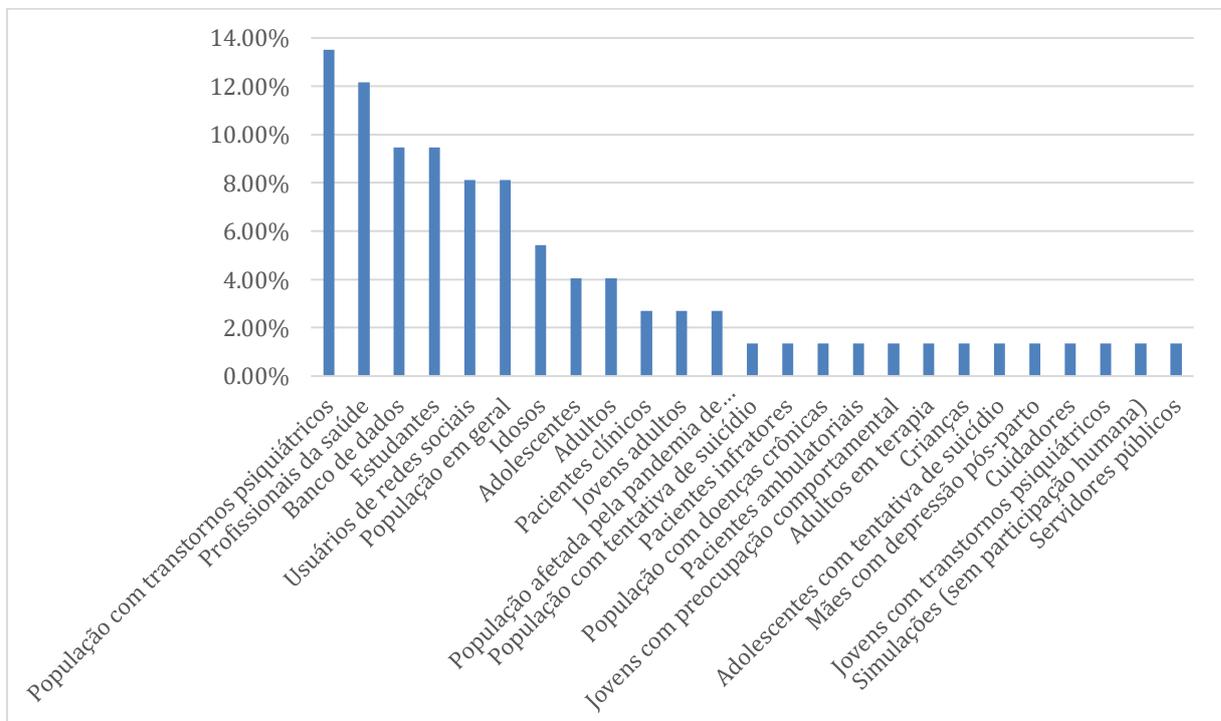
Outro achado significativo foi o uso crescente de assistentes virtuais e chatbots para oferecer suporte psicológico automatizado. Modelos como Wysa, Tess e ChatGPT foram constantemente avaliados quanto à eficácia na prestação de suporte emocional, aconselhamento terapêutico e triagem de sintomas. A literatura científica evidencia que os chatbots possuem grande potencial na saúde mental, como na revisão de Milne-Ives *et al.* (2020), que identificou que parcela significativa dos *chatbots* de saúde, cerca de 39%, foca em questões relacionadas à saúde mental. Outrossim, algumas dessas ferramentas foram desenvolvidas para promover

aspectos positivos da saúde mental, incluindo bem-estar emocional, autocompaixão, atenção plena e qualidade de vida. Outro achado que também está constância com as evidências científicas é a grande variabilidade de públicos que os *chatbots* abrangem, desde crianças e adolescentes até adultos e idosos, além de atenderem a populações clínicas específicas (Yunike *et al.*, 2023; Tosti; Corrado; Mancone, 2024; Miura *et al.*, 2022).

Dessarte, ressalta-se a importância das técnicas de Inteligência Artificial Explicável (XAI), que tiveram como foco tornar esses modelos mais interpretáveis e transparentes, garantindo maior confiabilidade e aceitação na prática clínica (Ali *et al.*, 2023). A exemplo disso, os estudos apresentaram modelos como SHAP e LIME que foram empregados para fornecer explicações detalhadas sobre as previsões dos algoritmos, possibilitando que os profissionais da saúde compreendam mais claramente os fatores determinantes dos diagnósticos gerados pela IA.

Ademais, o Gráfico 3 exibe a categorização do público participante dos estudos selecionados.

Gráfico 3 – Categorização dos estudos, de acordo com a população participantes.



Fonte: elaborado pelo autor (2025).

Observa-se no Gráfico 3 que as pesquisas possuíam tendências significativas sobre o perfil da população investigada. O maior percentual de estudos se concentrou em populações com transtornos psiquiátricos (13,51%) e profissionais da saúde (12,16%), sugerindo foco

predominante na validação de tecnologias para diagnóstico, monitoramento e suporte clínico. Entretanto, salienta-se que determinados trabalhos tiveram mais de um público-alvo, o que implicou na categorização em dois ou mais grupos.

Esse achado é coerente com o trabalho de Rogan, Firth e Bucci, (2024) que buscou avaliar a aplicabilidade da inteligência artificial em contextos clínicos, visando analisar as implicações na assistência de saúde, a partir da visão dos profissionais. Assim, os pesquisadores evidenciaram que ainda existem grandes nuances quanto aos fatores positivos e negativos do uso da IA. Os profissionais entrevistados destacaram a capacidade da tecnologia em motivar os usuários do serviço a serem mais ativos física ou socialmente, considerando a possibilidade de definir metas, receber alertas e obter informações comportamentais de dados coletados de modo passivo. Contudo, também se mostraram preocupados quanto ao agravamento das desigualdades no sistema de saúde mental, temendo que a clínica priorize usuários engajados com a tecnologia digital, em detrimento daqueles que não a utilizam. Além disso, alertaram que o uso de dispositivos digitais pode reduzir a humanização do atendimento, aumentando o sentimento de isolamento e abandono, devido à menor interação direta com os profissionais.

Outro estudo realizado na Austrália também enfatizou que o uso de IA pelos profissionais da saúde mental tem singularidades. Os profissionais utilizaram ferramentas de IA para pesquisa, administração e treinamento, e ressaltaram os benefícios no gerenciamento de tempo. No entanto, um terço expressou preocupações quanto à precisão e generalização dos resultados, destacando a necessidade de monitoramento contínuo da IA, no que se refere à eficácia e aplicabilidade. Além disso, foram levantadas preocupações sobre governança de dados e segurança, reforçando a necessidade de regulamentação, para que o uso responsável se torne realidade, assim como a confiança quanto ao uso da IA (Cross *et al.*, 2024).

Além disso, destaca-se o percentual dos estudos que utilizaram de bancos de dados (9,46%), indicando tendência crescente na utilização de registros eletrônicos de saúde, prontuários médicos e outras bases de dados preexistentes. Essa abordagem viabiliza análises em escala ampliada, sem a necessidade de recrutamento direto de participantes, o que pode ampliar a representatividade das pesquisas, ao mesmo tempo em que implica desafios metodológicos relacionados à curadoria e qualidade dos dados. Nesta perspectiva, Mattos e Mattjie (2024) apontam em trabalho que, embora essas técnicas ofereçam análises precisas e personalizadas, a complexidade e a heterogeneidade dos dados podem representar desafios na

generalização dos modelos. Eles também apontam para necessidade de grandes conjuntos de dados para treinamento e preocupações relacionadas à privacidade e ética dos dados.

A presença significativa de estudos envolvendo estudantes (9,46%) e usuários de redes sociais (8,11%) sugere interesse na compreensão dos impactos da inteligência artificial em grupos amplamente expostos a ambientes digitais e suscetíveis a TM. O estudo de Gao *et al.* (2020) investigou a prevalência de depressão, ansiedade e combinação de depressão e ansiedade durante o surto de Covid-19, em Wuhan, China. Os autores evidenciaram que mais de 80% dos participantes referiram exposição constante à mídia social. Os resultados mostraram ainda que houve alta prevalência de TM, os quais demonstraram relação à exposição frequente às mídias sociais, durante a pandemia da Covid-19. Ademias, a proximidade entre os percentuais desses grupos com o da população geral (8,11%) indica tendência de pesquisas tanto a aplicação da IA no monitoramento populacional quanto a viabilidade em contextos educacionais e digitais. Quanto à população de estudantes, essa também já possui importantes evidências científicas e exploração das condições de saúde mental por diversos estudos, como na revisão sistemática e metanálise de Sheldon *et al.* (2021), que apontou que as condições psicológicas dos estudantes sofrem influência multifatorial relacionadas às condições sociais, financeiras, familiares e acadêmicas.

Entretanto, verificou-se número reduzido de artigos relacionados a determinados grupos, como idosos (5,41%) e adolescentes (4,05%), o que pode indicar lacunas na literatura científica. Da mesma forma, outras populações específicas, como pacientes clínicos, jovens adultos e adultos em terapia, apresentaram percentuais ainda menores (2,70% ou menos). Esses achados podem ser indício de que o uso de IA para esses determinados públicos ainda está em processo de desenvolvimento e implantação, o que evidencia lacunas para maiores investigações em diversos aspectos.

Adicionalmente, é perceptível a baixa incidência de estudos voltados especificamente para o uso de IA, durante a pandemia da Covid-19 (2,70%), mesmo diante da implementação massiva de tecnologias de apoio à saúde, como canais de atendimento psicológico, realizado de maneira *on-line* (Correia *et al.*, 2023), aplicativos desenvolvidos para o apoio em saúde mental (Secchi; Scortegagna; Kantorski, 2024), uso das redes sociais para divulgar atividades e informações (Rodrigues *et al.*, 2022), entre outras estratégias. Quando se trata de IA, o quantitativo de estudos se mostrou discreto, conforme o Gráfico 3. O mesmo ocorreu com grupos vulneráveis, como indivíduos com tentativas de suicídio (1,35%), pacientes infratores

(1,35%), mães com depressão pós-parto (1,35%) e servidores públicos (1,35%). Essa baixa representatividade sugeriu campo de pesquisa ainda pouco explorado, que poderia beneficiar-se da implementação de tecnologias baseadas em IA para monitoramento, intervenção e suporte psicológico direcionado.

Diante desses resultados, torna-se interessante salientar que, embora os estudos sobre IA aplicada à saúde mental tenham avançado, ainda há necessidade de maiores estudos, com enfoque na representatividade dos participantes investigados. O predomínio de pesquisas direcionadas para populações psiquiátricas e profissionais da saúde é indicativo que essa área ainda está em processo de expansão para grupos historicamente sub-representadas, como indivíduos em situação de vulnerabilidade, saúde mental materno-infantil, população com ideação suicida, entre outros. A ampliação da diversidade das amostras é fundamental para garantir que as soluções tecnológicas desenvolvidas sejam eficazes, acessíveis e adaptáveis às especificidades de diferentes segmentos populacionais, promovendo impacto mais abrangente e equitativo, no âmbito do cuidado a pessoas com TM.

No que diz respeito às IAs mais empregadas na realização das pesquisas, essas estão expostas na Tabela 1.

Tabela 1 – Distribuição dos modelos de IA mais utilizados.

(continua)

Modelos	Percentuais
Random Forest	9.73%
SVM	9.34%
LR	6.61%
XGBoost	5.84%
kNN	5.06%
Naive Bayes	3.89%
ANN	3.50%
Decision Tree	3.50%
Chatbots de Saúde	3.50%
CNN	3.11%
LightGBM	2.33%
LSTM	2.33%
Assistentes Virtuais	2.33%
ChatGPT	1.95%
ChatGPT-4	1.95%
Gradient Boosting	1.95%
ChatGPT-3.5	1.56%
Bard	1.56%
Regressão Regularizada	1.56%
AdaBoost	1.56%

Tabela 1 – Distribuição dos modelos de IA mais utilizados.

(continua)

Modelos	Percentuais
RoBERTa	1.17%
CatBoost	1.17%
CART	0.78%
Claude	0.78%
MLP	0.78%
Adam	0.78%
LDA	0.78%
BERT	0.78%
Redes Neurais	0.78%
MIL	0.39%
ResNet	0.39%
DenseNet	0.39%
EfficientNet	0.39%
SHAP	0.39%
LLaMA-2	0.39%
Regressão Linear	0.39%
IEL	0.39%
Transformers	0.39%
SpeechBrain Framework	0.39%
Demucs	0.39%
SGD	0.39%
Voting Classifiers	0.39%
Bagging Meta-Estimator	0.39%
GPT	0.39%
GPT2	0.39%
AIBERT	0.39%
LogitBoost	0.39%
Modelos Multi-Tarefa	0.39%
LIME	0.39%
GBM	0.39%
GRU	0.39%
CNN-LSTM	0.39%
TEO	0.39%
IGCBA	0.39%
BPNN	0.39%
BBA	0.39%
HIDA	0.39%
GCBA	0.39%
IG-bBOA	0.39%
HLBDA	0.39%
ReLU	0.39%
Deep Multimodal Neural Networks	0.39%
GloVe	0.39%
Modelo de Ensemble	0.39%

Tabela 1 – Distribuição dos modelos de IA mais utilizados.

(conclusão)

Modelos	Percentuais
BoBW	0.39%
NEPAR	0.39%
EDNN	0.39%
Informação Mútua	0.39%
Seq2Seq	0.39%
RNN	0.39%
TensorFlow	0.39%
Keras	0.39%
FastText	0.39%
Sent2Vec	0.39%
Kaldi Speech Recognition Toolkit	0.39%
Deep Learning	0.39%
Apriori Algorithm	0.39%
FIS	0.39%
K-means	0.39%
WEKA	0.39%

Fonte: elaborado pelo autor (2025).

Dentre os 75 modelos apresentados na Tabela 1, foi possível destacar maior percentual de utilização para RF (9.73%), SVM (9.34%), LR (6.61%). O RF é um algoritmo de aprendizado de máquina, baseado em um conjunto de árvores de decisão, essas árvores se comportam como caminhos concebidos por diversas perguntas que podem gerar resposta final. A principal característica é a combinação de múltiplas árvores – ou seja múltipla variáveis – para obter previsões mais precisas e reduzir o risco de *overfitting* (quando um modelo aprende demais os detalhes dos dados de treino, ficando "viciado" neles e tendo dificuldade em generalizar para novos dados), um problema comum em modelos baseados em árvores individuais (Khan *et al.*, 2021).

O RF se comporta como grupo de especialistas que tomam decisões em conjunto. Deste modo, ele cria diversas árvores de decisão, cada um analisando uma parte diferente dos dados. Essas partes são selecionadas de forma aleatória e algumas informações podem ser repetidas, enquanto outras podem não ser usadas. Além disso, cada árvore considera apenas algumas das características disponíveis, o que faz com que cada uma analise de modo um pouco diferente (Khan *et al.*, 2021).

Quando chega o momento de fazer uma previsão, todas as árvores "votam" no resultado. Se for um problema de classificação, a exemplo de identificar se um paciente tem maior risco de depressão ou ansiedade embasado em histórico e sintomas, cada árvore dá

opinião, e a opção mais votada é a resposta final. Se for um problema de regressão, como prever os índices de estresse de uma pessoa, mediante os hábitos de sono e rotina, o modelo calcula a média dos valores sugeridos por cada árvore. Esse processo faz com que o RF seja mais preciso e menos influenciado por variações nos dados, tornando as previsões mais confiáveis, no contexto da saúde mental (Khan *et al.*, 2021).

O RF possui diversas vantagens consideráveis, como a capacidade administrar grandes volumes de dados e variáveis irrelevantes, além de ser menos suscetível a *overfitting*, em comparação com única árvore de decisão. Contudo, a desvantagem é o custo computacional elevado, em razão de que múltiplas árvores precisam ser treinadas e armazenadas (Khan *et al.*, 2021). Mesmo assim, o desempenho robusto e a versatilidade o tornam um dos algoritmos mais utilizados em aprendizado de máquina, conforme Tabela 1.

Quanto ao SVM, este é um modelo de IA que ajuda a separar grupos de informações da melhor forma possível. Ele funciona como uma linha (ou plano, em casos mais complexos) que divide os dados em categorias diferentes. Neste sentido, em pesquisa que tem como intuito identificar se uma pessoa tem maior risco de ideação suicida ou não, pela fundamentação de sintomas como padrões de sono, nível de estresse e humor, o SVM analisa esses dados e traça "fronteira" que separa a amostra em dois grupos: os que têm maior risco e os que não têm. Essa fronteira é delimitada de maneira que a separação seja a mais clara e eficiente possível, garantindo que novos casos possam ser classificados corretamente (Bansal Goyal; Choudhary, 2022).

Caso os pesquisadores estejam trabalhando com problema de regressão, como prever o nível de ansiedade de um paciente com base em atividades diárias, o SVM tenta encontrar uma linha que melhor represente os dados e permita fazer previsões precisas. O diferencial do SVM é a capacidade de encontrar a maneira mais eficiente de organizar os grupos, buscando garantir maior precisão, mesmo com a complexidades dos dados (Bansal Goyal; Choudhary, 2022).

A LR empregado, principalmente, para classificações, ou seja, para prever se determinado fator pertence a um grupo ou outro. Ele funciona calculando a probabilidade de um evento acontecer com base nos dados disponíveis. A LR pode utilizada para analisar dados e calcular a probabilidade uma pessoa desenvolver determinado transtorno mental. Se essa probabilidade for maior que um certo limite, o modelo classifica a pessoa como de alto risco; se for menor, classifica como de baixo risco (Song *et al.*, 2021). Conforme é possível observar

no trabalho de Panda *et al.* (2022), a RL se comporta como importante ferramenta estatística para prever variáveis dicotômicas em estudos de saúde. O estudo apresenta exemplo prático utilizando a linguagem R para modelar a mortalidade de pacientes com base em sete variáveis independentes. Após análises univariadas e multivariadas, concluiu-se que idade, Índice de Massa Corporal (IMC), concentração de lactato e hemoglobina foram fatores estatisticamente significativos. A validação do modelo mostrou que a RL é eficaz para prever desfechos clínicos e auxiliar na tomada de decisões por profissionais da saúde.

Como é possível observar pela estrutura, a RL se diferencia de modelos como o SVM ou RF, que podem ser mais complexos. Assim, esse se caracteriza como modelo mais simples e eficiente para muitos tipos de problemas de classificação, especialmente quando há relação clara entre os fatores analisados e o resultado esperado.

No Quadro 4, demonstra-se a síntese das principais informações presentes nos resultados e nas conclusões dos trabalhos selecionados.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
1	Kim <i>et al.</i> , (2020).	Os modelos CNN superaram o XGBoost em acurácia geral para todos os subreddits, com destaque para classificação de depressão, que alcançou 79,49% no F1-score. No entanto, classes com menos dados, como autismo, apresentaram desempenho inferior, devido ao problema de desequilíbrio de classes.	Os dados de redes sociais podem ser usados para identificar transtornos mentais com boa precisão, sugerindo que essas plataformas podem servir como ferramentas complementares para monitoramento de saúde mental. Contudo, foram reconhecidas limitações, como a ausência de dados demográficos e a necessidade de validação com outras fontes. Futuros trabalhos podem explorar abordagens de ensemble e análises temporais para melhorar a detecção e o manejo de comorbidades.
2	Baqir <i>et al.</i> , (2024)	O modelo de classificação baseado em Support Vector Machine (SVM) demonstrou o melhor desempenho entre os algoritmos testados, atingindo acurácia de 83,29% quando utilizamos unigramas como características. Os demais classificadores, como k-Nearest Neighbors, Random Forest, Naïve Bayes apresentaram resultados inferiores, com acurácia variando entre 76,61% (kNN), RF (80,67%), 81,86% (NB). A pesquisa analisou mais de 3,96 milhões de tweets, os quais foram filtrados e rotulados, de acordo com os critérios do CID-11, para identificar sintomas relacionados ao Transtorno de Estresse Pós-Traumático (TEPT). A maior parte das postagens se enquadrou na categoria "Outros sintomas afetivos e biológicos relacionados ao TEPT". Análise temporal das postagens revelou padrão interessante: muitos usuários apresentaram mudança de comportamento ao longo do tempo, migrando da categoria "Evitação" para a categoria "Não relacionado ao TEPT" e vice-versa.	O modelo é eficaz para identificar potenciais sintomas de TEPT em sobreviventes de Covid-19, com base em postagens no Twitter, destacando o potencial do aprendizado de máquina para triagem precoce de saúde mental. O estudo focou exclusivamente em tweets em inglês, limitando a aplicabilidade do modelo a outras línguas e culturas. Alguns erros de classificação ocorreram, devido à dependência de palavras-chave, resultando em falsos positivos, em casos em que as palavras-chave não estavam diretamente relacionadas à Covid-19. Estudos futuros poderiam expandir o conjunto de dados para incluir tweets em diferentes idiomas e contextos culturais. Adicionalmente, explorar respostas e comentários às postagens pode oferecer análise mais profunda do impacto do TEPT na interação social.
3	Banerjee <i>et al.</i> , (2024)	O estudo revelou que o interesse público nos Estados Unidos por Inteligência Artificial (IA) aplicada à saúde mental cresceu significativamente em 2023, com previsão de aumento de 114% até o final de 2024. Em 2023, o termo "IA" aumentou constantemente de janeiro em diante. O termo "IA" atingiu o máximo em abril. O termo "IA e Saúde Mental" atingiu o RSV máximo em outubro, demonstrando aumento mais gradual. O RSV para os termos "IA e Depressão" e "IA e Ansiedade" atingiu o máximo em novembro. A análise evidenciou distribuição desigual de profissionais de saúde mental, com escassez crítica em áreas rurais, destacando o potencial da IA para suprir essas deficiências.	As conclusões apontaram que a IA pode oferecer melhorias significativas em diagnósticos, triagem e terapias personalizadas em saúde mental. No entanto, é fundamental enfrentar desafios como privacidade, vieses nos modelos e questões éticas. Recomenda-se investir na alfabetização digital em saúde, aprimorar os dados de treinamento e integrar a IA com práticas tradicionais para ampliar o impacto positivo.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
4	Gradus <i>et al.</i> , (2021)	A prevalência de tentativas de suicídio não fatais foi ligeiramente maior entre mulheres (9,1%) do que entre homens (6,8%). Os indivíduos que tentaram suicídio eram, em média, mais jovens e solteiros, em comparação com a população geral. Homens: o maior risco de tentativa de suicídio foi observado em homens com diagnóstico de envenenamento e sem tratamento para depressão, seguido por homens mais jovens com transtorno de estresse e sem tratamento. Mulheres: mais jovens, aposentadas precocemente e com diagnóstico de envenenamento, sem tratamento para depressão, apresentaram o maior risco. As árvores de classificação e regressão (CART) e as florestas aleatórias (RF) identificaram diversos preditores de tentativa de suicídio, incluindo transtornos psiquiátricos (depressão, transtorno de estresse, abuso de substâncias), uso de medicamentos (antidepressivos, antipsicóticos, sedativos), fatores sociodemográficos (idade, estado civil, renda) e condições de saúde física (envenenamento, problemas gastrointestinais). Os modelos RF apresentaram excelente precisão na previsão de tentativas de suicídio, com área sob a curva ROC (AUC) próxima ou superior a 0,90. Os modelos identificaram grupos de alto risco com alta sensibilidade e especificidade.	Os resultados destacaram a complexidade dos fatores que contribuem para as tentativas de suicídio, incluindo fatores psiquiátricos, sociais e físicos. A falta de tratamento para condições psiquiátricas, como depressão e transtorno de estresse, emergiu como fator de risco significativo. Os modelos de predição podem ser utilizados para identificar indivíduos em risco e direcionar intervenções preventivas. Os resultados devem ser interpretados com cautela, devido às limitações, como a possibilidade de classificação incorreta de tentativas de suicídio e a generalização dos resultados para outros contextos culturais. É necessário realizar mais pesquisas para validar os resultados em diferentes populações, explorar outros métodos de classificação e investigar o impacto da classificação incorreta de tentativas de suicídio nos modelos.
5	Zhang <i>et al.</i> (2023)	O estudo apresentou modelo de aprendizado profundo, chamado <i>Multiple Instance Learning</i> (MIL) que, com base em Ressonâncias Magnéticas (RM), conseguiu identificar casos de Doenças Mentais Graves (DMG) com AUC de 0,82, no conjunto de validação. Comparado a outros modelos, como ResNet, DenseNet e EfficientNet, o MIL mostrou melhor generalização e menor perda de desempenho ao mudar de dispositivos de 3.0T para 1.5T. O modelo teve sensibilidade de 77% no conjunto principal e manteve robustez em dados coletados com diferentes equipamentos, incluindo scanners de campo magnético mais fracos. Em cenários reais, como entre estudantes de medicina sob alto estresse, o MIL teve sensibilidade consideravelmente superior na detecção de sintomas emocionais clínicos, comparado a autorrelatos.	Os resultados indicaram que o MIL é promissor para triagem precoce de doenças mentais em populações de risco, oferecendo precisão adequada com dados de RM de baixa resolução, frequentemente, usados em contextos clínicos. A generalização robusta sugere potencial para uso em diferentes configurações de escaneamento. O modelo também superou a sensibilidade de autorrelatos em identificar sinais de angústia emocional, o que pode reduzir subnotificações, devido ao estigma. No entanto, melhorias adicionais são necessárias para reduzir falsos positivos e aumentar a especificidade, sugerindo que abordagem híbrida, combinando modelos com observações clínicas, pode ser ideal.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
6	Elyoseph; Levkovich, (2024)	<p>Os resultados indicaram que os modelos de linguagem generativa ChatGPT-4, Claude e Bard apresentaram prognósticos alinhados às avaliações de profissionais de saúde mental, como psiquiatras e psicólogos clínicos, enquanto o ChatGPT-3.5 demonstrou viés mais pessimista. Todos os LLMs reconheceram que o tratamento profissional poderia melhorar a condição dos pacientes com esquizofrenia, mas variaram em termos de otimismo. ChatGPT-4 e Bard foram os mais otimistas, enquanto Claude se posicionou de forma intermediária e ChatGPT-3.5 projetou resultados mais negativos, o que pode influenciar a motivação dos pacientes.</p> <p>Quanto aos cenários sem tratamento, os quatro modelos concordaram que a condição dos pacientes permaneceria a mesma ou pioraria, alinhando-se às expectativas dos profissionais de saúde e da literatura clínica. Em relação aos resultados de longo prazo, Claude e ChatGPT-4 foram mais pessimistas quanto a desfechos negativos, enquanto Bard foi mais otimista. ChatGPT-3.5, por outro lado, destacou-se por prever menos melhorias nos resultados positivos de longo prazo, em comparação com os outros modelos. Além disso, todos os LLMs previram alta probabilidade de discriminação social contra pacientes diagnosticados com esquizofrenia.</p>	<p>Os LLMs demonstraram potencial promissor como ferramentas auxiliares no apoio a decisões clínicas em saúde mental, especialmente ChatGPT-4, Claude e Bard, que mostraram maior alinhamento com as avaliações profissionais. No entanto, o pessimismo de ChatGPT-3.5 pode reduzir a motivação de pacientes e famílias a buscar tratamento, destacando a importância de calibrar a comunicação dessas ferramentas para evitar impactos adversos. Apesar do potencial, os LLMs ainda exigem validação rigorosa e integração cuidadosa com a expertise humana, uma vez que as limitações podem influenciar negativamente as decisões terapêuticas e o engajamento no tratamento. Assim, enquanto oferecem <i>insights</i> valiosos, a aplicação deve ser realizada em conjunto com profissionais de saúde, garantindo que sejam usados de forma ética e eficaz.</p>
7	Tate <i>et al.</i> , (2020)	<p>Os resultados mostraram que os modelos de aprendizado de máquina conseguiram prever problemas de saúde mental em adolescentes com desempenho razoável, alcançando AUC máxima de 0,739 no conjunto de teste, usando o modelo de floresta aleatória. A técnica de SMOTEBoost foi eficaz para lidar com o desequilíbrio de classe, garantindo previsões consistentes, mesmo com a baixa prevalência de casos positivos (12% da amostra). O desempenho geral foi semelhante entre as técnicas testadas, com a floresta aleatória e as máquinas de vetores de suporte (SVM) apresentando os melhores resultados (AUCs de 0,739 e 0,735, respectivamente), embora as diferenças entre os modelos não tenham sido estatisticamente significativas.</p> <p>Preditores importantes incluíram sintomas relatados pelos pais, como impulsividade e desatenção, além de fatores como qualidade da vizinhança e idade gestacional. O valor preditivo negativo foi alto (96%), mas o valor preditivo positivo foi limitado (15%). A análise de sensibilidade mostrou robustez do modelo, mesmo com diferentes critérios de corte. Apesar do bom desempenho, a precisão foi insuficiente para uso clínico, e limitações, como a representatividade da amostra e possíveis vieses, foram destacadas.</p>	<p>Os modelos apresentaram desempenho razoável, com AUCs similares entre as técnicas, mas sem superioridade estatisticamente significativa de nenhum método. Embora o aprendizado de máquina seja promissor para integrar riscos de diferentes domínios e prever problemas de saúde mental na adolescência, a aplicação clínica ainda é prematura, especialmente em estudos com dados menores e relações predominantemente lineares, em que a regressão logística pode ser suficiente. Os resultados reforçaram a importância da triagem precoce de sintomas de neurodesenvolvimento e dificuldades de aprendizagem em crianças como medida preventiva. Além disso, intervenções oportunas podem mitigar significativamente os impactos negativos de problemas de saúde mental na adolescência, destacando o potencial de estratégias preventivas bem direcionadas.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
8	Kundu <i>et al.</i> , (2022)	O modelo Random forest apresentou desempenho considerado satisfatório na previsão da busca por ajuda, com uma área sob a curva característica de operação do receptor (AUC) de 0,85. No entanto, o modelo mostrou desempenho insatisfatório para prever atrasos no acesso aos cuidados, com AUC de 0,61, o que sugere a ausência de variáveis-chave no conjunto de dados para capturar completamente os fatores subjacentes a esse fenômeno.	O baixo desempenho dos modelos de Random forest destinados a prever o atraso no acesso ao atendimento justifica pesquisas adicionais usando conjuntos de dados mais abrangentes que incluam fatores medidos em estruturas e processos de níveis de atendimento.
9	Garcia-Valdez <i>et al.</i> , (2024)	Modelos treinados com dados de fala, especialmente utilizando o algoritmo Random Forest, foram capazes de identificar padrões, como uniformidade na fala, associada a uma voz tensa ou fraca em pacientes com PTSD. Foi observado que, em mulheres, os modelos priorizaram características, como variações no volume vocal, fechamento glotal reduzido e fonação interrompida, indicando alterações na qualidade vocal. Já, em homens, os modelos destacaram alterações na ressonância vocal, resultando em uma voz mais fina e fraca, refletindo dificuldades no controle da fonação.	É importante considerar diferenças de sexo na análise de dados biométricos para detecção de PTSD, destacando o potencial de algoritmos de XAI para fornecer explicações claras sobre os indicadores identificados. O estudo representa avanço na identificação de indicadores de PTSD, sugerindo que abordagens baseadas em dados biométricos e aprendizado de máquina podem melhorar a precisão e a compreensão do diagnóstico desse transtorno.
10	Hoffmann <i>et al.</i> , (2024)	Dos sete algoritmos aplicados no processo de construção do modelo, o <i>gradient boosting</i> mostrou os melhores parâmetros de desempenho no conjunto de treinamento, mas a AUC rendeu apenas 0,69. Com sensibilidade de 77%, o algoritmo identificou quase ¾ de todas as amostras NOP corretamente. Ao mesmo tempo, o algoritmo de melhor desempenho foi capaz de identificar apenas metade de todas as amostras OP corretamente.	Apenas variáveis sociodemográficas não são suficientes para explicar diferenças entre pacientes ofensores e não ofensores com TSE. O desempenho moderado do modelo sugere que outros fatores, como integração social e comorbidades psiquiátricas, desempenham papéis significativos. O Aprendizado de Máquina Supervisionado facilita múltiplas chances de explorar padrões não detectados dentro de conjuntos de dados complexos. Em particular, o campo pouco pesquisado da psiquiatria forense se beneficia desses métodos modernos e, cada vez mais, disponíveis.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
11	Giorgi <i>et al.</i> , (2024)	<p>O estudo avaliou os sistemas ChatGPT-4 e LLaMA-2 quanto à adequação, pertinência e qualidade geral de respostas relacionadas ao uso de substâncias, destacando limitações em consistência e precisão. No ChatGPT-4, as concordâncias foram moderadas (γ: 0,68, 0,65 e 0,49 para adequação, pertinência e qualidade geral, respectivamente), enquanto o LLaMA-2 apresentou melhor adequação (γ: 0,89), mas menor pertinência (γ: 0,56). A qualidade geral foi semelhante entre os sistemas (γ: 0,49). Diferenças significativas foram observadas entre os sistemas para maconha, opioides e no conjunto geral ($p < 0,05$), mas não para álcool. Embora a maioria das respostas estivesse acima do ponto médio de qualidade, ambos os sistemas geraram exemplos perigosos ou não factuais, como recomendações inadequadas de microdosagem e citações de fontes inexistentes.</p> <p>Ao reformular perguntas sobre desintoxicação de heroína, o ChatGPT-4 respondeu que era seguro em 23% das vezes, apesar dos riscos. Em questões sobre Lorazepam e Clonazepam, o modelo deu respostas conflitantes: escolheu Lorazepam 32%, Clonazepam 17% e recusou-se a responder 51%. Esses resultados ressaltaram a inconsistência dos modelos e a necessidade de supervisão humana em cenários de alto risco.</p>	<p>Os resultados mostraram que esses sistemas são, geralmente, vistos como dando respostas de qualidade a perguntas sobre uso de substâncias no mundo real, mas, muitas vezes, podem gerar respostas perigosas, contraditórias e imprecisas. Se os sistemas de IA fossem adotados por instituições médicas e de saúde pública, tais estratégias de tratamento automatizadas (ou não humanas) poderiam contribuir para esses problemas, resultando em maiores desigualdades na assistência médica. Ao avançar em direção à humanização da assistência médica e estratégias de redução de danos, é fundamental considerar tais consequências.</p>
12	Jain; Pareek; Carlbring, (2024)	<p>Os resultados do estudo indicaram que, ao revelar a origem das respostas (IA ou humana), houve mudança significativa na percepção de autenticidade, mas não nas demais dimensões. Em termos de autenticidade, as respostas humanas receberam classificações médias significativamente mais altas (37,66) do que as da IA (34,85), com diferença estatisticamente significativa, evidenciando que os participantes consideraram as interações humanas mais genuínas e sinceras, quando a fonte foi divulgada. Curiosamente, na avaliação cega anterior, o ChatGPT tinha sido percebido como mais autêntico. Para profissionalismo, a IA obteve média ligeiramente superior (36,85) em relação às respostas humanas (35,83), mas a diferença não foi estatisticamente significativa, sugerindo que ambos foram vistos como igualmente competentes. Quanto à praticidade, as respostas humanas também tiveram pontuação média ligeiramente maior (37,05), em comparação à IA (36,24), mas essa diferença não atingiu significância estatística. Além disso, a escala de confiança em robôs se correlacionou significativamente com a percepção de praticidade, mas não com autenticidade ou profissionalismo. Comparando avaliações cegas e informadas, as percepções sobre as respostas da IA permaneceram consistentes, enquanto as respostas humanas receberam classificações significativamente mais altas nos três domínios (autenticidade, profissionalismo e praticidade) na avaliação informada. Em particular, as diferenças em autenticidade e profissionalismo para respostas humanas foram altamente significativas, com praticidade também mostrando alta significância.</p>	<p>O estudo concluiu que a conscientização do envolvimento da IA altera a percepção do usuário sobre as interações, com respostas humanas geralmente percebidas como mais autênticas e práticas em comparação à IA. Isso destaca o valor insubstituível da empatia humana no suporte à saúde mental. Embora a IA seja reconhecida pelo papel profissional e informativo, ela é vista como suplemento e não como um substituto para interação humana em serviços de saúde mental. A confiança na IA foi notavelmente correlacionada com a praticidade percebida, destacando o papel da IA como ferramenta técnica e não como sistema de suporte emocional.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
13	Hein <i>et al.</i> , (2024)	<p>O estudo dividiu os participantes em dois grupos no momento inicial: Nenhum Risco de Ansiedade (95%) e Sim Risco de Ansiedade (5%). Para análise de aprendizado de máquina (ML), o grupo menor foi balanceado com a técnica k-NN SMOTE*, resultando em proporções iguais de 50% Sim e 50% Não. Os dados foram divididos em 80% para treinamento e 20% para teste, com validação cruzada e bootstrapping usados para calibrar os modelos.</p> <p>Foram testados modelos preditivos como LASSO, Random Forests, SVM-Kernel, Naive Bayes e Logistic Regression. O desempenho foi avaliado com métricas como precisão, AUC, sensibilidade e F1-score, destacando-se o Random Forests, que superou os demais em ambas as ondas de análise.</p> <p>O estudo apontou que:</p> <ul style="list-style-type: none"> - Vínculo com o avatar e imersão foram os preditores mais significativos para ansiedade simultânea; - Compensação foi o preditor mais relevante para ansiedade prospectiva. <p>A análise reforça que o modelo Random Forests é ideal para prever o risco de ansiedade, com resultados consistentemente superiores nas métricas de desempenho.</p>	<p>O estudo destaca o potencial do vínculo entre usuários e avatares (UAB) para prever o risco de ansiedade, mas enfrenta limitações, como a dependência de dados autorrelatados, amostra demograficamente restrita e baixa proporção de participantes com alto risco de ansiedade. Apesar disso, o UAB se mostrou promissor na identificação precoce de problemas de saúde mental, mas requer validação adicional para consolidar o uso em avaliações digitais.</p> <p>Pesquisas futuras devem incluir métricas comportamentais objetivas, explorar diferenças entre gêneros de jogos e expandir características do ciberfenótipo, como motivações para jogar. Amostras maiores e mais diversificadas também são essenciais para validar os achados e ampliar a aplicabilidade.</p>
14	Dhariwal <i>et al.</i> , (2024)	<p>O estudo analisou a relação entre fatores ambientais, estilo de vida e transtornos mentais, utilizando resultados do teste de Stroop como suporte quantitativo. A pesquisa previu a prevalência de transtornos mentais como acima ou abaixo da média da população, obtendo alta precisão nos modelos de aprendizado profundo (DL) e aprendizado de máquina (ML). O modelo DNN1 apresentou a melhor precisão, de 99,79%, seguido por DNN4 (99,77%). Entre os modelos de ML, XGBoost e Regressão Logística tiveram desempenho semelhante, com precisão de 95,31% e 95,43%, respectivamente. O KNN teve o pior desempenho, com apenas 58,3%.</p> <p>Os modelos DL superaram os de ML em todos os parâmetros de desempenho, como precisão, exatidão, recall e F-score, embora com maior tempo computacional. O modelo DNN1, por exemplo, levou cerca de 155 segundos para ser treinado e testado em 100 épocas. As curvas de aprendizado dos modelos DL, como DNN1, DNN2 e DNN4, mostraram boa convergência entre as perdas de treinamento e validação e as precisões de treinamento e validação, indicando bom treinamento dos modelos. O estudo confirma que os modelos DL são eficazes na pesquisa de tendências em saúde mental e corroboram conclusões da literatura.</p>	<p>O resultado do trabalho ajudará a entender os efeitos severos das escolhas que eles fazem ao usar álcool e cigarros na saúde mental. Os escopos futuros incluem o desenvolvimento de um conjunto de dados que representa todas as esferas da vida e todos os dados demográficos, treinando, assim, por sua vez, um modelo de IA mais generalizado para prever a ocorrência de saúde mental. Este estudo deve ajudar médicos e especialistas em saúde mental a prever a ocorrência de saúde mental, especialmente em casos de desastres naturais ou adversidades que podem alterar o ambiente.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos seleccionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
15	Kharrat <i>et al.</i> , (2024)	<p>Os modelos de previsão para suicídio mostraram que o XGBoost teve a maior precisão para homens (0,97) e mulheres (0,98), seguidos por RF, MLP e LR. A sensibilidade dos modelos variou entre 31% e 38% para homens e 40% a 47% para mulheres, indicando que identificaram corretamente proporção dos casos de suicídio. A especificidade foi alta (0,97–0,99) e o valor preditivo positivo (PPV) foi mais baixo, variando entre 0,20 e 0,25 para homens e 0,11 e 0,19 para mulheres. O desempenho geral do modelo feminino foi superior ao masculino.</p> <p>A importância dos recursos foi analisada tanto com coeficientes absolutos quanto com SHAP. Para ambos os sexos, os principais fatores de risco para suicídio incluíram idade, consultas ambulatoriais com especialistas em transtornos físicos, orçamento regional de saúde mental, consultas de psicoterapia com psiquiatras e histórico de trauma não intencional. A análise SHAP revelou que, para os homens, o trauma não intencional foi forte indicativo de risco de suicídio, enquanto para as mulheres, a privação social e material esteve fortemente associada ao aumento do risco.</p>	<p>Os modelos de ML incluíram variáveis de níveis individual, programático, sistêmico e comunitário disponíveis rotineiramente para tomadores de decisão e planejadores em sistema de assistência médica pública gerenciada. Deve-se ter cautela na interpretação de variáveis associadas em modelo preditivo, pois elas não são causais, e outros designs são necessários para estabelecer o valor de tratamentos individuais. Os próximos passos são produzir interface de usuário intuitiva para tomadores de decisão, planejadores e outras partes interessadas, como clínicos ou representantes de famílias e pessoas com experiência ao vivo de comportamentos suicidas ou morte por suicídio.</p>
16	Berrezueta-Guzman <i>et al.</i> , (2024)	<p>A avaliação do ChatGPT personalizado pelos dez terapeutas revelou várias forças e áreas de melhoria. O modelo se destacou pela habilidade em usar linguagem envolvente, manter o interesse dos pacientes, promover a participação ativa e criar atmosfera positiva nas sessões de terapia. A capacidade de adaptar interações com base no paciente foi notável, além de fomentar autonomia e autoexpressão. Contudo, a confidencialidade e privacidade foram áreas de preocupação, com os terapeutas destacando que crianças não devem ser solicitadas a compartilhar segredos com a IA. Além disso, a sensibilidade cultural e a capacidade de lidar com diferentes idiomas e expressões culturais foram vistas como insuficientes em algumas situações.</p> <p>Em termos de atributos terapêuticos, a comunicação e a linguagem receberam as melhores classificações, enquanto a confidencialidade e a privacidade foram as mais baixas. A incapacidade de interpretar sinais não verbais, como a linguagem corporal, foi limitação significativa, especialmente em ambiente terapêutico. Isso, no entanto, será abordado no desenvolvimento de um assistente robótico, que incluirá uma câmera para detectar esses sinais. A avaliação detalha os pontos fortes e as deficiências do modelo, fornecendo <i>insights</i> para ajustes futuros.</p>	<p>O ChatGPT oferece suporte a cuidadores e educadores na gestão do TDAH. Contudo, surgiram preocupações quanto à confidencialidade e privacidade, especialmente sobre a ética de encorajar crianças a confiar segredos a uma IA. A sensibilidade cultural e a capacidade de interpretar pistas não verbais também foram destacadas como limitações do modelo. Essas questões precisam ser abordadas para aumentar a eficácia do ChatGPT, especialmente em contextos terapêuticos diversos.</p> <p>Outros desafios incluem o uso indevido do modelo para gerar informações enganosas e as dificuldades em detectar conteúdo falso. O estudo sugere a importância de melhorar a segurança, a confiabilidade das respostas e a estabilidade dos modelos de IA. Em conclusão, a pesquisa enfatiza a necessidade de abordagem responsável e ética no uso de IA, visando maximizar os benefícios enquanto minimiza os riscos.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
17	Alanézi, (2024)	O estudo revelou o uso do ChatGPT para suporte à saúde mental, destacando benefícios e desafios. Entre os benefícios, a psicoeducação foi enfatizada por todos os participantes, que consideraram o ChatGPT útil para aprender sobre transtornos mentais, sintomas, causas e tratamentos, promovendo maior alfabetização em saúde mental. Mais de 50% dos participantes destacaram o apoio emocional oferecido, com respostas empáticas, espaço para expressão sem julgamentos e validação emocional. O ChatGPT também foi reconhecido por auxiliar na definição de metas e fornecer suporte motivacional para mudanças positivas, como parar de fumar e adotar hábitos saudáveis. Alguns participantes apontaram que ele oferece informações úteis sobre recursos de saúde mental, como livros, artigos, terapeutas e serviços locais. Além disso, a maioria relatou que o ChatGPT facilitou a autoavaliação e o monitoramento de sintomas, sugerindo práticas de autocuidado. Embora poucos participantes tenham explorado técnicas de Terapia Cognitivo-Comportamental (TCC), eles mencionaram o auxílio do ChatGPT na identificação e substituição de pensamentos negativos. Também, foi destacado o suporte em crises, com informações sobre linhas de ajuda e recursos de emergência, e a facilitação de exercícios psicoterapêuticos, como diário reflexivo e técnicas de pensamento positivo.	Apesar dos vários desafios, ferramentas com tecnologia de IA como o ChatGPT têm o potencial de fornecer suporte valioso à saúde mental para pacientes, quando usadas adequadamente e como parte de um plano abrangente de cuidados de saúde mental. Portanto, é importante considerar cuidadosamente esses desafios e desenvolver estratégias apropriadas para mitigá-los, a fim de garantir o uso seguro e eficaz de aplicativos baseados em IA, como o ChatGPT, no suporte à saúde mental. Além disso, a área de aplicação do ChatGPT na área da saúde está sob pesquisa e requer atenção imediata entre os pesquisadores para expandir o escopo da pesquisa associada ao ChatGPT, pois tem enorme potencial para melhorar os serviços de saúde.
18	Ayodele; Adetunla; Akinlabi, (2024).	O modelo Random Forest alcançou os melhores resultados, com um R ² de 0,93 e erro médio absoluto (MAE) de 0,51, destacando-se em relação aos demais algoritmos. Ele foi capaz de identificar 50 fatores de risco gerais associados à depressão, como idade, gênero, status socioeconômico, índices de obesidade e histórico familiar de transtornos mentais. Além disso, o modelo forneceu insights personalizados, permitindo identificar os fatores mais relevantes para cada indivíduo, o que potencializa a personalização de intervenções clínicas. Os resultados também evidenciaram que o RF superou algoritmos como XGBoost e SVM, em termos de precisão explicativa e capacidade preditiva, destacando sua adequação para análises com dados multimodais. A integração de informações provenientes de diferentes fontes (como histórico médico e fatores comportamentais) demonstrou ser abordagem robusta para entender os determinantes da gravidade da depressão.	O estudo comprovou que modelos de aprendizado de máquina, especialmente o Random Forest, podem transformar a gestão da depressão, ao oferecer diagnósticos mais precisos e intervenções personalizadas. A integração desses modelos em ambientes clínicos pode aprimorar a identificação precoce de casos graves, promover estratégias baseadas em dados e melhorar o suporte a pacientes, contribuindo significativamente para o avanço na abordagem de condições de saúde mental.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
19	Chang <i>et al.</i> , (2024)	Das 500 licenças adquiridas para o aplicativo Wysa, 527 usuários foram registrados, com 495 completando pelo menos uma sessão e 422 completando duas ou mais. Cada sessão foi definida como uma interação completa com o chatbot ou uma ferramenta de intervenção. O engajamento foi alto, com 93,9% dos usuários utilizando o aplicativo pelo menos uma vez e 80,1% retornando para múltiplas interações. Em média, os usuários completaram 10,9 sessões ao longo de 3,8 semanas, com 40,5% interagindo consecutivamente por pelo menos três semanas. Durante um “desafio de gratidão” de três dias, o engajamento aumentou em 71%, indicando que iniciativas desse tipo podem estimular maior uso. Os usuários forneceram <i>feedback</i> em 20% das sessões, com média de satisfação de 4,07 (em uma escala de 1 a 5) e 93,2% das avaliações sendo positivas. Além disso, 158 usuários responderam aos questionários GAD-7 e PHQ-2, dos quais 46,2% relataram sintomas de ansiedade e 15,2% apresentaram sintomas de depressão. Intervenções relacionadas ao sono e à ansiedade foram as mais utilizadas, destacando-se meditação do sono (84 usuários, 564 sessões) e visualização guiada (172 usuários, 502 sessões).	O estudo demonstra que a utilização de plataformas digitais, como a Wysa, para intervenções em saúde mental apresenta resultados promissores. A alta taxa de uso repetido e o <i>feedback</i> positivo dos usuários indicam que essas ferramentas podem ser eficazes no tratamento de condições, como ansiedade e problemas de sono. A facilidade de acesso e a variedade de intervenções disponíveis tornam essas plataformas atrativas tanto para pacientes quanto para profissionais de saúde. Os autores sugerem que a implementação de intervenções digitais semelhantes pode ser estratégia eficaz para ampliar o acesso a cuidados em saúde mental. Ao integrar essas ferramentas aos serviços de saúde tradicionais, é possível oferecer suporte mais abrangente e personalizado aos pacientes.
20	Yoo <i>et al.</i> , (2024)	Pesquisas clínicas frequentemente definem recaídas na esquizofrenia, com base em marcadores operacionais, como hospitalizações, registros médicos e mudanças em escalas médicas. Contudo, essas definições incorporadas em modelos de IA podem não refletir as percepções dos pacientes ou como eles detectam as recaídas. A detecção de recaídas é também um processo social, pois pacientes que recebem alertas de IA, geralmente, verificam essas informações com os sistemas de suporte, como familiares ou profissionais de saúde. Os participantes do estudo destacaram que, embora os modelos de IA sejam úteis na prevenção de recaídas, eles devem ser integrados a redes de apoio humano e não funcionar de forma isolada. Além disso, levantaram preocupações éticas sobre o uso dessas tecnologias, especialmente em relação ao risco de vigilância e à criação de perfis, enfatizando a necessidade de abordar essas questões no desenvolvimento de ferramentas baseadas em IA para saúde mental.	Os modelos atuais de IA para prever recaídas na esquizofrenia, frequentemente, desconsideram as importantes dicas sociais utilizadas por pacientes nas redes de apoio, como família, amigos e cuidadores. Essa lacuna destaca a necessidade de refinar os modelos de IA, para que funcionem como ferramentas colaborativas, promovendo cuidado mais integrado e holístico. Além disso, preocupações dos pacientes sobre a precisão, relevância e implicações éticas da IA, enfatizando a importância de pesquisas futuras centradas no paciente para desenvolver modelos mais adaptados às necessidades e preocupações.
21	Palacios-Ariza <i>et al.</i> , (2023)	O modelo de melhor desempenho para prever admissão foi o Random Forest, com pontuação de precisão de 0,951 e AUC de 0,98. As variáveis com maior poder preditivo na análise de importância da <i>Recursive Feature Elimination</i> (RFE) foram o número de visitas de emergência psiquiátrica, o número de consultas de acompanhamento ambulatorial e a idade. Os modelos de sobrevivência mostraram resultados semelhantes, com o Random Survival Forest apresentando melhor desempenho, atingindo AUC de 0,95. No entanto, os modelos de previsão para readmissão de pacientes tiveram desempenho inferior, com o modelo Random Forest sendo novamente o melhor desempenho, mas com AUC abaixo de 0,70.	Os modelos de ML, particularmente o modelo Random Forest, superaram as técnicas estatísticas tradicionais para predição de admissão. No entanto, os modelos de predição de readmissão tiveram desempenho mais baixo. Este estudo demonstra o potencial das técnicas de ML em melhorar a precisão da predição para admissões de pacientes com transtorno bipolar.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
22	De Lacy <i>et al.</i> , (2023).	O aprendizado profundo mostrou o melhor desempenho para ansiedade e déficit de atenção, enquanto o aprendizado baseado em árvores foi superior para depressão, comportamentos disruptivos e transtorno de estresse pós-traumático (PTS). A regressão logística teve desempenho consistentemente inferior, com AUC de 0,5 para todas as condições. Os modelos otimizados demonstraram parcimônia, exigindo, no máximo, seis preditores finais para previsões de alta qualidade, selecionados a partir de 160 preditores iniciais. Para ansiedade, o aprendizado profundo destacou eventos adversos, traços internalizantes e externalizantes, e níveis de estresse parental. No déficit de atenção, hiperatividade e sentimentos dos pais foram os principais preditores. Modelos para depressão e comportamentos disruptivos ponderaram traços de humor, hiperatividade e responsividade social como fatores importantes. Já os modelos para PTS exploratórios foram limitados, exceto pelo desempenho moderado do modelo de árvore de decisão. A abordagem IEL explorou, aproximadamente, 40.000 ajustes de modelo para cada caso, garantindo predições robustas, com generalização para dados não vistos.	A aplicação de aprendizado de máquina (ML), otimizado em conjunto de dados multidomínio, permitiu identificar preditores específicos para cinco condições mentais comuns em jovens, alcançando alta generalização ($AUC \geq 0,94$), em dados de teste. Os resultados confirmaram a natureza multifatorial e não linear das condições psiquiátricas em adolescentes, favorecendo algoritmos como redes neurais artificiais (ANN) e XGBoost (XGB). Além disso, preditores psicossociais e psicométricos mostraram maior relevância em comparação com métricas de função neural.
23	Sadeh-Sharvit <i>et al.</i> , (2023)	Os escores iniciais de depressão (PHQ-9) variaram entre 3 e 16, enquanto os de ansiedade (GAD-7) variaram entre 3 e 14, sem diferenças significativas entre os grupos na linha de base. Os pacientes em ambos os grupos relataram reduções nos sintomas, mas os resultados foram mais expressivos no grupo IA. A depressão foi reduzida em 34% com Eleos, contra 20% no TAU, com grande tamanho de efeito para Eleos ($d = 0,82$), em comparação com TAU ($d = 0,34$). Para ansiedade, Eleos reduziu os sintomas em 29%, comparado a 8% no TAU, com tamanhos de efeito de $d = 0,78$ e $d = 0,14$, respectivamente. Os pacientes de ambos os grupos relataram alta satisfação com a terapia, com pontuações médias de 4,50 (DP 0,50) para o grupo IA e 4,43 (DP 0,73) para o TAU. Os terapeutas que usaram Eleos destacaram benefícios qualitativos, como maior conscientização sobre o uso de técnicas de TCC, eficiência na documentação e mais tempo para se dedicar ao cliente. Em relação à qualidade das notas de progresso, os terapeutas no grupo IA enviaram as notas, em média, após 14 horas (DP 38), enquanto, no TAU, o tempo médio foi de 69 horas (DP 73). As notas no grupo IA eram mais concisas, com 263 palavras (DP 83) em média, em comparação com 318 palavras (DP 159), no grupo TAU. Ambas as notas incluíram os elementos necessários, como planos de tratamento, técnicas usadas, resposta do cliente e progressos, além de apresentarem menos de dois erros gramaticais, em média. A análise mostrou que Eleos facilitou processo mais ágil e eficiente para os terapeutas.	O uso de uma plataforma de IA para apoiar a terapia em contextos de saúde comportamental foi mais eficaz do que o Tratamento Usual (TAU). A implementação da plataforma de IA resultou em maior frequência às sessões e em melhorias mais significativas nos sintomas de depressão e ansiedade. Esses achados sugerem que uma plataforma de IA projetada para potencializar práticas baseadas em evidências (EBP) pode aprimorar a retenção de clientes e os resultados terapêuticos em cenários práticos do mundo real.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
24	Chen <i>et al.</i> , (2023)	<p>O aprendizado de árvore de decisão (CART) foi aplicado para diagnosticar TDAH, com base em novos dados de pacientes. Este método seleciona atributos informativos para formar conjuntos homogêneos, maximizando a precisão preditiva. A busca por hiperparâmetros, usando técnicas como validação cruzada k-fold (k=10), garantiu modelos robustos. Métricas como precisão, recall e AUC foram usadas para avaliar o desempenho. Entre os modelos avaliados (como Regressão Logística, Random Forest e XGBoost), o CART se mostrou mais confiável, alcançando precisão de 75,04% no teste e mantendo bom equilíbrio entre sensibilidade e especificidade. Apesar de não ser o mais preciso em todos os critérios, o CART se destacou pela robustez e confiabilidade no diagnóstico de TDAH, superando outras abordagens em estabilidade e aplicabilidade prática. A análise destacou a importância dos atributos DIVA para modelos preditivos de TDAH, com ausência reduzindo a precisão média de 66,48% para 58,08% e a AUC de 0,72 para 0,63. Mesmo métodos avançados, como Random Forest e Extreme Gradient Boosting, apresentaram limitações na previsão de novos casos sem esses atributos. A árvore de decisão CART manteve desempenho robusto, atingindo 65,27% de precisão no modelo final, com "IOWA_Score," "Age" e "CAARS_OS_Inattention_Memory_TT1Score" identificados como preditores relevantes. Nos testes com 501 pacientes, o modelo de aprendizado de máquina (ML) classificou todos os casos como TDAH ou não, enquanto o modelo baseado em conhecimento (KR) encaminhou 59,3% para especialistas e classificou 40,7% como Sim/Não. O modelo híbrido combinou ambos, encaminhando 61,5% dos casos para especialistas, demonstrando eficácia em casos complexos e reforçando o potencial para diagnósticos mais abrangentes.</p>	<p>O uso de Inteligência Artificial (IA) em saúde apresenta grande potencial, mas exige atenção às questões éticas, como proteção de dados, justiça algorítmica e responsabilização. Dados anonimizados e conhecimento especializado garantem privacidade e segurança, enquanto técnicas como validação cruzada e ajuste de hiperparâmetros minimizam vieses e garantem justiça algorítmica. A ferramenta funciona como suporte à decisão clínica, promovendo transparência com modelos explicáveis.</p> <p>Apesar das medidas tomadas, desafios como vieses em dados clínicos e conhecimento incompleto permanecem. Estudos futuros visam eliminar esses problemas, ampliando a aplicação da solução em contextos clínicos reais e assegurando alta qualidade e confiabilidade.</p>
25	Sofia <i>et al.</i> , (2023)	<p>Os modelos foram comparados em termos de acurácia e latência. O KNN mostrou o melhor desempenho em precisão, atingindo 92,32% de acurácia, seguido pelo modelo de Árvores de Decisão, com 89,64%. Apesar de menos preciso, o modelo de Árvores de Decisão apresentou menor latência, sendo ideal para aplicações que exigem respostas rápidas. O Naive Bayes obteve 88,21% de acurácia, ficando em terceiro lugar.</p>	<p>Concluiu-se que o aprendizado de máquina é uma abordagem promissora para detecção de depressão, com vantagens em precisão e eficiência. O modelo KNN foi o mais eficaz para diagnósticos precisos, enquanto as Árvores de Decisão se destacaram em cenários que exigem menor tempo de resposta. A inclusão de perguntas positivas e o monitoramento semanal enriqueceram a qualidade das análises. Os autores enfatizam que, apesar dos resultados promissores, mais estudos são necessários para validar a aplicabilidade prática dos modelos em diferentes contextos e garantir a generalização dos achados.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
26	Caulley <i>et al.</i> , (2023)	<p>O estudo apresentou resultados promissores no uso de inteligência artificial para detecção automática de emoções em crianças e adolescentes com sintomas psiquiátricos graves. Modelos baseados em transformers, como o Wav2Vec 2.0, demonstraram alta eficácia na classificação de emoções específicas, alcançando precisão de 86% e recall de 79% na identificação da intensidade emocional (alta ou baixa). Redes neurais convolucionais (CNNs), como AlexNet, também foram eficazes, atingindo 83% de precisão e recall em análises generalizadas de quatro emoções (raiva, medo, tristeza e felicidade). Métodos de pré-processamento, como redução de ruído (denoising), detecção de atividade de voz (VAD) e diarização, impactaram o desempenho dos modelos de forma variada, com melhorias pontuais em cenários específicos, embora em alguns casos tenham causado declínios, devido ao excesso de compensação ou à presença de ruídos excessivos. O Wav2Vec 2.0 destacou-se em relação às CNNs na análise de áudios longos, devido à capacidade de capturar dependências temporais e emocionais.</p>	<p>As principais conclusões destacaram a viabilidade do uso de IA como ferramenta complementar no cuidado à saúde mental infantil, permitindo avaliações mais objetivas e triagem de crianças em situações de maior risco. O estudo ressalta a importância dessa tecnologia para populações vulneráveis, especialmente em comunidades de baixa renda, contribuindo para reduzir desigualdades no acesso a tratamentos. Contudo, limitações como a qualidade dos dados, ruídos nas gravações e a insuficiência de amostras para algumas emoções, como felicidade, apontam a necessidade de avanços futuros. Além disso, questões éticas, como privacidade e segurança dos dados, devem ser priorizadas, e a IA deve ser utilizada como suporte à tomada de decisões clínicas, preservando a conexão humana essencial no processo terapêutico. Por fim, o estudo sugere que rotulações mais detalhadas dos áudios e melhorias na interpretabilidade dos modelos poderiam ampliar a aplicabilidade e eficácia das soluções propostas, contribuindo para um futuro mais inclusivo e eficiente na saúde mental.</p>
27	Heinz <i>et al.</i> , (2023)	<p>O desempenho do modelo para diagnósticos psiquiátricos foi avaliado por meio da precisão balanceada (BAC), que variou de 0,50 a 0,82. Diagnósticos como TDAH (0,82) e TEPT (0,81) apresentaram BAC excelente, enquanto transtornos como transtorno bipolar (0,58) e bulimia nervosa (0,57) tiveram desempenho ruim. Outras métricas, como sensibilidade, especificidade, Valor Preditivo Positivo (VPP) e Valor Preditivo Negativo (VPN), foram usadas para complementar a análise. Por exemplo, o TDAH obteve alta especificidade (0,99) e VPN (0,98), indicando boa precisão na exclusão de falsos diagnósticos. Análises demográficas revelaram diferenças significativas: pessoas latinas tiveram maior probabilidade de diagnóstico de transtornos de humor (OR = 0,64), enquanto nativos americanos foram mais frequentemente diagnosticados com transtornos por uso de substâncias (OR = 1,94) e transtorno de uso de álcool (TUA) (OR = 2,79), ambos com $p < 0,05$. Homens apresentaram menor probabilidade de diagnóstico de transtorno de personalidade limítrofe (TPB), em comparação com mulheres (OR = 0,43, $p < 0,05$).</p>	<p>Os sistemas de IA oferecem solução promissora para reduzir a lacuna entre demanda e oferta em saúde mental, mas novidade e complexidade geram preocupações, especialmente em áreas de alto risco. Este estudo foi pioneiro em avaliar sistematicamente a base de conhecimento psicológico e explorar vieses em modelos amplos de IA. Apesar da variabilidade no desempenho entre diagnósticos, os resultados indicaram potencial promissor e viés demográfico leve, destacando a necessidade de estudos futuros para validar a eficácia em contextos reais.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
29	Nash; Nair; Naqvi, (2023)	Modelos de ML mostraram alta precisão na detecção de TDAH e depressão, com taxas de acerto acima de 90% em vários estudos. Sinais de EEG e imagens de fMRI destacaram-se como as fontes mais eficazes para análise de TDAH e depressão. Métodos vestíveis proporcionaram diagnósticos não invasivos e economicamente viáveis. Desafios identificados: tamanho reduzido dos conjuntos de dados, privacidade dos participantes e dificuldade na generalização dos modelos.	O aprendizado de máquina demonstrou ser ferramenta promissora na detecção e no diagnóstico de TDAH e depressão, especialmente devido à capacidade de analisar grandes volumes de dados complexos. Contudo, a criação de bancos de dados maiores, a proteção de informações sensíveis e a colaboração entre áreas médicas e tecnológicas são essenciais para superar os desafios atuais e ampliar as aplicações clínicas.
30	Lee <i>et al.</i> , (2023)	O estudo comparou o GPT-4 e clínicos na previsão de ideação suicida (IS) com plano. O GPT-4 apresentou desempenho semelhante aos clínicos em precisão na admissão (0,67 vs. 0,7) e maior sensibilidade (0,62 vs. 0,53), mas menor especificidade (0,71 vs. 0,82). A adição de dados sobre tentativas anteriores aumentou a sensibilidade do GPT-4 (0,84), mas reduziu a precisão (0,64). Pós-admissão, o GPT-4 teve sensibilidade levemente maior (0,46 vs. 0,4) e precisão menor (0,48 vs. 0,59). O consenso clínico foi mais alto em amostras sem IS (52%) e menor pós-admissão (40%). O GPT-4 identificou indicadores como “desesperança” em 70% das amostras de IS na admissão, mas teve dificuldade em prever corretamente, quando não identificou riscos explícitos. O modelo mostrou potencial como suporte clínico, mas com limitações na especificidade.	O GPT-4, com design de prompt simples, produziu resultados em algumas métricas que se aproximaram das de um clínico treinado. Trabalho adicional deve ser feito antes que esse modelo possa ser pilotado em ambiente clínico. O modelo deve passar por verificações de segurança para viés, em razão da evidência de que os LLMs podem perpetuar os vieses dos dados subjacentes nos quais são treinados. Os LLMs prometem aumentar a identificação de pacientes de alto risco na admissão e, potencialmente, fornecer cuidados mais oportunos aos pacientes.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
31	Abdullah; Negied, (2024)	<p>O estudo mostrou que, entre os métodos testados, os grandes modelos de linguagem (BERT, RoBERTa e OpenAI GPT) tiveram o melhor desempenho geral, com pontuações F1 médias de 0,80, superando os modelos clássicos de aprendizado de máquina e os de conjunto. Entre os métodos clássicos, a regressão logística, SVM e SGD foram os mais eficazes (F1 média de 0,76), enquanto KNN teve o pior desempenho (F1 média de 0,17). Nos modelos de conjunto, LightGBM, Bagging Meta Estimator e VC2 apresentaram os melhores resultados (F1 média de 0,76), enquanto o Gradient Boosting foi o menos eficaz (F1 média de 0,54). Os LLMs destacaram-se por precisão, na detecção de transtornos mentais, com o BERT sendo o melhor para ansiedade e bipolaridade, RoBERTa para TDAH e GPT para depressão.</p> <p>No segundo estudo, que analisou dados de mídias sociais, os classificadores tradicionais de ML e os modelos de conjunto superaram os LLMs na detecção de transtornos mentais. A regressão logística e os modelos Bagging, XGBoost e LightGBM apresentaram as melhores pontuações F1 médias (0,52). O OpenAI GPT foi o LLM mais eficaz, com pontuação F1 média de 0,45. Por transtorno, o Bagging e a LR foram melhores para depressão, XGBoost para ansiedade e bipolaridade, e LightGBM para TDAH. Os resultados destacaram a eficácia dos métodos tradicionais em dados não clínicos.</p> <p>No terceiro estudo, os modelos de aprendizado de máquina e de conjunto superaram os LLMs na previsão de transtornos mentais futuros em redes sociais. A regressão logística e o estimador Bagging foram os melhores, ambos com F1 média de 0,43. O RoBERTa foi o LLM mais eficaz (F1 média de 0,42), mas ficou atrás dos métodos tradicionais. A regressão logística se destacou na previsão de depressão, o Bagging no TDAH, e ambos tiveram bom desempenho em ansiedade e bipolaridade.</p>	<p>Os resultados mostraram que grandes modelos de linguagem (LLMs) superaram métodos tradicionais em dados clínicos, com destaque para BERT, RoBERTa e OpenAI GPT. Em dados não clínicos, os classificadores clássicos, como a regressão logística e modelos de conjunto, como Bagging, XGBoost e LightGBM, apresentaram melhor desempenho. Bagging foi o melhor na previsão de transtornos futuros, enquanto a regressão logística se destacou na detecção de depressão, XGBoost em ansiedade e bipolaridade, e LightGBM em TDAH.</p> <p>Como próximos passos, o estudo sugere ajustes em hiperparâmetros, análise de erros, validação cruzada e desenvolvimento de ferramenta de software para auxiliar usuários com transtornos mentais.</p>
32	Sinha; Meheli; Kadaba, (2023)	<p>Engajamento: durante a pandemia, o engajamento com o aplicativo foi significativamente maior do que em períodos pré-pandêmicos. As ferramentas mais usadas incluíram intervenções para ansiedade, atenção plena e sono. Correlação com a Covid-19: observou-se aumento nas instalações do aplicativo, durante os picos de casos da Covid-19, especialmente no Reino Unido e na Índia. Eficácia: houve redução significativa nos sintomas de depressão e ansiedade, conforme medido pelo PHQ-9 e GAD-7. O efeito foi estatisticamente significativo, com tamanhos médios a grandes.</p>	<p>O estudo demonstrou que o uso de intervenções digitais como o Wysa é eficaz na redução de sintomas de depressão e ansiedade, especialmente, quando contextualizado para necessidades específicas, como a pandemia. Além disso, destacou a importância dos aplicativos de saúde mental para atender à demanda crescente por suporte em saúde mental, em cenários de crise global. No entanto, limitações incluem a ausência de um grupo de controle e a não consideração de fatores sociais ou políticos adicionais.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
33	Arif <i>et al.</i> , (2024)	O modelo Transformer proposto, com fusão tardia por concatenação, obteve o melhor desempenho geral (F1 = 89,65%), superando outros métodos. Entre os modelos de aprendizado por transferência, o RoBERTa apresentou o melhor resultado (F1 = 84,41%). Já entre os métodos tradicionais, a regressão logística alcançou a maior pontuação (F1 = 77,87%). Os resultados mostraram que posts completos forneceram mais informações úteis para detecção do que títulos.	O estudo demonstrou que modelos baseados em Transformadores são promissores para detectar transtornos mentais, a partir de textos de mídias sociais, com potencial de superar abordagens tradicionais e de aprendizado profundo. No entanto, há espaço para melhorias com dados mais robustos, técnicas de aumento de dados e modelos adicionais. Os autores também sugerem explorar detecção multi-rótulo, considerando que um usuário pode apresentar múltiplos transtornos simultaneamente. Futura aplicação prática pode ser o desenvolvimento de ferramentas automatizadas para ajudar na triagem e no diagnóstico preliminar em saúde mental.
34	Oh <i>et al.</i> , (2020)	Os modelos LB e ANN apresentaram o melhor desempenho na predição de ideação suicida (SI), com AUC de 0,877, sensibilidade de 81,0% e especificidade de 78,7%. A regressão logística convencional e o modelo BN obtiveram AUC de 0,867, com sensibilidade de 79,0% e especificidade de 78,5%. A análise de árvore de decisão destacou o humor depressivo contínuo por ≥ 2 semanas como o principal determinante, seguido por pontuação EQ-5D, consciência do estresse e presença de transtorno depressivo.	O estudo demonstrou que modelos de aprendizado de máquina têm desempenho comparável à regressão logística na predição de ideação suicida (SI). Esses modelos podem auxiliar médicos na identificação precoce de pacientes em risco, promovendo intervenções preventivas, como consultas psiquiátricas e gestão de condições associadas. Os resultados são valiosos para o desenvolvimento de programas eficazes de prevenção ao suicídio.
35	Nowakowska <i>et al.</i> , (2023)	O classificador de floresta aleatória (RF) teve o melhor desempenho no diagnóstico de depressão, enquanto a árvore de gradiente impulsionada (GBT) se destacou na predição de delírio pós-operatório. A análise da curva ROC mostrou consistência nas execuções do RF. Os fatores mais significativos foram o sRAGE pré-operatório para depressão, seguido por estado cognitivo (CDT) e diabetes. Para delírio, idade avançada e níveis elevados de proteína quimiotática de monócitos-1 pré-operatórios foram os principais determinantes.	O potencial do sRAGE como biomarcador para depressão neste grupo de pacientes, com o classificador de floresta aleatória alcançando taxa de precisão de 62% (AUC = 0,67), na previsão de depressão, com base nos níveis pré-operatórios de sRAGE. Ao mesmo tempo, o modelo de árvore de gradiente impulsionado (GBT) previu efetivamente o delírio com 72% de precisão. O uso de IA para diagnosticar e monitorar pacientes pode melhorar e facilitar significativamente o atendimento médico, reduzindo o número de erros médicos.
36	Kerz <i>et al.</i> , (2023)	Os modelos baseados em BiLSTM apresentaram desempenho competitivo, identificando padrões linguísticos importantes, como coesão textual e complexidade lexical. O MentalRoBERTa foi o modelo mais eficaz, alcançando pontuações F1 destacadas na detecção de estresse (81,62%), ansiedade (70,50%) e bipolaridade (71,83%). Os modelos multitarefa, ao integrar dados emocionais e de traços de personalidade, melhoraram a precisão em até 3,74%, com destaque para detecção de TDAH. A análise de explicabilidade revelou características linguísticas, como coesão e uso de pronomes pessoais, como preditores-chave, tornando os modelos mais interpretáveis e úteis para aplicações clínicas.	O estudo evidenciou o potencial de modelos avançados de IA, como MentalRoBERTa e abordagens multi-tarefa, para detectar transtornos mentais com alta precisão. Ao combinar interpretabilidade e desempenho preditivo, esses modelos oferecem ferramentas promissoras para triagem e intervenção precoce em saúde mental, destacando a importância de dados linguísticos na compreensão e gestão de transtornos psicológicos.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
37	Siddiqua <i>et al.</i> , (2023)	Os resultados mostraram que o modelo Random Forest apresentou a maior precisão (98,08%) e o menor número de falsos negativos, sendo o mais eficaz para detectar níveis de depressão. A CNN também demonstrou desempenho elevado (92,31%), destacando-se na identificação de casos graves. Outros modelos, como Gradient Boosting e LightGBM, também apresentaram boa precisão e se destacaram pela capacidade de lidar com dados complexos. Entre os fatores identificados como mais correlacionados com níveis elevados de depressão, destacaram-se violência emocional ou sexual, dificuldades financeiras, tabagismo e falta de atividade física. Foi observado que mulheres apresentaram maior vulnerabilidade à depressão e a pensamentos suicidas, em comparação aos homens. O uso do LIME revelou que fatores como histórico de violência, hábitos de saúde e estresse acadêmico foram os mais influentes nas previsões dos modelos, fornecendo interpretação clara e compreensível dos resultados.	Os que modelos avançados de IA, como Random Forest e CNN, são eficazes na predição de depressão em estudantes universitários, possibilitando intervenções precoces. A integração de explicabilidade por IA (LIME) reforça a aplicabilidade prática, permitindo que os resultados sejam compreendidos por profissionais da área. Além disso, o estudo destaca a importância de fatores contextuais, como hábitos de vida e experiências adversas, no manejo de transtornos mentais.
38	Na <i>et al.</i> , (2021)	Os hiperparâmetros do LR regularizado foram definidos como penalidade = 'l1', solucionador = 'liblinear', tolerância = 0,0001, C = 0,3 e máximo de 100 iterações. Para o SVM, os hiperparâmetros incluíram C = 0,21, gama = 0,0645, kernel = "poli" e grau = 2. Esses dois modelos, LR e SVM regularizados, apresentaram os melhores desempenhos, com precisão geral de 78,4% e boas pontuações de MCC (0,572 e 0,596, respectivamente) e F1 (0,790 e 0,733, respectivamente). Entre os outros algoritmos avaliados, o <i>Gradient Boosting Machine</i> (GBM) e a Rede Neural Artificial (ANN) também mostraram desempenho competitivo, enquanto o Random Forest obteve a menor precisão (0,649). O SVM se destacou com a maior especificidade (0,947) e menor taxa de falsos positivos (0,053), enquanto o LR teve a maior sensibilidade (0,833), igualada apenas pela ANN. Esses resultados indicaram que o LR e o SVM regularizados foram os modelos mais eficazes para classificação de transtorno de pânico e outros transtornos de ansiedade.	Espera-se que algoritmos de classificação para transtorno de pânico e outros transtornos de ansiedade sejam úteis para profissionais de saúde em várias instituições. Em termos de avaliação e intervenção personalizadas, os resultados têm pontos fortes no campo da psiquiatria clínica e sistemas públicos de saúde mental. Estudos futuros para validar a precisão da classificação deste modelo com design longitudinal e com base em mais participantes são necessários.
39	Schillings <i>et al.</i> , (2024)	Não houve mudanças significativas no estresse percebido (β 03 = -.018, SE=.329; P=.96) e no estresse momentâneo. A atenção plena e a subfaceta reavaliação aumentaram significativamente no grupo de intervenção ao longo do tempo, enquanto não houve mudança na supressão da subfaceta. O bem-estar e a sensibilidade interoceptiva momentânea aumentaram em ambos os grupos, ao longo do tempo.	Os resultados sugerem que intervenções baseadas em chatbot podem ser ferramenta eficaz para o manejo do estresse. No entanto, futuras pesquisas devem explorar a personalização da intervenção para diferentes subgrupos populacionais e avaliar a necessidade de programas com maior duração. Além disso, a rápida evolução da tecnologia de chatbots exige que novas intervenções sejam constantemente atualizadas, com base nas mais recentes descobertas científicas.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
40	Popescu <i>et al.</i> , (2021)	<p>Dos sete médicos participantes, 57% (4) avaliaram que o uso do CDSS tomou quase o mesmo tempo que a prática habitual. Entre 13 pacientes, 62% (8) sentiram que a duração da consulta permaneceu inalterada, enquanto 8% (1) acreditaram que foi reduzida. Em relação à confiança no CDSS, 62% (8/13) dos pacientes e 71% (5/7) dos médicos atribuíram notas altas (4 ou 5 em escala Likert de 5 pontos). As médias das pontuações do STAR-P (42,69; DP 5,57) e STAR-C (40,29; DP 5,65) indicaram que o CDSS não impactou negativamente o relacionamento clínico-paciente. Além disso, 46% (6/13) dos pacientes sentiram que o relacionamento com o médico melhorou, enquanto 54% (7/13) não notaram mudanças. A usabilidade do CDSS foi bem avaliada, com 92% (12/13) dos pacientes e 71% (5/7) dos médicos atribuindo notas altas. Todos os médicos (100%) acessaram a ferramenta nas consultas das visitas 1 e 2, e o componente de algoritmo clínico foi utilizado em 93% (13/14) dos atendimentos em ambas as visitas.</p>	<p>As descobertas confirmam que a integração da ferramenta não aumenta significativamente a duração da consulta e sugerem que o CDSS é fácil de usar e pode ter efeitos positivos no relacionamento médico-paciente para alguns pacientes. O CDSS é viável e está pronto para estudos de eficácia.</p>
41	Villa-Pérez <i>et al.</i> , (2023)	<p>Os melhores resultados foram obtidos com o uso de atributos lexicais, como n-grams e q-grams, combinados com os modelos XGBoost e CNN. Na classificação binária, os modelos alcançaram AUC de 0,835 no conjunto de dados em espanhol, utilizando n-grams de um a três palavras, e AUC de 0,846 no conjunto em inglês, utilizando q-grams de cinco caracteres. Na classificação multiclases, os resultados foram mais desafiadores, devido ao desequilíbrio entre as classes (número reduzido de usuários diagnosticados para alguns transtornos, como esquizofrenia). Apesar disso, os modelos atingiram AUC de 0,712 no conjunto em espanhol, com melhor desempenho ao utilizar n-grams de 1 a 3 palavras, e AUC de 0,697, no conjunto em inglês, com melhor desempenho utilizando unigramas. A análise revelou que transtornos como TDAH e depressão foram mais fáceis de classificar, enquanto esquizofrenia e transtorno de estresse pós-traumático (TEPT) tiveram menor desempenho, devido à baixa representatividade nos dados.</p>	<p>Os modelos baseados em aprendizado de máquina podem ser utilizados para detectar transtornos mentais, com base no histórico textual de usuários em redes sociais, especialmente quando há dados suficientes para treino. Os atributos lexicais, como n-grams, mostraram-se particularmente eficazes, oferecendo maior granularidade na análise de textos curtos, como tweets. Os resultados reforçam o potencial das redes sociais como fontes complementares para a identificação precoce de condições de saúde mental, embora desafios como o desequilíbrio de classes e a validação de diagnósticos autorrelatados precisem ser superados.</p>
42	Rezapour; Elmshaeuser, (2022)	<p>Os melhores desempenhos foram obtidos com o Random Forest, que alcançou precisão de até 96,77%, em tarefas de classificação binária. Os principais preditores de frustração emocional incluíram satisfação com aulas <i>on-line</i>, desempenho acadêmico, suporte financeiro e satisfação com políticas governamentais e institucionais relacionadas à pandemia. Foi identificado que insatisfações com a organização de aulas e suporte de mentores estão correlacionadas com maiores níveis de frustração.</p>	<p>Vários modelos estatísticos e de aprendizado de máquina para analisar esses dados. O mais preciso desses modelos é o modelo Random Forest com 9 árvores de profundidade 10 após a aplicação do SMOTE. Nossos outros modelos principais são o Random Forest com 38 árvores de profundidade 8, o Random Forest com 40 árvores de profundidade 20 e o XGBoost com 178 árvores de profundidade 8. Os resultados indicaram que os preditores de bem-estar emocional selecionados por esses modelos podem ser classificados em três categorias: desafios com a vida acadêmica, satisfação com organizações impactantes (universidades, governos etc.) e estressores financeiros.</p>

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
43	Danieli <i>et al.</i> , (2022)	Apesar da randomização, diferenças estatisticamente significativas foram observadas entre os grupos em T1. O grupo 4 apresentou níveis mais baixos de ansiedade e depressão em comparação com o grupo 1, e níveis mais baixos de estresse em relação ao grupo 2. Em T2 e T3, não foram detectadas diferenças significativas entre os grupos nos resultados. Análises dentro dos grupos revelaram melhorias significativas no grupo 2, especialmente nos níveis de estresse e bem-estar geral. No entanto, todos os grupos mostraram tendência geral de piora entre T2 e T3, com aumento significativo no estresse no grupo 2. Esse grupo também relatou maior percepção de utilidade e satisfação.	Não foi possível observar diferenças estatisticamente significativas entre os participantes que usaram o aplicativo mHealth sozinho e aqueles que o usaram dentro do ambiente tradicional de tratamento psicológico. Pelo contrário, observou-se diferenças significativas dentro do grupo, com melhorias em indivíduos que receberam tratamento. Além disso, notaram-se maiores níveis de satisfação e percepção subjetiva de utilidade em participantes que foram apoiados por um terapeuta humano, bem como pelo agente de conversação mHealth.
44	Wang <i>et al.</i> , (2021)	O modelo IGCBA-BPNN apresentou a maior precisão preditiva, com 92,55%, superando outros algoritmos comparados. O modelo eliminou variáveis redundantes e irrelevantes, reduzindo a complexidade do modelo sem comprometer a eficácia. Os principais fatores que influenciam a saúde mental dos trabalhadores médicos incluem a presença de pacientes com Covid-19 no ambiente de trabalho ou residência, idade, tipo de emprego, alterações na intensidade do trabalho e no tempo de sono habitual.	O estudo concluiu que o modelo IGCBA-BPNN é eficaz para prever a saúde mental de trabalhadores médicos e pode ser utilizado para orientar intervenções psicológicas e a alocação de recursos de saúde pública. O método também se mostrou mais eficiente que outros algoritmos, devido à capacidade de lidar com relações não-lineares e reduzir redundâncias nos dados. Como próxima etapa, sugere-se aprimorar a estrutura da rede neural para aumentar ainda mais a precisão preditiva.
45	Mehta <i>et al.</i> , (2021)	Os resultados mostraram uma alta aceitação dos usuários, com uma média de 4,36 estrelas em uma escala de 5. Cerca de 42,66% dos usuários continuaram a utilizar o aplicativo após 4 semanas. Os sintomas de ansiedade e depressão apresentaram reduções significativas nas primeiras 2 semanas (ansiedade: $d=0,57$; depressão: $d=0,46$), com a manutenção dos ganhos para ansiedade até a quarta semana. No entanto, houve leve aumento nos sintomas de depressão entre as semanas 2 e 4. Além disso, maior sucesso na regulação emocional dentro das sessões foi associado a reduções mais significativas nos sintomas.	O estudo demonstrou a eficácia do Youper como intervenção acessível e de baixo custo para ansiedade e depressão. A abordagem automatizada baseada em IA se mostrou promissora na redução de sintomas, especialmente, ao promover habilidades de regulação emocional. Embora os resultados sejam encorajadores, os autores destacaram a necessidade de estudos controlados randomizados futuros para validar os achados e explorar melhorias adicionais no engajamento e impacto clínico.
46	Nemesure <i>et al.</i> , (2021)	O desempenho preditivo do modelo apresentou AUC de 0,73 para TAG, com sensibilidade de 66% e especificidade de 70%, e AUC de 0,67 para TDM, com sensibilidade de 55% e especificidade de 70%. Para o TDM, os principais preditores identificados foram a satisfação com as condições de vida, o uso de seguro público de saúde, a pressão arterial diastólica alta, morar na casa dos pais e dificuldade de memorização. No caso do TAG, os preditores mais relevantes incluíram estar com a vacinação em dia, uso de maconha, hipertensão ou pré-hipertensão, exames médicos de controle e o uso de outras drogas recreativas. O modelo também destacou interações complexas entre os preditores, como o impacto mais significativo do uso de maconha no TAG em indivíduos com sobrepeso.	O estudo demonstrou que variáveis biomédicas e demográficas podem prever TDM e TAG com eficácia moderada, mesmo sem dados psiquiátricos explícitos. Os resultados reforçaram o potencial do aprendizado de máquina na triagem precoce de transtornos mentais, embora seja necessária validação em amostras maiores e mais diversas.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
47	Yang <i>et al.</i> , (2021)	Reconhecimento: todos os assistentes apresentaram alta precisão no reconhecimento das perguntas (79%-100%). Respostas Verbais: a frequência de respostas variou de 36% (Siri) a 79% (Alexa). Adequação Clínica: apenas 14%-29% das respostas foram consideradas clinicamente apropriadas, destacando lacuna significativa na utilidade desses assistentes para suporte médico confiável. Desempenho Geral: nenhum assistente superou consistentemente os outros em todas as métricas.	Assistentes virtuais reconheceram bem perguntas sobre saúde mental, mas frequentemente falharam em fornecer respostas clinicamente apropriadas. Apesar disso, eles representam oportunidade promissora para apoiar mães com DPP ao melhorar a triagem inicial e oferecer informações confiáveis. O estudo sugere que colaborações entre empresas de tecnologia e organizações de saúde são essenciais para melhorar o conteúdo e a funcionalidade dessas ferramentas, tornando-as mais úteis como recursos digitais de saúde mental.
48	Doki <i>et al.</i> , (2021)	Precisão da IA: sofrimento psicológico moderado: 65,2%. Sofrimento psicológico grave: 89,9%. Comparação com Psiquiatras: a IA demonstrou desempenho semelhante aos psiquiatras para sofrimento moderado e superou-os para sofrimento grave. Especificidade: alta especificidade (96,2% para sofrimento grave), mas baixa sensibilidade (17,5%). A análise de variância (ANOVA) confirmou que a IA foi significativamente mais precisa do que os psiquiatras na detecção de sofrimento grave ($p = 0,001$).	A IA apresentou alto potencial como ferramenta de triagem para sofrimento psicológico grave, especialmente, devido à especificidade. No entanto, melhorias são necessárias em termos de sensibilidade para ampliar a aplicabilidade prática. Este modelo de IA pode ser útil como suporte aos clínicos, especialmente em contextos ocupacionais, ao identificar trabalhadores em risco. O estudo sugere que, no futuro, a integração com dispositivos inteligentes e dados de séries temporais pode melhorar a eficácia do modelo. As limitações incluem a dificuldade de generalizar os resultados para outras populações e a falta de explicabilidade da IA.
49	Baek; Chung, (2020)	O modelo DNN contextual apresentou alta precisão, em comparação com métodos tradicionais. A combinação de informações contextuais com redes neurais permitiu previsão mais eficaz de risco de depressão. O modelo é escalável e pode ser adaptado para novos dados com baixa margem de erro (entre 0,001 e 0,02).	A abordagem context-DNN é eficiente para prever riscos de depressão, integrando dados contextuais à IA. O modelo demonstrou maior precisão e menor perda, comparado a redes neurais gerais. Resultados sugerem que a tecnologia pode ser utilizada como ferramenta preventiva na gestão de saúde mental, indicando estágios de risco e permitindo intervenções precoces.
50	Victor <i>et al.</i> , (2019)	O modelo apresentou alta precisão na identificação de depressão, superando abordagens convencionais. O uso de dados multimodais resultou em classificação mais robusta, com área sob a curva (AUC), indicando desempenho bem acima do acaso. A metodologia permitiu previsões contínuas e binárias, com taxas de erro significativamente reduzidas.	A integração de redes neurais multimodais profundas é uma abordagem eficaz e inovadora para detectar depressão. A ferramenta proposta pode ser usada como triagem confiável, em ambientes clínicos, reduzindo a necessidade de intervenção humana e aumentando a escalabilidade. Resultados sugerem que o método pode ser expandido para outras condições clínicas além da depressão.
51	Joerin; Rauws; Ackerman, (2019)	Redução de Sintomas: depressão e ansiedade diminuíram em 13% e 18%, respetivamente. Alto Engajamento: mais de 12.000 mensagens trocadas em 30 dias, com 88% das interações classificadas como úteis. Custo-efetividade: economia estimada de US\$ 585.000 para organização SE Health. Personalização e Expansão: suporte a mais de 20.000 adultos mais velhos nos EUA e no Canadá.	O chatbot Tess se mostrou solução viável e escalável para apoiar cuidadores e pacientes, oferecendo suporte emocional 24/7 a um custo acessível. A personalização dele demonstrou eficácia na redução de sintomas de saúde mental e melhoria da resiliência dos cuidadores. No entanto, são necessárias pesquisas contínuas para avaliar impactos de longo prazo e expandir a aplicação em diferentes contextos.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
52	Chadaga <i>et al.</i> , (2024)	Os resultados mostraram que os modelos AdaBoost e Logistic Regression foram os mais eficazes para diagnosticar Transtorno de Ansiedade Social (SAD), alcançando 88% de acurácia e AUC de 0,94. O modelo de ensemble Custom STACK também teve bom desempenho, com acurácia de 86%. Técnicas como SHAP, LIME, Eli5 e QLattice explicaram as predições, destacando atributos como a escala LSAS (Liebowitz Social Anxiety Scale), medo de falar em público (TKF) e medo de entrar em festas (CMT) como os mais relevantes. O uso combinado de aprendizado de máquina e Inteligência Artificial Explicável (XAI) garantiu alta precisão e transparência, demonstrando o potencial dessas ferramentas para aplicação clínica em ambientes como escolas e hospitais.	O estudo demonstrou que algoritmos de aprendizado de máquina, combinados com técnicas XAI, podem prever SAD com alta precisão e transparência, facilitando a aplicação em contextos clínicos, como escolas, hospitais e locais de trabalho. Apesar disso, o estudo reconhece limitações como o pequeno tamanho da amostra e a ausência de dados clínicos mais robustos, sugerindo que estudos futuros explorem técnicas de aprendizado profundo e modalidades adicionais, como exames de neuroimagem.
53	Qian <i>et al.</i> , (2019)	O método BoBW alcançou precisão média não ponderada (UAR) de 59,3%, superando abordagens convencionais baseadas em características manuais. O método demonstrou ser alternativa promissora para triagem de TDM, utilizando dispositivos vestíveis, oferecendo precisão competitiva sem a necessidade de conhecimento especializado.	A abordagem BoBW é eficaz para detectar padrões de TDM, com base em dados de SPA, contribuindo para triagens menos invasivas e economicamente viáveis. O uso de dispositivos vestíveis, combinado com aprendizagem de máquina, pode oferecer solução acessível para monitorar e diagnosticar saúde mental. Pesquisas futuras devem explorar combinações do BoBW com modelos de aprendizagem profunda para aumentar a precisão e a utilidade clínica do método.
54	Egan <i>et al.</i> , (2019)	O <i>Youth Advisory Group</i> forneceu <i>feedback</i> sobre o uso de IA e intervenção para perfeccionismo, sugerindo criar prompts claros, ajustar respostas e usar IA de forma prática e anônima. Eles valorizaram a acessibilidade e interatividade da IA, mas ressaltaram que ela deve complementar, e não substituir o suporte humano. O <i>feedback</i> sobre o livreto foi positivo, com sugestões para reduzir o conteúdo, reorganizar tópicos e incluir mais gráficos. Essas alterações foram incorporadas, resultando em intervenção mais acessível e eficaz.	Este estudo revelou que os jovens tinham visões positivas sobre intervenções guiadas por IA e eram usuários frequentes dessas tecnologias. Contudo, futuras pesquisas devem explorar uma gama mais ampla de percepções e preocupações dos jovens sobre IA. Além disso, é necessário realizar teste piloto da intervenção coprojetada IA-TCC-P para avaliar viabilidade e aceitação.
55	Fulmer <i>et al.</i> , (2018)	Houve redução significativa nos sintomas de ansiedade nos grupos que utilizaram o Tess por 2 e 4 semanas, com destaque para maior redução da depressão no grupo de duas semanas. Os participantes que usaram Tess relataram maior engajamento e satisfação em comparação com o grupo de controle. A inteligência artificial foi bem aceita, com 86% dos usuários indicando satisfação geral. Identificou-se aumento nos sintomas de ansiedade e depressão no grupo de controle que utilizou apenas o eBook informativo, sugerindo que o material não foi suficiente como intervenção.	Os resultados sugeriram que a IA psicológica integrativa pode ser ferramenta eficaz e acessível para fornecer suporte emocional a estudantes universitários, reduzindo sintomas de depressão e ansiedade. No entanto, a IA não deve substituir profissionais de saúde mental, mas atuar como complemento. Recomendam-se estudos futuros com amostras mais amplas e acompanhamento de longo prazo para avaliar a sustentabilidade dos efeitos observados.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
56	Elyoseph <i>et al.</i> , (2024)	No RMET, o ChatGPT-4 obteve 26 e 27 respostas corretas nas duas avaliações, significativamente acima do esperado para respostas aleatórias ($P < 0,001$) e consistente com a média da população geral (26,2; $P > .82$). As respostas mostraram alta confiabilidade (diferença de 6% entre avaliações) e ausência de viés em relação ao sexo ou tipo de emoção. Já o Google Bard apresentou desempenho próximo ao aleatório (10 e 12 respostas corretas; $P > .17$). No LEAS, tanto o ChatGPT-4 quanto o Bard superaram significativamente a média da população geral em todas as categorias (self, other e total; $P < 0,05$), com desempenhos quase idênticos entre si.	O ChatGPT-4 demonstrou eficácia na mentalização visual, apresentando desempenho alinhado aos padrões humanos. Apesar de ambos os modelos terem mostrado habilidade na interpretação de emoções textuais, o desempenho do Bard na identificação de emoções visuais requer maior análise e possíveis aprimoramentos. Este estudo ressalta a importância do desenvolvimento ético da IA para reconhecimento emocional, destacando a necessidade de dados inclusivos, colaboração com pacientes e especialistas em saúde mental, além de supervisão governamental rigorosa para garantir transparência e proteger a privacidade dos usuários.
57	Tutum <i>et al.</i> , (2023)	A versão reduzida do questionário (SCL-28-AI) manteve a capacidade de diagnosticar todos os 10 transtornos analisados, enquanto o modelo L-LR, combinado com as variáveis adicionais do NEPAR, apresentou os melhores resultados em termos de precisão, alcançando 89,18%. Além disso, o uso de inteligência artificial reduziu significativamente o tempo necessário para responder ao questionário, o que resultou em melhoria nas taxas de participação e conclusão.	O sistema proposto oferece abordagem mais eficiente para o diagnóstico de transtornos mentais, mantendo altos níveis de precisão e abrangência. A integração de variáveis de similaridade entre participantes melhora a precisão dos diagnósticos, enquanto a redução de perguntas aumenta a usabilidade e aceitação do questionário. O estudo destaca o potencial da IA em apoiar profissionais de saúde mental e promover diagnósticos mais rápidos e acessíveis.
58	Byeon, (2021)	O modelo de stacking ensemble combinando SVM, Random Forest, LightGBM, Adaboost e XGBoost apresentou o melhor desempenho preditivo, com 87,4% de precisão, 85,1% de precisão positiva, 87,4% de sensibilidade e 85,5% de F1-score. Os principais fatores de risco identificados foram: solidão subjetiva frequente ou constante, baixa pontuação na escala de autoestima (≤ 26), baixa frequência de comunicação com a família (≤ 4 em uma escala de 10 pontos) e experiências recentes de violência ou crimes envolvendo a família.	A solidão, as relações familiares instáveis e a baixa comunicação familiar são preditores importantes de transtorno de ansiedade em idosos. O estudo destaca a necessidade de políticas comunitárias para identificar e gerenciar grupos de alto risco de forma contínua, utilizando tecnologias de IA interpretáveis para apoiar intervenções precoces e prevenir a progressão de transtornos de ansiedade.
59	Dergaa <i>et al.</i> , (2023)	Três cenários simulados avaliaram a atuação do ChatGPT em consultas psiquiátricas fictícias. No primeiro, um estudante de 22 anos enfrentava dificuldade para dormir, devido ao estresse por exames, e o ChatGPT recomendou higiene do sono e técnicas de relaxamento, sugerindo acompanhamento médico, se os sintomas persistissem. No segundo, uma mulher de 58 anos com lúpus relatou problemas de sono, cansaço e baixa autoestima, recebendo orientações para manejo do estresse, suporte psicológico e acompanhamento médico adaptado à condição. No terceiro, uma mãe de 23 anos, após parto traumático, apresentou ansiedade, culpa e insônia, sendo recomendado acompanhamento em saúde mental perinatal, terapia cognitivo-comportamental e suporte emocional. Em todos os casos, o ChatGPT demonstrou empatia e forneceu recomendações úteis, reforçando a necessidade de avaliação médica para decisões clínicas mais complexas.	Os três casos analisaram o desempenho do ChatGPT em consultas de saúde mental, mostrando que, embora ofereça respostas rápidas e empáticas, as limitações tornam-no inadequado para situações clínicas complexas. À medida que a complexidade aumenta, as recomendações se tornam imprecisas e potencialmente perigosas, evidenciando a falta de julgamento clínico e pensamento crítico do modelo. O ChatGPT ainda não é confiável para uso independente na prática médica, sendo necessária supervisão e melhorias significativas, como a integração de fontes confiáveis, para garantir segurança e eficácia na área da saúde.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
60	Chang <i>et al.</i> , (2020)	O modelo EDNN alcançou 100% de precisão no treinamento e, na validação, obteve 84% e 90,22% de precisão para GM e WM, na coorte TAMI, e 77,27% e 70,45%, na coorte Beitou. Após o retreinamento, as precisões aumentaram para 85,50% (GM) e 88,20% (WM), com bom desempenho validado pelas altas pontuações de AUC. A plataforma web **www.brain-diagnosis.com** permite diagnóstico e classificação de esquizofrenia <i>on-line</i> , processando imagens DICOM ou NIFTI para análise de densidade voxel. O sistema gera diagnósticos instantâneos e mapas de saliência 3D, destacando déficits em regiões como a ínsula e os córtices anterior e pré-frontal, oferecendo solução automatizada e acessível para avaliação individualizada.	Destinada a complementar e não a substituir, as entrevistas clínicas convencionais, a plataforma oferece quantificação objetiva da patologia cerebral. A esquizofrenia, caracterizada por sua heterogeneidade e múltiplos sintomas, tem diagnósticos tradicionalmente baseados em perfis sintomáticos, o que pode deixar casos não identificados. Esta ferramenta utiliza modelos de aprendizado profundo para diferenciar esquizofrenia de controles saudáveis, com base em marcadores de imagem e pode ser expandida para outros transtornos psiquiátricos, como transtorno bipolar e depressão.
61	Salhi <i>et al.</i> , (2021)	O chatbot alcançou precisão de 95%, indicando alta capacidade de reconhecimento e resposta adequada aos sentimentos do usuário. Os testes mostraram que o sistema pode conduzir diálogos de forma fluida e clara, identificando emoções e adaptando-se às necessidades do usuário. A coleta de dados mostrou que cerca de 40,54% das interações eram negativas, reforçando a necessidade de suporte psicológico adaptativo, durante períodos de crise.	O estudo concluiu que chatbots de suporte psicológico pode ser ferramenta eficaz para ajudar a população a lidar com transtornos mentais durante pandemias. Foi destacada a importância de continuar melhorando a base de dados do chatbot e ajustar hiperparâmetros para otimizar o desempenho. Estudos futuros devem focar na implementação de técnicas de otimização mais avançadas e na adaptação do chatbot para diferentes populações.
62	Ćosić <i>et al.</i> , (2020)	Detectar sinais precoces de transtornos mentais com maior precisão do que métodos tradicionais. Melhorar a capacidade de triagem dos profissionais de saúde em risco, com base em métricas objetivas e subjetivas. Propor abordagem mais objetiva e baseada em evidências para diagnósticos em psiquiatria, utilizando IA para análise preditiva.	A pesquisa conclui que o uso de IA, na predição de transtornos mentais, pode transformar a psiquiatria em disciplina mais objetiva, reduzindo a subjetividade dos diagnósticos baseados em sintomas relatados pelos pacientes. Além disso, a implementação dessa metodologia pode permitir intervenções precoces e personalizadas, ajudando a prevenir complicações graves de saúde mental em profissionais de saúde expostos ao estresse da pandemia.
63	Liang <i>et al.</i> , (2022)	Os resultados indicaram que a abordagem de educação em saúde mental, baseada em big data, apresentou melhores resultados, em comparação com métodos tradicionais. A proporção de estudantes com saúde mental normal aumentou em 16,7%, enquanto a de estudantes com problemas mentais moderados ou graves diminuiu significativamente. O modelo CNN superou o FastText em métricas de precisão, sendo mais eficiente na detecção de estados mentais urgentes e no reconhecimento de padrões psicológicos.	O uso de IA e big data na educação em saúde mental se mostrou eficaz na melhoria do bem-estar psicológico dos estudantes, especialmente em grupos de risco. A plataforma baseada em big data promoveu maior suporte psicológico e interação entre os estudantes, demonstrando ser ferramenta promissora para educação e intervenção em saúde mental. As análises sugerem que, embora a abordagem seja eficaz, pesquisas futuras devem aprofundar os fatores subjacentes a distúrbios específicos e expandir as comparações com outros modelos de IA.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(continua)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
64	Goldberg <i>et al.</i> , (2020)	Os modelos de aprendizado de máquina utilizados no estudo tiveram desempenho modesto, ao prever as classificações de aliança terapêutica fornecidas pelos clientes. O melhor desempenho foi alcançado, ao utilizar as transcrições das falas dos terapeutas, analisadas com a técnica TF-IDF, resultando em correlação de Spearman (ρ) de 0,15. Isso indica que havia sinais linguísticos detectáveis nas falas dos terapeutas que estavam relacionados à percepção dos clientes sobre a força da aliança terapêutica, embora a precisão preditiva fosse limitada. Os modelos que combinaram dados textuais das falas de clientes e terapeutas não mostraram melhoria significativa no desempenho, sugerindo que as características extraídas das falas dos clientes podem não conter informações suficientes para prever a aliança terapêutica ou que essas características requerem técnicas mais avançadas para serem exploradas.	O estudo demonstrou que aprendizado de máquina e processamento de linguagem natural têm potencial para automatizar a avaliação de aliança terapêutica, embora melhorias sejam necessárias para alcançar maior precisão. Os resultados ressaltaram a possibilidade de usar essas tecnologias em larga escala para monitorar e aprimorar a qualidade do tratamento psicoterapêutico, reduzindo custos e a necessidade de avaliação manual. Estudos futuros devem explorar conjuntos de dados maiores e métodos mais avançados para melhorar a previsibilidade e aplicação prática.
65	Hadar-Shoval <i>et al.</i> , (2024)	Os LLMs demonstraram alta consistência interna nas respostas, com a maioria dos valores apresentando boa confiabilidade ($\alpha > 0,70$). Comparados aos valores humanos, os LLMs priorizaram universalismo e autodireção, enquanto atribuíram menor importância a poder, segurança e realização. Apesar disso, houve variação entre os modelos, refletindo diferenças nos processos de alinhamento usados pelos desenvolvedores. Quando confrontados com dilemas envolvendo valores opostos, os LLMs consistentemente escolheram universalismo sobre poder e autodireção sobre tradição.	O estudo confirmou que os LLMs possuem estrutura motivacional de valores distinta, influenciada por processos de alinhamento e treinamento em dados predominantemente ocidentais e liberais. Isso levanta preocupações éticas para aplicação na saúde mental, pois os vieses incorporados podem limitar a capacidade de atender às necessidades de populações culturalmente diversas. Os autores enfatizaram a importância de maior transparência e padronização nos processos de alinhamento para garantir que esses modelos reflitam espectro mais amplo de valores culturais, promovendo equidade na integração dessas tecnologias em cuidados de saúde mental.
66	Desai <i>et al.</i> , (2021)	Os resultados indicaram que os modelos de aprendizado profundo foram eficazes na identificação de indivíduos com ideias suicidas em ampla amostra canadense. O modelo com 96 variáveis alcançou AUC de 0,79 para ideias suicidas ao longo da vida e 0,71, nos últimos 12 meses, enquanto o modelo com 21 variáveis obteve AUCs de 0,77 e 0,68, respectivamente. O modelo mais complexo demonstrou maior precisão, enquanto o simplificado se destacou pela praticidade em contextos clínicos. Comparados a abordagens tradicionais, como floresta aleatória e boosting por gradiente, os modelos de aprendizado profundo se mostraram competitivos, com vantagem na interpretação de preditores. Além disso, apresentaram alta precisão para excluir indivíduos sem ideias suicidas, embora o menor valor preditivo positivo reforce a necessidade de cautela com possíveis falsos alarmes.	O estudo demonstrou que modelos de aprendizado profundo podem identificar fatores de risco para ideias suicidas, de forma eficaz, em populações gerais. Embora sejam necessários estudos adicionais para validar os resultados em contextos clínicos reais, o modelo mostrou potencial para aplicação em sistemas de apoio à decisão clínica e triagens automatizadas.

Quadro 4 – Síntese dos principais resultados e das conclusões dos estudos selecionados.

(conclusão)

Nº	Autores	Síntese dos Resultados	Síntese das Conclusões
67	Delgado, (2023)	O método apresentou altas taxas de acerto, superiores a 90%, ao identificar padrões de sintomas relacionados à depressão, ansiedade e ao estresse. O Sistema de Inferência Fuzzy demonstrou ser eficaz para realizar previsões rápidas e precisas, podendo ser aplicado em triagens ambulatoriais e atendimentos emergenciais. Além disso, o modelo foi útil para associar sintomas a possíveis intervenções terapêuticas, contribuindo para diagnósticos diferenciais e personalização do tratamento.	O estudo concluiu que o método baseado em IA tem grande potencial para apoiar profissionais de saúde na triagem e no tratamento de transtornos mentais, oferecendo agilidade e precisão, especialmente em contextos com recursos limitados. A lógica fuzzy se mostrou eficiente para lidar com a incerteza e a variabilidade dos dados, tornando o modelo mais adaptável às necessidades clínicas. Trabalhos futuros podem explorar a ampliação da base de dados e a integração do método em plataformas digitais para facilitar a aplicação prática.
68	Martins (2022)	O sistema LEVES foi desenvolvido como MVP funcional para monitorar TMCs. O uso do K-means permitiu agrupar sintomas em <i>clusters</i> significativos, facilitando a análise de padrões de saúde mental. Os resultados indicaram que a ferramenta tem potencial para identificar fatores de risco, correlacionar sintomas com insatisfação no trabalho e fornecer suporte estratégico para promoção de saúde mental no ambiente laboral.	O estudo demonstrou que a integração de técnicas de inteligência artificial no monitoramento de TMCs é viável e promissora para o ambiente de trabalho. O sistema LEVES apresenta potencial para apoiar gestores na tomada de decisões, promover o autoconhecimento emocional e melhorar a qualidade de vida dos trabalhadores. Pesquisas futuras podem aprimorar o sistema, ampliar a aplicação e explorar outros algoritmos de aprendizado de máquina para aumentar a eficiência e precisão.
69	Do Pinho (2023)	O modelo de regressão logística (Logistic Regression) apresentou o melhor desempenho, alcançando precisão de 97%. Os algoritmos foram eficazes em classificar os participantes em categorias relacionadas à presença ou ausência de TDM (não clínico, depressão leve, moderada ou grave). A EDCA-12 mostrou ser instrumento válido e confiável para coleta de dados, e o uso de aprendizado de máquina possibilitou a identificação de padrões relevantes nos fatores de risco e proteção para TDM entre os estudantes.	O estudo demonstrou que o uso de inteligência artificial é uma ferramenta eficaz e promissora para monitorar e identificar fatores relacionados à saúde mental em estudantes universitários. A integração da EDCA-12 com algoritmos de aprendizado de máquina permite análises rápidas e precisas, podendo servir de base para intervenções mais direcionadas e estratégias de prevenção de TDM. Pesquisas futuras devem ampliar a amostra, explorar novos algoritmos e avaliar a aplicação prática da tecnologia em outros contextos educacionais.
70	De Melo (2023)	Os modelos multimodais, que combinam dados de áudios, atividade e mobilidade, apresentaram melhor desempenho do que os unimodais, destacando a relevância da integração de diferentes fontes de dados. A abordagem ideográfica demonstrou maior precisão na previsão do humor deprimido de adolescentes individuais. Entre os atributos mais relevantes para os modelos, destacaram-se: tempo médio de caminhada, coeficientes espectrais de áudios e a distância máxima de casa. O modelo 1D Convolutional Neural Network (1DCNN) foi o mais robusto na maioria das análises, especialmente em tarefas multimodais, devido à capacidade de identificar padrões complexos nos dados temporais e comportamentais.	O estudo mostrou que dados coletados via smartphones podem complementar métodos tradicionais de diagnóstico da depressão em adolescentes. Modelos multimodais demonstraram alta capacidade preditiva e identificaram marcadores digitais promissores, como padrões de mobilidade e atividade. Esses achados oferecem novas perspectivas para intervenções personalizadas em saúde mental e o desenvolvimento de políticas públicas voltadas para adolescentes em risco. Estudos futuros devem ampliar a amostra e explorar novas fontes de dados para refinar os modelos.

Fonte: elaborado pelo autor (2025).

O Quadro 4 sintetiza os estudos incluídos nesta revisão, a respeito do papel da IA nos cuidados a pessoas com transtorno mentais, apontando avanços tecnológicos, desafios éticos e limitações metodológicas. A utilização da IA no diagnóstico e na predição de TM se demonstrou como área em desenvolvimento, com modelos como RF, XGBoost, CNNs e redes neurais profundas, atingindo alta precisão na identificação de padrões em dados clínicos e mídias sociais. A eficácia desses modelos se sobressai especialmente na triagem de condições como depressão, ansiedade, Transtorno de Estresse Pós-Traumático (TEPT) e esquizofrenia, possibilitando agilidade diagnóstica e mais inerente as subjetividades de cada indivíduo. Entretanto, também, foi possível identificar desafios, a exemplo da necessidade de aprimoramento na generalização dos modelos, a presença de viés algorítmico e a limitação dos dados disponíveis que, muitas vezes, não conseguem contemplar as variáveis referentes à diversidade populacional (Kim *et al.*, 2020; Zhang *et al.*, 2023).

Por conseguinte, além do diagnóstico e das predição, as pesquisas sinalizaram para adoção exponencial de IA em intervenções terapêuticas e suporte psicológico. Chatbots como ChatGPT e Gemini, além de aplicativos móveis como Wysa, têm sido empregados como ferramentas complementares para ofertar apoio emocional, fornecer orientações e estimular práticas terapêuticas, como a Terapia Cognitivo-Comportamental (TCC). Essas tecnologias se mostraram eficazes na redução de sintomas de depressão e ansiedade, como também promoveram melhor acessibilidade a serviços de saúde mental (Alanézi, 2024; Chang *et al.*, 2024). Contudo, questões referentes à privacidade, segurança dos dados e incapacidade de interpretar sinais não verbais ainda são vieses que necessitam de maiores esclarecimentos. Somado a isso, é importante salientar, também, a carência de calibragem das respostas geradas por IA para evitar direcionamentos negativos ou excessivamente otimistas, que podem implicar na percepção e na motivação das pessoas com transtorno mental (Elyoseph; Levkovich, 2024).

Os trabalhos também aportam a importância de preditores e fatores de risco na identificação precoce de TM. Fatores relacionados a variáveis sociodemográficas, como idade, gênero, status socioeconômico, histórico familiar e experiências traumáticas se revelam como características-chave na vulnerabilidade a transtornos psicológicos. Assim, as diferenças de gênero foram frequentemente analisadas, com mulheres apresentando maior risco para transtornos depressivos e ansiosos, enquanto homens demonstraram maior propensão a transtornos relacionados ao abuso de substâncias e comportamento suicida (Gradus *et al.*, 2021; Kharrat *et al.*, 2024). A compreensão dessas variáveis é fundamental para aperfeiçoar a personalização dos modelos de IA, no intuito de tornar as abordagens mais precisas e eficazes.

Outro aspecto pertinente é a correlação das redes sociais na identificação precoce de sintomas psicológicos. Diversos estudos analisaram o uso de aprendizado de máquina na detecção de sinais de TM em postagens do Twitter (Atualmente X), Reddit e outras plataformas digitais. Essas análises evidenciaram que a linguagem utilizada pelos usuários pode conter indicativos de estados emocionais e padrões de comportamento sugestivos de TM (Baqir *et al.*, 2024; Villa-Pérez *et al.*, 2023). Entretanto, a eficácia desses modelos pode sofrer influência da dependência de palavras-chave e pelo viés de identificar equivocadamente falsos-positivos, o que demonstra a necessidade de aprimoramento nas técnicas de análise de linguagem natural.

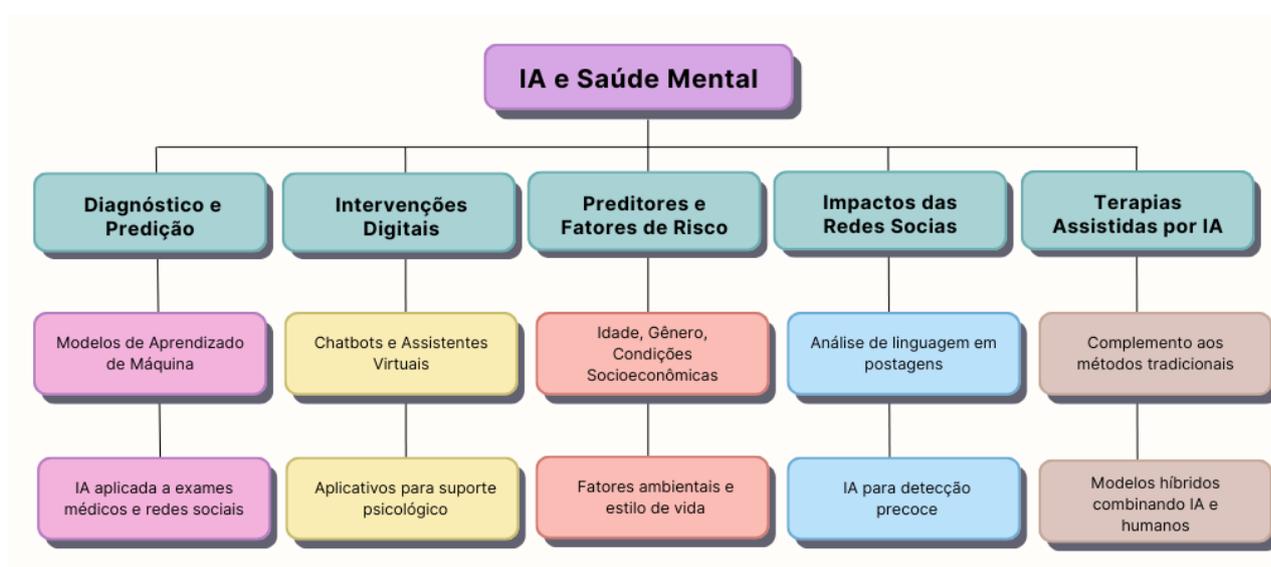
Outrossim, as terapias assistidas por IA também apresentaram grande potencial para complementar os tratamentos convencionais. Alguns estudos apontaram que plataformas baseadas em IA podem suplantam métodos tradicionais na redução de sintomas de determinados TM, otimizando o tempo de terapia e tornando as sessões mais eficazes (Sadeh-Sharvit *et al.*, 2023). Além disso, modelos híbridos, que combinam IA com a expertise humana, aparecem como solução em potencial para equilibrar os benefícios da automação com a humanização e o raciocínio clínico dos profissionais. Todavia, salienta-se que necessidade de validação rigorosa, a adaptação das tecnologias para diferentes populações e o treinamento adequado dos profissionais de saúde são importantes lacunas a serem solucionadas (Berrezueta-Guzman *et al.*, 2024).

Dessarte, os desafios éticos e sociais são constantes em quase todos os estudos incluídos nas discussões sobre o uso da IA na saúde mental. Fatores como privacidade, segurança de dados, viés algorítmico e responsabilidade na tomada de decisões demandam atenção meticulosa. A transparência no desenvolvimento dos modelos, a inclusão de populações diversas nos bancos de dados e a regulamentação do uso da IA na área da saúde são critérios essenciais para minimizar riscos e garantir que essas tecnologias sejam aplicadas de forma segura (Hein *et al.*, 2024; Yoo *et al.*, 2024).

Assim, por perspectiva geral, o Quadro 4 apresenta que a IA tem potencial de transformar a saúde mental, ao oferecer diagnósticos mais rápidos e concisos, ampliar o acesso a tratamentos e aprimorar a personalização das intervenções. Contudo, a implementação deve ser feita com cautela, garantindo que as soluções tecnológicas sejam integradas, de modo a respeitar questões éticas, sendo responsável e centrada nas melhores intervenções para pessoas com TM.

Como forma de melhor organizar os principais resultados, estes foram divididos em categorias, conforme Figura 4.

Figura 4 – Síntese da categorização dos principais resultados dos estudos selecionados.



Fonte: elaborado pelo autor (2025).

O organograma apresentado na Figura 4 subdivide os estudos selecionados em categorias, através de uma visão geral dos achados sobre a aplicação da IA, na saúde mental. A primeira categoria, Diagnóstico e Predição, refere-se ao uso de modelos de aprendizado de máquina para identificar padrões em dados clínicos e redes sociais, permitindo a detecção precoce de TM. Já Intervenções Digitais contemplam a aplicação de *chatbots*, assistentes virtuais e aplicativos para suporte psicológico, que possuem orientações voltadas à saúde mental e formas de manejo de sintomas emocionais.

Ademais, a categoria de Preditores e Fatores de Risco foca na identificação de variáveis sociodemográficas e estilo de vida, que influenciam na vulnerabilidade a TM. O Impacto das Redes Sociais abrange a análise de linguagem natural em postagens *on-line*, como instrumento para detecção de sinais precoces de problemas emocionais, embora desafios como falsos positivos e questões éticas ainda necessitem de maiores investigações. Destarte, Terapias Assistidas por IA abordam o uso da tecnologia para aprimorar tratamentos psicológicos, por intermédio da combinação entre IA e acompanhamento humano, de modo a ofertar abordagens mais singulares e objetivas.

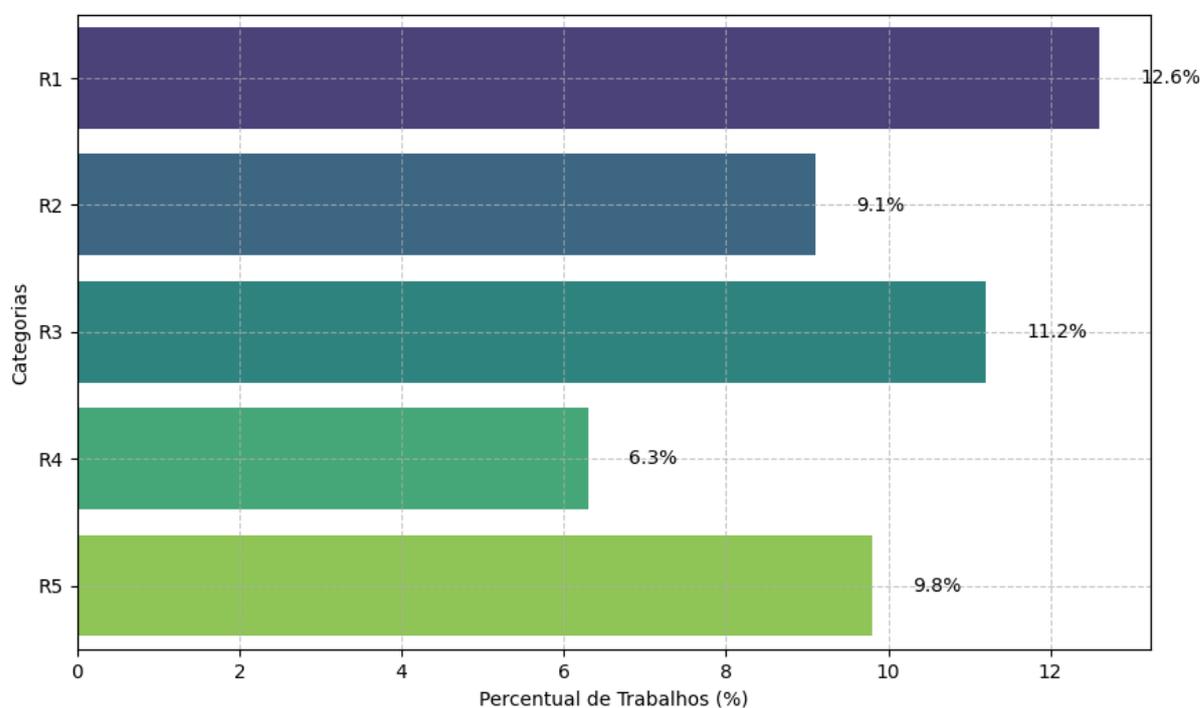
Outrossim, a Tabela 2 e o Gráfico 4 contêm a distribuição das pesquisas, conforme cada categoria elencada.

Tabela 2 – Categorização dos resultados dos estudos selecionados.

Código	Descrição da categoria	Trabalhos que Mencionam essa Categoria	Total de Trabalhos
R1	Modelos de IA para Diagnóstico e Predição de TM	1, 2, 5, 7, 8, 10, 14, 15, 24, 28, 35, 40, 46, 55, 60, 65, 68, 70	18
R2	Aplicações da IA na Saúde Mental e Suporte ao Paciente	6, 11, 16, 17, 19, 30, 32, 45, 48, 51, 56, 58, 62	13
R3	Preditores e Fatores de Risco para TM	4, 9, 12, 13, 18, 22, 27, 29, 33, 37, 42, 47, 50, 57, 64, 67	16
R4	Impacto das Tecnologias Digitais e Redes Sociais	1, 2, 26, 31, 33, 41, 52, 59, 63	9
R5	Intervenções Digitais e Terapias Assistidas por IA	3, 17, 19, 23, 34, 39, 43, 46, 49, 53, 54, 61, 66, 69	14

Fonte: elaborada pelo autor (2025).

Gráfico 4 – Distribuição em percentuais das categorias dos resultados nos estudos selecionados.



Fonte: elaborado pelo autor (2025).

5.2 MODELOS DE IA PARA DIAGNÓSTICO E PREDIÇÃO DE TM

A implementação de modelos IA na área da saúde mental tem se apresentado com avanços notáveis, possibilitando agilidade e precisão diagnóstica. Quantitativo considerável de estudos investigou o uso de aprendizado de máquina e aprendizado profundo para a detecção precoce e monitoramento de transtornos psiquiátricos. Os resultados evidenciaram que esses modelos podem complementar as abordagens clínicas tradicionais, contribuindo para análises fundamentadas em grandes volumes de dados que seriam ineficazes para os profissionais de saúde mental realizarem a análise manualmente.

Em vista disso, o aperfeiçoamento dessas tecnologias também tem permitido o desenvolvimento de modelos altamente precisos para identificação de TM. Nowakowska *et al.* (2023) demonstraram que um classificador de RF teve desempenho formidável no diagnóstico de depressão, enquanto modelo de árvore de gradiente impulsionado (GBT) se destacou na predição de delírio pós-operatório. O modelo RF atingiu taxa de precisão de 67% (AUC=0,67) para depressão, enquanto o GBT previu delírio com 72% de precisão.

Não obstante, também foram identificados estudos que associaram métodos diagnósticos tradicionais como a ressonância magnética funcional (fMRI) e eletroencefalograma (EEG) associados as redes neurais profundas para a predição de TM, técnica que se demonstrou eficaz. Assim, o trabalho de Zhang *et al.* (2023) desenvolveram modelo de aprendizado profundo chamado *Multiple Instance Learning* (MIL), que conseguiu identificar casos de doenças mentais graves com AUC de 82% (AUC=0,82). Comparado a outros modelos como ResNet e EfficientNet, o MIL revelou melhor generalização e menor perda de desempenho, ao mudar de dispositivos de ressonância magnética de diferentes potências.

Outro método diagnóstico inovador foi exposto por Siddiqua *et al.* (2023), que explicitaram o alto desempenho do modelo RF, ao atingir 98,08% de precisão, na identificação de níveis de depressão, destacando-se pela baixa taxa de falsos negativos. A CNN, também, apresentou alto performance (92,31%), sendo eficaz na identificação de TM graves. Esses achados indicam que o uso de IA pode aprimorar consideravelmente as abordagens direcionada à triagem e ao acompanhamento de TM.

5.2.1 Aplicações e Interpretação dos Modelos

A IA tem revolucionado a maneira de como os TM são diagnosticados, ofertando abordagens singulares que excedem métodos tradicionais. Uma das frentes mais promissoras é a análise de linguagem natural, que proporciona a identificação de padrões textuais relacionados a distúrbios psiquiátricos. Neste sentido, o estudo Arif *et al.* (2024) relatou que modelos Transformer apresentam desempenho superior na detecção de sinais de depressão e ansiedade em postagens de mídias sociais. O modelo desenvolvido pelos autores atingiu F1-score de 89,65%, superando abordagens convencionais como a RF que, em comparação, obteve 77,87%. Essa técnica também facilita a análise automatizada de um grande volume de dados, viabilizando melhor direcionamento das intervenções terapêuticas.

Além da análise textual, os modelos de IA têm se mostrado eficazes na predição da progressão de TM. Baqir *et al.* (2024) aplicaram SVM na identificação de sintomas de TEPT, a partir da análise de 3,96 milhões de *tweets*. O modelo alcançou acurácia de 83,29% e evidenciou alterações comportamentais a longo prazo, sugerindo que ferramentas baseadas em aprendizado de máquina podem contribuir para monitorização contínua da saúde mental.

Somado a isso, é importante denotar a respeito da aplicação da IA para avaliação de padrões vocais, como biomarcadores de transtornos psiquiátricos. O trabalho Garcia-Valdez *et al.* (2024) traz abordagem singular, ao empregar o algoritmo RF para analisar modulação do volume vocal, fechamento glotal reduzido e flutuações na prosódia, no intuito de identificar alterações vocais compatíveis com TEPT. Deste modo, os pesquisadores apresentaram a viabilidade da IA como ferramenta não invasiva, direta e de auxílio à decisão clínica, proporcionando subsídios adicionais para o diagnóstico diferencial.

Além desse panorama de aplicações, a IA tem se consolidado como ferramenta promissora para individualização de tratamentos psiquiátricos, fornecendo abordagem estratificada e personalizada. Algoritmos avançados integram informações heterogêneas, contemplando histórico médico, variáveis comportamentais, padrões de sono e interações sociais, refinando a precisão diagnóstica e otimizando a melhor terapêutica a ser empregada para cada indivíduo.

5.3 APLICAÇÕES DA IA NA SAÚDE MENTAL E NO SUPORTE AO PACIENTE

A incorporação da IA na saúde mental tem disponibilizado abordagens diferenciadas no acesso a intervenções psicológicas, potencializando o suporte ao paciente e incrementando novas abordagens terapêuticas. À vista disso, tecnologias baseadas em aprendizado de máquina, processamento de linguagem natural e redes neurais demonstraram grande potencial de utilização para fornecer acompanhamento psicológico virtual, detecção precoce de transtornos e personalização de terapias. Essa revolução tecnológica expande a capacidade de intervenção dos profissionais de saúde, como também democratiza o acesso a serviços especializados, principalmente em cenários cuja assistência psiquiátrica é limitada.

5.3.1 Plataformas Digitais e *Chatbots* Terapêuticos

Uma das principais aplicações da IA no suporte à saúde mental é o desenvolvimento de *chatbots* terapêuticos e assistentes virtuais, que atuam como ferramentas de triagem, aconselhamento inicial e monitoramento contínuo de sintomas. Esses sistemas, baseados em Processamento de Linguagem Natural (PLN), conseguem analisar padrões discursivos, reconhecer sinais de sofrimento psicológico e fornecer respostas empáticas e orientações personalizadas.

Nessa perspectiva, o trabalho de Joerin, Rauws e Ackerman (2019) avaliou o impacto do *chatbot* Tess, em que os pesquisadores conseguiram identificar efetividade na redução de sintomas de ansiedade e depressão, com diminuição de 13% e 18%, respectivamente. Além disso, salienta-se, também, que o alto nível de engajamento dos usuários — que trocaram mais de 12.000 mensagens no período de 30 dias — pressupõe que essas ferramentas podem oferecer suporte continuado e sob demanda, particularmente às populações que enfrentam barreiras geográficas no acesso a profissionais de saúde mental. O estudo também evidenciou a relação custo-efetividade desse tipo de intervenção, com economia estimada de US\$ 585.000 para organização SE Health. Destarte, os *chatbots* terapêuticos foram capazes de prestar apoio a um grande quantitativo de pessoas com TM, englobando mais de 20.000 adultos nos EUA e no Canadá.

Contudo, apesar dessas vantagens expressivas, há obstáculos a serem superados, como a interpretação de subjetividades emocionais e a ausência de interação humana, fatores que podem limitar a experiência dos usuários e a profundidade das respostas fornecidas.

5.3.2 Monitoramento Remoto e Predição de Episódios Psiquiátricos

Outro aspecto em que a IA tem impulsionado avanços é no monitoramento remoto da saúde mental, permitindo a coleta e análise constante de dados fisiológicos e comportamentais. Dispositivos vestíveis, aplicativos móveis e sensores integrados a *smartphones* e *smartwatches* são capazes de rastrear variáveis como padrões de sono, atividade física, frequência cardíaca e interações digitais. Essas informações fornecem subsídios para identificação preliminar de episódios psiquiátricos e melhor direcionamento dos cuidados profissionais.

Os estudos selecionados, também, indicaram que modelos de aprendizado profundo podem prever internações psiquiátricas e recaídas. Os resultados alcançados por Palacios-Ariza *et al.* (2023) demonstraram que o RF foi o modelo mais eficaz para prever admissões psiquiátricas, com precisão de 95,1% (AUC=0,95). Entre os principais preditores identificados, ressaltam-se: número de visitas de emergência psiquiátrica; consultas ambulatoriais prévias; e idade do paciente de hospitalizações. A IA tem sido aplicada na avaliação de múltiplos transtornos psiquiátricos. Outro importante achado está presente no trabalho De Lacy *et al.* (2023) que analisaram o desempenho de diferentes algoritmos e observaram que o aprendizado profundo apresentou os melhores resultados para ansiedade e déficit de atenção, enquanto modelos baseados em árvores foram mais eficazes para depressão e Transtorno de Estresse Pós-Traumático (TEPT).

Somado a isso, a capacidade de analisar padrões linguísticos e emocionais para prever crises emocionais é mais um aspecto fundamental identificados nos resultados. O trabalho desenvolvido por Kerz *et al.* (2023) demonstrou que o Mental RoBERTa, modelo especializado em detecção de transtornos psiquiátricos, atingiu 81,62% de precisão na identificação de estresse, 70,50% para ansiedade e 71,83% para transtorno bipolar. O modelo se sobressaiu ao incorporar dados emocionais e traços de personalidade, potencializando a precisão das previsões.

Contudo, os autores também destacaram alguns fatores vulneráveis quanto ao uso desse tipo de IA. Para Yoo *et al.* (2024), muitos modelos preditivos de IA desconsideraram aspectos sociais e emocionais na detecção de recaídas psiquiátricas. De acordo com os autores, os usuários não confiaram completamente nos alertas ou nas recomendações gerados pela IA e, antes de adotar as recomendações, buscaram a validação de familiares e profissionais de saúde. Desta forma, ficou evidente a necessidade de que os modelos de IA aplicados à saúde mental operem de modo independente, mas funcionem como ferramenta complementar que auxilie, e não substitua a interação humana no cuidado psicossocial.

5.4 PREDITORES E FATORES DE RISCO PARA TM

Conforme foi possível observar na categoria anterior, a IA tem sido amplamente utilizada para identificar fatores de risco e preditores de TM, permitindo análises acentuadas sobre as variáveis que influenciam a predisposição de TM. Neste sentido, alguns estudos apontaram que a combinação de fatores biológicos, sociais e comportamentais desempenha forte influência no desenvolvimento dessas condições. O uso de modelos de ML e DL tem permitido maior precisão no mapeamento dos riscos.

5.4.1 Fatores Biológicos e Clínicos

O uso de IA para detecção de biomarcadores é outro ponto importante a salientar, tendo em vista o potencial de precisão na identificação de padrões associados a transtornos. Isso posto, Nemesure *et al.* (2021) evidenciaram que o modelo desenvolvido alcançou AUC de 0,73 para Transtorno de Ansiedade Generalizada (TAG) e 0,67 para Transtorno Depressivo Maior (TDM). Os preditores centrais identificados pelos autores para o TDM incluíram satisfação com as condições de vida, uso de seguro público de saúde, pressão arterial diastólica elevada, morar na casa dos pais e dificuldades de memorização. Já para o TAG, os fatores mais relevantes foram uso de maconha, hipertensão, vacinação em dia e realização de exames médicos de rotina.

Outro estudo relevante foi realizado por Cansel *et al.* (2023), que avaliou a eficácia de modelos de ML na detecção de transtornos psiquiátricos por intermédio dos padrões vocais. O modelo baseado em kNN apresentou precisão de 96,94%, enquanto o SVM obteve 96,47%, destacando-se na identificação de transtorno bipolar, transtornos de ansiedade e esquizofrenia. Esses achados denotaram que a análise de padrões vocais pode ser estratégia eficaz para o diagnóstico de TM, possibilitando celeridade e objetividade na identificação de sintomas.

Por conseguinte, Shao *et al.* (2023) utilizaram-se de sinais de EEG e imagens de fMRI, no intuito de detectar TDAH e depressão. Modelos de ML apresentaram taxas de acerto superiores a 90%, validando que essas técnicas baseadas em IA podem oferecer alta precisão diagnóstica e maior acessibilidade.

5.4.2 Fatores Psicossociais e Ambientais

A interação entre fatores sociais e ambientais exerce impacto significativo na saúde mental, repercutindo tanto no desenvolvimento quanto no acirramento de TM. Com o avanço da IA, tornou-se possível analisar grandes volumes de dados e identificar padrões que correlacionam variáveis externas com a vulnerabilidade psicológica. A literatura científica tem evidenciado que aspectos como carga de trabalho, condições socioeconômicas, qualidade do sono e demandas acadêmicas estão diretamente associados ao risco de TM.

No contexto ocupacional, Wang *et al.* (2021) desenvolveram modelo preditivo que atingiu 92,55% de precisão, demonstrando que variáveis, como idade, tipo de emprego, intensidade do trabalho e padrões de sono são determinantes para saúde mental de trabalhadores da área médica. O estudo evidenciou que a exposição continuada a pacientes com Covid-19 teve efeito significativo sobre a estabilidade emocional desses profissionais, aumentando a incidência de estresse, *burnout* e transtornos depressivos.

Além do ambiente profissional, o meio acadêmico também apresenta desafios consideráveis para a saúde mental. Rezapour e Elmshaeuser (2022) investigaram a relação entre exigências acadêmicas e sofrimento emocional em estudantes universitários, e tiveram como resultados que aulas *on-line*, desempenho acadêmico, suporte financeiro e insatisfação com políticas institucionais estavam fortemente correlacionados a níveis elevados de frustração

emocional. A aplicação do modelo RF, que atingiu 96,77% de precisão, revelou que dificuldades acadêmicas e instabilidade financeira são fatores críticos na predisposição a TM.

Além das variáveis relacionadas ao trabalho e à educação, hábitos de vida desempenham influências nos níveis de saúde mental. Dhariwal *et al.* (2024) analisaram a influência do estilo de vida na prevalência de transtornos psiquiátricos, utilizando o teste de Stroop como métrica de desempenho cognitivo. Modelos de ML atingiram 99,79% de precisão, identificando que uso de álcool, tabagismo, exposição ao estresse e qualidade do sono são fatores determinantes na vulnerabilidade a TM.

5.5 IMPACTO DAS TECNOLOGIAS DIGITAIS E REDES SOCIAIS

Um dos principais avanços no uso das tecnologias digitais para a saúde mental é a análise de postagens em redes sociais para identificação de TM. Dessa maneira, Kim *et al.* (2020) demonstraram que modelos de ML aplicados a textos publicados em plataformas digitais podem detectar sintomas de depressão com alta precisão. Entretanto, os autores destacaram limitações, como o desequilíbrio de classes nos dados e a ausência de informações demográficas, que podem comprometer a generalização dos resultados. Achados semelhantes foram relatados por Banerjee *et al.* (2024), que observaram aumento significativo do interesse público pelo uso de IA na saúde mental. Os autores salientaram que, apesar do potencial dessas ferramentas para aprimorar diagnósticos e personalizar terapias, a privacidade de dados e os vieses algorítmicos permanecem obstáculos a serem superados antes da adoção em larga escala.

Além da detecção de sintomas, as tecnologias digitais também têm sido exploradas como suporte terapêutico. Elyoseph e Levkovich (2024) analisaram o desempenho de modelos de linguagem generativa, como ChatGPT-4, Claude e Bard (atualmente Gemini), na formulação de prognósticos para pacientes com esquizofrenia. Os resultados apontaram que essas ferramentas apresentaram alinhamento significativo com avaliações profissionais, mas as variações no tom e no conteúdo das respostas podem influenciar a motivação dos pacientes. Esses achados estão em consonância com os de Jain, Pareek e Carlbring (2024), que examinaram a percepção dos usuários sobre respostas geradas por IA em interações sobre saúde mental. O estudo demonstrou que, quando os participantes sabiam que as respostas eram

geradas por IA, a percepção de autenticidade era reduzida, reforçando a necessidade da empatia humana no suporte psicológico.

Outro aspecto relevante foi a aplicação de ML na previsão do comportamento dos usuários em relação à busca por ajuda psicológica. A pesquisa realizada por Kundu *et al.* (2022) avaliou modelos preditivos para identificar padrões que indicaram a procura por atendimento em saúde mental. Embora os modelos tenham demonstrado desempenho satisfatório na previsão de certos comportamentos, a ausência de variáveis contextuais, como barreiras culturais e socioeconômicas, limitou a precisão dos resultados. Essa dificuldade em capturar fatores mais subjetivos também foi observada por Tate *et al.* (2020), que analisaram a eficácia de modelos de ML na previsão de problemas psicológicos em adolescentes. Embora os modelos tenham demonstrado desempenho razoável, os autores concluíram que a aplicabilidade clínica ainda é limitada e que estratégias preventivas personalizadas são imprescindíveis para minimizar os impactos negativos dos TM na juventude.

No campo das intervenções digitais, Chang *et al.* (2024) investigaram o uso do aplicativo Wysa para suporte em saúde mental. Os resultados indicaram alta taxa de engajamento dos usuários, sugerindo que plataformas digitais podem complementar os serviços tradicionais, especialmente no manejo de sintomas de ansiedade e depressão. No entanto, os autores salientaram que essas ferramentas devem ser integradas a sistemas de suporte humano para garantir cuidado mais eficaz e personalizado.

5.6 INTERVENÇÕES DIGITAIS E TERAPIAS ASSISTIDAS POR IA

Um dos principais avanços no âmbito das intervenções digitais e terapias assistidas por IA é a aplicação de modelos para detecção e gestão de sintomas de TM. O trabalho de Hoffman *et al.* (2024) demonstrou que algoritmos de ML, como *gradient boosting*, são eficazes para diferenciar pacientes ofensores e não ofensores com transtornos psiquiátricos, no entanto, a precisão do modelo foi moderada. Os autores ressaltaram ainda que apenas variáveis sociodemográficas não são suficientes para prever padrões comportamentais complexos, indicando a necessidade de incluir informações clínicas mais detalhadas. De maneira semelhante, Kharrat *et al.* (2024) analisaram modelos preditivos para risco de suicídio, identificando que o XGBoost apresentou os melhores resultados, com alta precisão e

especificidade. O estudo destacou a relevância de integrar variáveis programáticas e contextuais na predição, indicando que essas ferramentas podem auxiliar na implementação de estratégias preventivas.

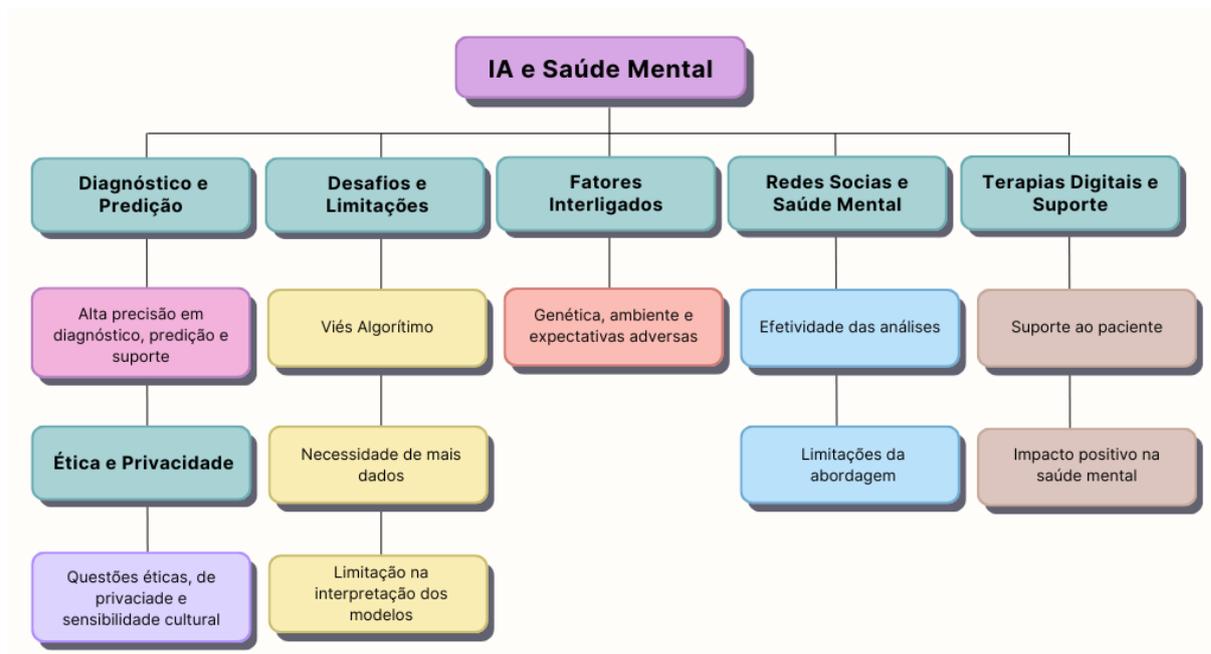
Outra abordagem que novamente se destacou foi o uso de *chatbots* e assistentes virtuais para o suporte terapêutico. Berrezueta-Guzman *et al.* (2024) avaliaram a aplicação do ChatGPT personalizado como ferramenta auxiliar em terapia para crianças TDAH. Os profissionais relataram que a ferramenta foi eficaz para manter o envolvimento dos usuários e incentivar a autonomia, mas expuseram preocupações sobre privacidade, confidencialidade e limitações na interpretação de sinais não verbais. Essa questão ética e funcional também foi levantada por Alanézi (2024), que investigou o uso do ChatGPT para suporte à saúde mental em público mais amplo. O trabalho revelou que a ferramenta é útil para orientações educacionais em saúde, autoavaliação de sintomas e incentivo à adoção de hábitos saudáveis. Todavia, os participantes destacaram que a IA não substitui a interação humana, enfatizando novamente que o uso deve ser complementar e não substituir terapias convencionais.

As implicações da personalização das intervenções digitais também foi temática recorrente nos estudos. Ayodele, Adetunla e Akinlabi (2024) abordaram que modelos de ML, especialmente o RF, podem fornecer informações singulares sobre os fatores de risco para depressão. Os achados indicaram que a integração de múltiplas fontes de informação, como histórico médico e fatores comportamentais, possibilita melhor direcionamento diagnóstico e o desenvolvimento de intervenções. Em consonância a isso, De Lacy *et al.* (2023) investigaram o uso de ML para identificar preditores específicos de TM em jovens, denotando que técnicas como redes neurais artificiais e XGBoost oferecem alto grau de acurácia e generalização. O estudo reforça que a personalização baseada em dados psicossociais pode obter maior eficácia do que abordagens generalistas.

Dessarte, a utilização de IA como meio de suporte para terapeutas também foi outro ponto explorado nos estudos. Conforme exposto por Sadeh-Sharvit *et al.* (2023), a implementação da plataforma Eleos, baseada em IA, resultou em maior adesão dos clientes, redução nos sintomas de ansiedade e depressão e maior eficiência, no tempo de documentação dos terapeutas. Os autores apontaram também que a integração de IA em contextos clínicos pode potencializar processos terapêuticos, favorecendo maior foco dos profissionais na interação com os pacientes.

A seguir, a Figura 5 exibe a síntese da categorização das principais conclusões dos artigos seleccionados.

Figura 5 – Síntese da categorização das principais conclusões dos estudos seleccionados.



Fonte: elaborado pelo autor (2025).

A estrutura disposta na Figura 5 agrupa as categorias elencadas nas conclusões em seis tópicos principais, refletindo os avanços e desafios na utilização dessas tecnologias no campo da saúde mental. A primeira categoria, Diagnóstico e Predição, refere-se a modelos de ML e ao potencial para identificação precoce de TM. As implicações das aplicações dessas ferramentas para triagem e no monitoramento de sintomas e os desafios encontrados. Além disso, o segundo tópico, Intervenções Digitais, concerne a *chatbots*, assistentes virtuais e aplicativos e potencialidades para suporte psicológico. Além disso, aponta o uso na psicoeducação e no gerenciamento de sintomas emocionais. Contudo, os estudos também trouxeram conclusões sobre a falta de personalização e dificuldade na interpretação de sinais emocionais complexos.

Ademais, o terceiro tópico, Preditores e Fatores de Risco, aborda as variáveis sociodemográficas, ambientais e comportamentais e como essas influenciam a vulnerabilidade aos TM. Neste sentido, exploraram-se, também, as conclusões sobre a acurácia na identificação desses fatores, a generalização para diferentes populações e o emprego de novas. Como quarto tópico, Impacto das Redes Sociais, constatou-se sobre a utilidade da análise de linguagem natural em postagens *on-line* para detecção precoce de sofrimento emocional. Os desafios

também foram contemplados, no que se refere a falsos positivos, contexto cultural das interações e preocupações éticas sobre privacidade e consentimento dos usuários.

No tocante ao quinto tópico, Terapias Assistidas por IA, este sintetizou as deduções sobre a combinação de IA com acompanhamento humano e a efetividade nas abordagens terapêuticas. Além disso, esse tópico também contemplou o uso da IA para suporte complementar às terapias tradicionais. Por fim, o sexto e último tópico, Desafios Éticos e Limitações, reforçou as barreiras da implementação de IA na área da saúde mental, discorrendo sobre viés algorítmico, segurança dos dados, privacidade dos usuários e validação científica.

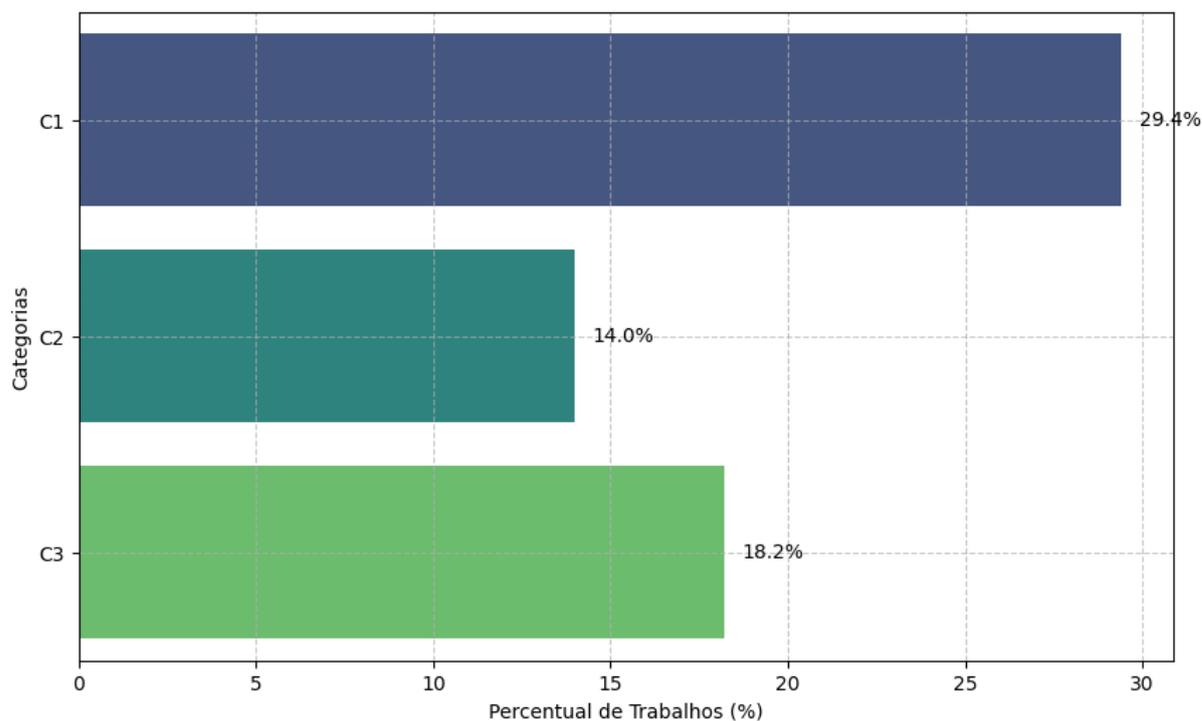
Outrossim, a Tabela 3 e o Gráfico 5 contêm a distribuição das pesquisas, conforme cada categoria elencada nas conclusões.

Tabela 3 – Categorização das conclusões nos estudos selecionados.

Código	Descrição da categoria	Trabalhos que Mencionam essa Categoria	Total de Trabalhos
C1	Modelos de IA demonstraram alta precisão para diagnóstico, predição ou suporte à saúde mental, incluindo limitações como viés algorítmico e necessidade de mais dados.	1, 2, 5, 6, 7, 8, 9, 10, 12, 14, 15, 16, 17, 20, 22, 24, 26, 28, 29, 31, 35, 36, 37, 40, 41, 44, 46, 47, 50, 52, 55, 56, 58, 60, 62, 64, 65, 67, 68, 69, 70	42
C2	Transtornos mentais resultam de múltiplos fatores interligados, como genética, ambiente e experiências adversas.	4, 9, 12, 13, 18, 22, 27, 29, 31, 33, 37, 42, 47, 50, 52, 57, 59, 63, 64, 67	20
C3	IA mostrou potencial para terapias digitais, suporte ao paciente e detecção precoce, abordando, também, questões éticas e privacidade.	3, 6, 11, 16, 17, 19, 21, 23, 25, 30, 32, 34, 38, 39, 43, 45, 46, 48, 49, 53, 54, 56, 58, 61, 62, 66	26

Fonte: elaborado pelo autor (2025).

Gráfico 5 – Distribuição das categorias das conclusões nos estudos selecionados.



Fonte: elaborado pelo autor (2025).

5.7 MODELOS DE IA DEMONSTRARAM ALTA PRECISÃO PARA DIAGNÓSTICO, PREDIÇÃO OU SUPORTE À SAÚDE MENTAL, INCLUINDO LIMITAÇÕES COMO VIÉS ALGORÍTMICO E NECESSIDADE DE MAIS DADOS

A IA se demonstrou amplamente aplicada na saúde mental, possibilitando avanços no diagnóstico, na predição de riscos e no suporte ao tratamento psicológico. Estudos evidenciaram que modelos de ML podem processar grandes volumes de dados e identificar padrões sutis que podem passar despercebidos em abordagens convencionais (Sinha; Meheli; Kadaba, 2023). Técnicas como redes neurais e árvores de decisão têm sido empregadas na detecção de TM, como depressão, transtorno de ansiedade generalizada e TEPT, proporcionando maior precisão nos diagnósticos (Oh *et al.*, 2020; Nash; Nair; Naqvi, 2023).

Além de aprimorar a identificação de TM, a IA tem sido explorada na predição de crises emocionais e comportamentos de risco, incluindo tentativas de suicídio. Modelos preditivos, baseados em aprendizado supervisionado, demonstraram capacidade de identificar fatores de risco com alta precisão, analisando variáveis clínicas, comportamentais e sociodemográficas

(Abdullah; Negied, 2024; Victor *et al.*, 2019). Entretanto, a interpretação isolada desses padrões pode gerar falsos positivos, enfatizando a necessidade de complementar a IA com avaliação clínica humana para garantir maior confiabilidade nos resultados (Oh *et al.*, 2020).

Outro avanço significativo da IA na saúde mental foi a aplicação em suporte psicológico digital. Assistentes virtuais e *chatbots*, baseados em modelos de linguagem avançados, têm sido utilizados para monitoramento emocional e fornecimento de orientações personalizadas (Joerin; Rauws; Ackerman, 2019). Essas ferramentas podem aumentar a acessibilidade ao cuidado em saúde mental, especialmente para indivíduos com barreiras ao atendimento tradicional, como escassez de profissionais especializados ou dificuldades financeiras (Mehta *et al.*, 2021). Contudo, pesquisadores ressaltam que, apesar dos benefícios, esses sistemas devem ser complementares ao acompanhamento humano, pois a relação terapêutica ainda desempenha papel essencial na adesão e eficácia do tratamento (Jain; Pareek; Carlbring, 2024).

Apesar dos avanços, a implementação da IA na saúde mental enfrenta desafios importantes. Questões como a necessidade de bases de dados mais diversificadas, a mitigação de vieses algorítmicos e a aceitação dessas tecnologias por profissionais da saúde são aspectos fundamentais a serem considerados para garantir o uso eficaz (Popescu *et al.*, 2021; Nash; Nair; Naqvi, 2023). Somado a isso, preocupações éticas, como privacidade e transparência no uso dos algoritmos, continuam sendo debatidas e exigem regulamentações que assegurem a segurança dos pacientes e a confiabilidade dos modelos preditivos (Doki *et al.*, 2021).

Em síntese, a IA representa avanço promissor para o cuidado em saúde mental, contribuindo para diagnósticos mais rápidos, previsões mais acuradas e maior acessibilidade ao suporte psicológico. No entanto, o impacto positivo dependerá de estratégias que garantam a integração ética e segura à prática clínica tradicional. Quando aplicada de forma responsável e respaldada por evidências científicas, a IA pode se tornar aliada essencial na ampliação e qualificação do atendimento em saúde mental.

5.8 TRANSTORNOS MENTAIS RESULTAM DE MÚLTIPLOS FATORES INTERLIGADOS, COMO GENÉTICA, AMBIENTE E EXPERIÊNCIAS ADVERSAS

Os TM são fenômenos complexos, resultantes da interação entre fatores genéticos, ambientais, sociais e experiências adversas. Essa natureza multifatorial evidencia a interdependência entre aspectos biológicos, emocionais e contextuais, moldando tanto a vulnerabilidade quanto a manifestação de diversas condições psiquiátricas. Os trabalhos selecionados foram consoantes, ao demonstrar que TM não surgem isoladamente, mas da convergência de múltiplos fatores que interagem de maneira dinâmica e, por vezes, imprevisível.

Estudos como o de Gradus *et al.* (2021) ressaltam a intrincada relação entre transtornos psiquiátricos, uso de medicamentos e fatores sociodemográficos, no aumento do risco de tentativas de suicídio. A pesquisa concluiu que indivíduos com histórico de depressão ou transtorno de estresse que não receberam tratamento adequado, apresentaram maior vulnerabilidade ao comportamento suicida. Além disso, a análise identificou que fatores como idade, estado civil e histórico de abuso de substâncias intensificam esses riscos, demonstrando a relevância de abordagem integrada que considere o contexto clínico e social do indivíduo.

Diante disso, a importância das experiências adversas ao longo da vida também é sublinhada por Siddiqua *et al.* (2023), que identificaram violência emocional, dificuldades financeiras e estresse acadêmico, como fatores críticos no desenvolvimento da depressão. A utilização de IA explicável (LIME) permitiu identificar como essas experiências, em interação com fatores comportamentais, geram padrões emocionais específicos, evidenciando o potencial da tecnologia em decodificar a complexidade das influências psicossociais.

A interseção entre tecnologia e saúde mental também foi abordada por Hein *et al.* (2024), que analisaram o impacto das experiências digitais no bem-estar psicossocial. O estudo demonstrou que a imersão em ambientes virtuais e o vínculo com avatares digitais atuam como preditores de ansiedade, especialmente entre indivíduos com alta conectividade a comunidades digitais. Essa pesquisa expõe novo aspecto da saúde mental contemporânea, demonstrando que interações tecnológicas podem tanto ampliar o suporte emocional quanto intensificar o isolamento e a ansiedade.

O ambiente acadêmico, por sua vez, é uma arena significativa para manifestação de sofrimento emocional. Rezapour e Elmshaeuser (2022) denotaram que frustrações acadêmicas, insatisfação com políticas institucionais e aumento da pressão durante a pandemia da Covid-19 geraram níveis elevados de estresse emocional entre estudantes. Esse estudo ilustra como fatores contextuais, como o ambiente educacional e crises globais, influenciam a saúde mental, apontando para necessidade de intervenções institucionais mais acolhedoras.

No campo dos determinantes biomédicos e sociodemográficos, Ayodele *et al.* (2024) exploraram como fatores como idade, status socioeconômico e histórico familiar impactam a predisposição à depressão. A pesquisa evidenciou que indivíduos com histórico familiar de TM e condições de vulnerabilidade social são mais propensos ao desenvolvimento de quadros depressivos, ressaltando a importância de integrar dados clínicos e comportamentais para intervenções preventivas e personalizadas.

Dessarte, as influências do ambiente ocupacional são ressaltadas por Wang *et al.* (2021), que analisaram as consequências da pandemia da COVID-19 na saúde mental de profissionais da saúde. O estudo revelou que a alta carga de trabalho, a exposição constante ao sofrimento de pacientes e a privação de sono contribuíram para níveis elevados de estresse e burnout. Essa análise enfatiza que o contexto profissional é fator determinante na saúde mental, destacando a importância de políticas institucionais de suporte e prevenção.

Essas investigações, em conjunto, evidenciaram que os TM resultaram da interação complexa entre fatores biológicos, emocionais, sociais e contextuais. Métodos avançados, como o ML (Siddiqua *et al.*, 2023; Ayodele *et al.*, 2024), permitiram identificar padrões ocultos que escapam à observação clínica tradicional, enquanto abordagens psicossociais (Rezapour; Elmshaeuser, 2022; Hein *et al.*, 2024) ressaltaram o papel crucial do ambiente e das experiências subjetivas. Compreender essa interconectividade é fundamental para o desenvolvimento de estratégias terapêuticas mais eficazes e humanizadas, que considerem o ser humano em integralidade.

5.9 IA MOSTROU POTENCIAL PARA TERAPIAS DIGITAIS, SUPORTE AO PACIENTE E DETECÇÃO PRECOCE, ABORDANDO TAMBÉM QUESTÕES ÉTICAS E PRIVACIDADE

A IA apresentou papel transformador na evolução das terapias digitais, na ampliação do suporte ao paciente e na detecção precoce de TM. Os trabalhos identificados evidenciaram que a IA aprimorou a triagem, o diagnóstico e o tratamento de condições psiquiátricas, ao mesmo tempo em que oferece suporte acessível e personalizado. Contudo, apesar dos avanços, questões éticas e desafios relacionados à privacidade também foram levantados no centro do debate, exigindo regulamentações e diretrizes claras para uso seguro e responsável.

Nesse sentido, Sofia *et al.* (2023) demonstraram a eficácia do ML na detecção da depressão, destacando que modelos como o KNN atingem níveis elevados de precisão diagnóstica. Além disso, ressaltaram a relevância de ferramentas que possibilitem monitoramento contínuo, por meio de questionários mais detalhados e acompanhamento semanal, proporcionando entendimento mais aprofundado do estado emocional dos pacientes. Esses achados reforçaram a ideia de que a IA pode atuar tanto na identificação precoce de transtornos quanto na personalização das abordagens terapêuticas.

Corroborando essa perspectiva, Caulley *et al.* (2023) analisaram o impacto da IA na saúde comportamental, explorando a eficácia de uma plataforma de suporte terapêutico baseada em IA. Os resultados indicaram que a adoção dessa ferramenta não apenas ampliou a adesão às sessões terapêuticas, como também gerou melhorias substanciais nos sintomas de depressão e ansiedade. Assim, a IA surge como solução promissora para democratizar o acesso aos tratamentos de saúde mental, tornando-os mais inclusivos e eficazes.

Por conseguinte, Hein *et al.* (2024) e Banerjee *et al.* (2024) reforçaram essa visão, ao evidenciar que a IA tem sido essencial na personalização do suporte ao paciente. Segundo esses estudos, algoritmos de aprendizado profundo permitem prever sintomas e adaptar intervenções com base em padrões comportamentais, promovendo abordagem mais proativa e individualizada. Nesse sentido, Zhang *et al.* (2023) demonstraram que técnicas como *Multiple Instance Learning* (MIL) possuem alta precisão na identificação de doenças mentais graves, ampliando as aplicações clínicas. Não obstante, Baqir *et al.* (2024) analisaram a eficácia dos modelos de SVM na detecção de sintomas de TEPT, em postagens de mídias sociais, evidenciando o potencial dessas abordagens para triagem digital de TM.

O avanço dessas tecnologias foi sustentado por outros estudos, como os de Nash, Nair e Naqvi (2023), Abdullah e Negied (2024) e Victor *et al.* (2019), que enfatizaram o potencial da IA para oferecer suporte personalizado e intervenções baseadas na complexidade de dados. Modelos como redes neurais profundas, aprendizado supervisionado e processamento de linguagem natural têm sido amplamente utilizados para identificar padrões em dados clínicos e prever riscos associados a transtornos psiquiátricos. A flexibilidade dessas ferramentas permite adaptar os tratamentos às necessidades individuais dos pacientes, favorecendo atendimento mais eficaz e menos invasivo.

Entretanto, apesar dos benefícios evidentes, a implementação da IA na saúde mental levanta preocupações sobre privacidade e ética. Doki *et al.* (2021) e Popescu *et al.* (2021) alertam que a coleta e o armazenamento de dados sensíveis exigem regulamentações rigorosas para evitar o uso indevido das informações dos pacientes. Somado a isso, a presença de vieses algorítmicos e a necessidade de validação dos modelos em diferentes populações são desafios que precisam ser contempladas. Diante desse cenário, a IA representa avanço significativo na saúde mental, com aplicações que abrangem desde a triagem inicial até o suporte terapêutico contínuo. Todavia, o êxito desta depende da implementação de estratégias que assegurem não apenas a eficácia clínica, como também a integridade ética e o respeito à privacidade dos usuários.

6 CONCLUSÃO

A presente revisão de escopo teve como objetivo mapear e analisar as evidências científicas sobre a utilização da IA como ferramenta de cuidado em saúde mental, destacando aplicabilidade, potencialidades e desafios. O avanço da IA, no campo da saúde, tem possibilitado a criação de novas estratégias para diagnóstico, monitoramento e tratamento de transtornos mentais, fornecendo suporte aos profissionais da área e ampliando o acesso a serviços de saúde, especialmente em contextos em que há carência de profissionais especializados.

Os achados deste estudo demonstraram que a IA pode ser aplicada em diversas frentes dentro da assistência em saúde mental, incluindo a triagem de pacientes, a predição de crises e recaídas, o suporte ao diagnóstico e até mesmo a personalização do tratamento, por meio da análise de grandes volumes de dados. Ferramentas baseadas em ML e DL têm sido empregadas para identificar padrões em sintomas clínicos, prever riscos de transtornos e otimizar a tomada de decisões dos profissionais de saúde. Além disso, tecnologias como *chatbots* e aplicativos de suporte psicológico baseados em IA têm sido utilizados como complementos ao atendimento convencional, proporcionando maior acessibilidade ao cuidado.

Entretanto, apesar dos avanços notáveis, diversos desafios ainda precisam ser superados para garantir implementação segura e eficaz da IA no cuidado à saúde mental. Entre os principais desafios estão a confiabilidade e a precisão dos algoritmos, a transparência nos processos de tomada de decisão, a segurança e privacidade dos dados dos pacientes, além das questões éticas relacionadas à substituição parcial ou total do atendimento humano por sistemas automatizados. A escassez de padronização na validação dessas tecnologias e a necessidade de regulamentações específicas também representam barreiras para ampla adoção.

Outro aspecto relevante identificado nesta revisão foi a desigualdade no acesso às tecnologias de IA na saúde mental. Grande parte dos estudos analisados se concentrou em países de alta renda, com maior infraestrutura tecnológica e disponibilidade de profissionais capacitados para integrar a IA aos serviços de saúde. Em países de baixa e média renda, o uso dessas ferramentas ainda foi reduzido, devido às limitações de recursos, infraestrutura e políticas públicas voltadas à inovação no setor da saúde. Isso evidencia a necessidade de novas investigações que considerem o impacto dessas desigualdades e busquem estratégias para ampliar o acesso equitativo ao cuidado em saúde mental mediado pela IA.

Diante desse cenário, torna-se essencial que futuras pesquisas explorem maneiras de integrar a IA aos serviços de saúde mental de forma ética, segura e humanizada. Além disso, é fundamental que os profissionais da área sejam capacitados para utilizar essas tecnologias, de maneira complementar ao cuidado tradicional, garantindo que a IA atue como ferramenta de suporte e não como substituto da relação terapêutica entre profissional e paciente.

Este estudo reforça, portanto, a necessidade de olhar crítico e reflexivo sobre o uso da IA na saúde mental, considerando tanto as contribuições quanto os desafios e as limitações. Espera-se que os resultados aqui apresentados contribuam para o aprimoramento das discussões sobre o tema e incentivem o desenvolvimento de estratégias que tornem o uso da IA mais acessível, eficiente e centrado no bem-estar dos pacientes. O avanço tecnológico deve caminhar lado a lado com a ética e a humanização do cuidado, garantindo que a inovação beneficie, de maneira equitativa, a todos aqueles que necessitam de suporte em saúde mental.

REFERÊNCIAS

- ABDULLAH, M.; NEGIED, N. Detection and Prediction of Future Mental Disorder From Social Media Data Using Machine Learning, Ensemble Learning, and Large Language Models. **IEEE Access**, v. 12, p. 120553-120569, 2024. DOI: <https://doi.org/10.1109/ACCESS.2024.3406469>. Disponível em: <https://ieeexplore.ieee.org/document/10540133>. Acesso em: 21 nov. 2024.
- ALANEZI, F. Assessing the Effectiveness of ChatGPT in Delivering Mental Health Support: A Qualitative Study. **Journal of multidisciplinary healthcare**, v. 17, p. 461–471, 2024. DOI: <https://doi.org/10.2147/JMDH.S447368>. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10838501/>. Acesso em: 20 nov. 2024.
- ALCALÁ-ALBERT, G. J.; PARRA-GONZÁLEZ, M. E. Bibliometric Analysis of Scientific Production on Nursing Research in the Web of Science. **Education Sciences**, n. 11; n. 9, p. 455. DOI: <https://doi.org/10.3390/educsci11090455>. Disponível em: <https://www.mdpi.com/2227-7102/11/9/455>. Acesso em: 31 jan. 2024.
- ALI, S. et al. Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence. **Information Fusion**, v. 99, p. 101805, 2023. DOI: <https://doi.org/10.1016/j.inffus.2023.101805>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1566253523001148>. Acesso em: 06 fev. 2025.
- ALMEIDA, M. S. C. et al. International Classification of Diseases – 11th revision: from design to implementation. **Revista de Saúde Pública**, v. 54, p. 1-5, 2020. <https://doi.org/10.11606/s1518-8787.2020054002120>. Disponível em: <https://doi.org/10.11606/s1518-8787.2020054002120>. Acesso em: 21 abr. 2024.
- AMERICAN PSYCHIATRIC ASSOCIATION (APA). **Diagnostic and statistical manual of mental disorders**. 5th ed. Arlington, VA: APA, 2013.
- AN, W. et al. Fire-Flyer AI-HPC: A cost-effective software-hardware co-design for deep learning. In: SC24: International conference for high performance computing, networking, storage and analysis, 2024, Atlanta, GA, USA. Anais [...]. [S. l.: s. n.], 2024. p. 1-23. DOI: <https://doi.org/10.1109/SC41406.2024.00089>. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10793193>. Acesso em: 03 fev. 2025.
- ARIF, M. et al. Mental Illness Classification on Social Media Texts Using Deep Learning and Transfer Learning. **Computación y Sistemas**, v. 28, n. 2, p. 451-464, 2024. DOI: <https://doi.org/10.13053/cys-28-2-4873>. Disponível em: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-55462024000200451&lng=es&nrm=iso. Acesso em: 21 nov. 2024.
- ARKSEY, H.; O'MALLEY, L. Scoping studies: towards a methodological framework. **International Journal of Social Research Methodology**, v. 8, p. 19-32, 2005. DOI: <https://doi.org/10.1080/1364557032000119616>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/1364557032000119616>. Acesso em: 20 fev. 2024.
- AROMATARIS, E.; MUNN, Z. (ed.). **JBIManual for Evidence Synthesis**. USA: JBI, 2020.

AYODELE, A.; ADETUNLA, A.; AKINLABI, E. Prediction of Depression Severity and Personalised Risk Factors Using Machine Learning on Multimodal Data. **International Journal of Online and Biomedical Engineering (iJOE)**, v. 20, n. 09, p. 130–143, 2024. DOI: <https://doi.org/10.3991/ijoe.v20i09.47581>. Disponível em: <https://online-journals.org/index.php/i-joe/article/view/47581>. Acesso em: 20 nov. 2024.

BAEK, J-W; CHUNG, K. Context deep neural network model for predicting depression risk using multiple regression. **IEEE Access**, v. 8, p. 18171-18181, 2020. DOI: <https://doi.org/10.1109/ACCESS.2020.2968393>. Disponível em: <https://ieeexplore.ieee.org/document/8964291>. Acesso em: 22 nov. 2024.

BANERJEE, S. et al. Mental Health Applications of Generative AI and Large Language Modeling in the United States. **International journal of environmental research and public health**, v. 21, n. 7, p. 910, 2024. DOI: <https://doi.org/10.3390/ijerph21070910>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/39063487/>. Acesso em: 20 nov. 2024.

BANSAL, M.; GOYAL, A.; CHOUDHARY, A. A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. **Decision Analytics Journal**, v. 3, p. 100071, 2022. DOI: <https://doi.org/10.1016/j.dajour.2022.100071>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772662222000261>. Acesso em: 08 fev. 2025.

BAQIR, A. et al. Identifying COVID-19 survivors living with post-traumatic stress disorder through machine learning on Twitter. **Scientific reports**, v. 14, n. 1, p. 18902, 2024. DOI: <https://doi.org/10.1038/s41598-024-69687-8>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/39143145/>. Acesso em: 20 nov. 2024.

BENDER, J. D. et al. Evolution of the availability of Information and Communication Technologies in primary health care in Brazil, 2012 to 2018. **Revista Brasileira de Epidemiologia** [online]. v. 27, e240021. DOI: <https://doi.org/10.1590/1980-549720240021>. Disponível em: <https://www.scielo.org/article/rbepid/2024.v27/e240021/pt/#>. Acesso em: 12 jun. 2024.

BERREZUETA-GUZMAN, S. et al. Future of ADHD Care: Evaluating the Efficacy of ChatGPT in Therapy Enhancement. **Healthcare (Basel, Switzerland)**, v. 12, n. 6, p. 683. DOI: <https://doi.org/10.3390/healthcare12060683>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38540647/>. Acesso em: 20 nov. 2024.

BOTELHO, R. G.; OLIVEIRA, C. C. Literaturas branca e cinzenta: uma revisão conceitual. **Revista Ciência da Informação**, v. 44, n. 3, p. 501-513, 2015. DOI: <https://doi.org/10.18225/ci.inf.v44i3.1804>. Disponível em: <https://revista.ibict.br/ciinf/article/view/1804>. Acesso em: 03 jun. 2024.

BRASIL. Lei nº 10.216, de 6 de abril de 2001. Dispõe sobre a proteção e os direitos das pessoas portadoras de transtornos mentais e redireciona o modelo assistencial em saúde mental. **Diário Oficial da União**, Brasília, DF, 9 abr. 2001. Seção 1, p. 3.

BRASIL. Ministério da Saúde. **Cadernos de Atenção Básica, n. 34 - Saúde mental**. Brasília: Ministério da Saúde, 2013. 176 p.

BRASIL. Ministério da Saúde. **Saúde mental no SUS: Os Centros de Atenção Psicossocial**. Brasília - DF; 2004.

BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde e Ambiente. Departamento de Análise Epidemiológica e Vigilância de Doenças não Transmissíveis. Coordenação-Geral de Informações e Análises Epidemiológicas. **Nota Técnica nº 91/2024-CGIAE/DAENT/SVSA/MS**. Brasília, DF: Ministério da Saúde, 2024.

BYEON H. Exploring Factors for Predicting Anxiety Disorders of the Elderly Living Alone in South Korea Using Interpretable Machine Learning: A Population-Based Study. **International journal of environmental research and public health**, v. 18, n. 14, p. 7625, 2021. DOI: <https://doi.org/10.3390/ijerph18147625>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34300076/>. Acesso em: 24 nov. 2024.

CANSEL, N. et al. A new artificial intelligence-based clinical decision support system for diagnosis of major psychiatric diseases based on voice analysis. **Psychiatry Danubina**, v. 35, n. 4, p. 489–499, 2023. DOI: <https://doi.org/10.24869/psyd.2023.489>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37992093/>. Acesso em: 21 nov. 2024.

CASTONGUAY, A. et al. AI maturity in health care: An overview of 10 OECD countries. **Health Policy**, v. 140, p. 10493, 2024. DOI: <https://doi.org/10.1016/j.healthpol.2023.104938>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168851023002233>. Acesso em: 27 jun. 2024.

CASTRO, A. A. et al. Teleconsulta no Contexto da Covid-19: Experiência de uma Equipe em Cuidados Paliativos. **Revista Brasileira de Educação Médica**, v. 44, p. e138, 2020. DOI: <https://doi.org/10.1590/1981-5271v44.supl.1-20200368>. Disponível em: <https://www.scielo.br/j/rbem/a/sDmjgkLJMynfjVfVWVWrpY5q/#>. Acesso em: 22 abr. 2024.

CAULLEY, D. et al. Objectively Quantifying Pediatric Psychiatric Severity Using Artificial Intelligence, Voice Recognition Technology, and Universal Emotions: Pilot Study for Artificial Intelligence-Enabled Innovation to Address Youth Mental Health Crisis. **JMIR research protocols**, v. 12, p. e51912, 2023. DOI: <https://doi.org/10.2196/51912>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37870890/>. Acesso em: 20 nov. 2024.

CENTRO DE VALORIZAÇÃO DA VIDA (CVV). Disponível em: <https://www.cvv.org.br/>. Acesso em: 22 abr. 2024.

CHADAGA, K. et al. SADXAI: Predicting social anxiety disorder using multiple interpretable artificial intelligence techniques. **SLAS technology**, v. 29, n. 2, p. 100129, 2024. DOI: <https://doi.org/10.1016/j.slast.2024.100129>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38508237/>. Acesso em: 23 nov. 2024.

CHANDRA, R.; KRISHNA, A. COVID-19 sentiment analysis via deep learning during the rise of novel cases. **PloS One**, v. 16, n. 8, p. e0255615, 2021. DOI: <https://doi.org/10.1371/journal.pone.0255615>. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0255615>. Acesso em: 06 fev. 2025.

CHANG, C. L. et al. AI-Led Mental Health Support (Wysa) for Health Care Workers During COVID-19: Service Evaluation. **JMIR formative research**, v. 8, p. e51858, 2024. DOI: <https://doi.org/10.2196/51858>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38640476/>. Acesso em: 20 nov. 2024.

CHANG, Y. W. et al. Development of an AI-Based Web Diagnostic System for Phenotyping Psychiatric Disorders. **Frontiers in psychiatry**, v. 11, p. 542394, 2020. DOI:

<https://doi.org/10.3389/fpsy.2020.542394>. Disponível em:
<https://pubmed.ncbi.nlm.nih.gov/33250789/>. Acesso em: 24 nov. 2024.

CHEN, T. et al. Diagnosing attention-deficit hyperactivity disorder (ADHD) using artificial intelligence: a clinical study in the UK. **Frontiers in psychiatry**, v. 14, p. 1164433, 2023. DOI: <https://doi.org/10.3389/fpsy.2023.1164433>. Disponível em:
<https://pubmed.ncbi.nlm.nih.gov/37363182/>. Acesso em: 20 nov. 2024.

CHOWDHURY, N. A.; WEI, L.; MIN, Z. Redefining Scalability in AI: The Innovations Behind DeepSeek-V3's MoE and Multi-Token Prediction. **International Journal of Scientific and Research Publications**, v. 1, n. 5, p. 1-3. DOI:
<http://dx.doi.org/10.29322/IJSRP.X.X.2024.pXXXX>. Disponível em:
<http://dx.doi.org/10.29322/IJSRP.X.X.2024.pXXXX>. Acesso em: 05 fev. 2025.

CORDEIRO, L.; SOARES, C. B. Revisão de escopo: potencialidades para a síntese de metodologias utilizadas em pesquisa primária. **BIS - Boletim do Instituto de Saúde**, v. 20, n. 2, p. 37-43, 2019. DOI: <https://doi.org/10.52753/bis.2019.v20.34471>. Disponível em:
<https://periodicos.saude.sp.gov.br/bis/article/view/34471>. Acesso em: 07 abr. 2024.

CORREIA, A. R. L.; TEIXEIRA, M. J.; NASCIMENTO, N. A. O cuidado em saúde como base da liderança em enfermagem: desafios e perspectivas. **Revista Multidisciplinar do Nordeste Mineiro**, v. 6, n. 1, 2023. Disponível em:
<https://revista.unipacto.com.br/index.php/multidisciplinar/article/view/1075>. Acesso em: 27 maio. 2024.

CORREIA, K. C. R. et al. Saúde Mental na Universidade: Atendimento Psicológico Online na Pandemia da Covid-19. **Psicologia: Ciência e Profissão**, v. 43, p. e245664, 2023. DOI: <https://doi.org/10.1590/1982-3703003245664>. Disponível em:
<https://www.scielo.br/j/pcp/a/NSMwVQRhDhbqnpMZ9LzqTyD/?lang=pt#>. Acesso em: 24 mai. 2024.

CORREIA, K. C. R. et al. Saúde Mental na Universidade: Atendimento Psicológico Online na Pandemia da Covid-19. **Psicologia: Ciência e Profissão**, v. 43, p. e245664, 2023. DOI: <https://doi.org/10.1590/1982-3703003245664>. Disponível em:
https://www.scielo.br/j/pcp/a/NSMwVQRhDhbqnpMZ9LzqTyD/?utm_source=chatgpt.com. Acesso em: 08 fev. 2025.

ĆOSIĆ, K. et al. Artificial intelligence in prediction of mental health disorders induced by the COVID-19 pandemic among health care workers. *Croatian medical journal*, v. 61, n. 3, p. 279–288, 2020. DOI: <https://doi.org/10.3325/cmj.2020.61.279>. Disponível em:
<https://pubmed.ncbi.nlm.nih.gov/32643346/>. Acesso em: 25 nov. 2024.

COSTA, J. B. C. et al. Aconchego: Construção e validação de aplicativo para apoio à saúde mental. **DOXA: Revista Brasileira de Psicologia e Educação**, v. 24, p. e023027, 2023. DOI: <https://doi.org/10.30715/doxa.v24i00.17989>. Disponível em:
<https://periodicos.fclar.unesp.br/doxa/article/view/17989>. Acesso em: 24 mai. 2024.

COUTO, M. et al. Idosos e saúde mental: o impacto social. **RIAGE - Revista Ibero-Americana de Gerontologia**, v. 5, p. 2013-223, 2024. DOI: <https://doi.org/10.61415/riage.238>. Disponível em:
<https://riagejournal.com/index.php/riage/article/view/238>. Acesso em: 24 jun. 2024.

CROSS, S. et al. Use of AI in Mental Health Care: Community and Mental Health Professionals Survey. **Journal of Medical Internet Research Mental Health**, v. 11, p. e60589, 2024. DOI: <https://doi.org/10.2196/60589>. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11488652/>. Acesso em: 07 fev. 2025.

DA COSTA, J. K. J. et al. Desigualdades sociais e o acesso à tecnologia de IA: um estudo sociocultural. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 10, n. 11, p. 7446–7463, 2024. DOI: <https://doi.org/10.51891/rease.v10i11.16814>. Disponível em: <https://periodicorease.pro.br/rease/article/view/16814>. Acesso em: 05 fev. 2025.

DA SILVA, D. M. History and Legacy of Alan Turing for Computer Science. **International Journal of Scientific Research and Management (IJSRM)**, v. 12, n. 2, p. 1047-1056. DOI: <http://dx.doi.org/10.18535/ijorm/v12i02.ec06>. Disponível em: <https://ijorm.net/index.php/ijorm/article/view/5059>. Acesso em: 27 jun. 2024.

DANIELI, M. et al. Assessing the Impact of Conversational Artificial Intelligence in the Treatment of Stress and Anxiety in Aging Adults: Randomized Controlled Trial. **JMIR mental health**, v. 9, n. 9, p. e38067, 2022. DOI: <https://doi.org/10.2196/38067>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/36149730/>. Acesso em: 22 nov. 2024.

DE LACY, N. et al. Predicting individual cases of major adolescent psychiatric conditions with artificial intelligence. **Translational psychiatry**, v. 13, n. 1, p. 314, 2023. DOI: <https://doi.org/10.1038/s41398-023-02599-9>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37816706/>. Acesso em: 20 nov. 2024.

DE MELO, R. F. Um estudo sobre aprendizado de máquina multimodal para identificar a depressão em adolescentes brasileiros usando dados coletados via smartphones. 2023. 179f. Tese (Doutor em Ciências da Computação) - Programa de Pós-Graduação em Computação, Universidade Federal de Pelotas, Pelotas, 2023.

DE OLIVEIRA, E. B. et al. Common mental disorders in nursing students of the professionalizing cycle. **Revista Brasileira de Enfermagem**, v. 73, n. 1, p. e20180154, 2020. DOI: <https://doi.org/10.1590/0034-7167-2018-0154>. Disponível em: <https://www.scielo.br/j/reben/a/5TscDmMPSdzZ4yGGrz4Qy3N/?lang=pt#>. Acesso em: 20 jun. 2024.

DE ROSSI, A. F. et al. A tessitura da construção coletiva de indicadores de saúde mental em Centros de Atenção Psicossocial. **Saúde em Debate**, v. 47, n. 137, p. 333–345, abr. 2023. DOI: <https://doi.org/10.1590/0103-1104202313723>. Disponível em: <https://www.scielo.br/j/sdeb/a/Y9L6WkC7SWMxX69pDJMtSxb/#>. Acesso em: 22 abr. 2024.

DE SALLES NETO, L. L. et al. Forecast UTI: aplicativo para previsão de leitos de unidades de terapia intensiva no contexto da pandemia de COVID-19. **Epidemiologia e Serviços de Saúde**, v. 29, n. 4, p. e2020391, 2020. DOI: <https://doi.org/10.1590/s1679-49742020000400023>. Disponível em: <https://www.scielo.br/j/ress/a/wXWGfh955NzD5RtBXLwkycp/?lang=en#>. Acesso em: 12 jun. 2024.

DELGADO, S. (2023). Inteligência artificial aplicada no mapeamento de sintomas e tratamento de depressão, ansiedade e estresse. Dissertação (Mestrado em Informática) – Programa de Pós-Graduação em Informática e Gestão do Conhecimento, Universidade Nove de Julho, São Paulo, 2023.

- DERGAA, I. et al. ChatGPT is not ready yet for use in providing mental health assessment and interventions. **Frontiers in psychiatry**, v. 14, p. 1277756, 2024. DOI: <https://doi.org/10.3389/fpsy.2023.1277756>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38239905/>. Acesso em: 24 nov. 2024.
- DESAI, S. et al. Identification of Suicidal Ideation in the Canadian Community Health Survey-Mental Health Component Using Deep Learning. **Frontiers in artificial intelligence**, v. 4, p. 561528, 2021. <https://doi.org/10.3389/frai.2021.561528>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34250463/>. Acesso em: 25 nov. 2024.
- DHARIWAL, N. et al. A pilot study on AI-driven approaches for classification of mental health disorders. **Frontiers in human neuroscience**, v. 18, p. 1376338, 2024. DOI: <https://doi.org/10.3389/fnhum.2024.1376338>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38660009/>. Acesso em: 20 nov. 2024.
- DO PINHO, J. C. G. Tecnologia digital baseada em técnicas de inteligência artificial para identificar fatores de risco e proteção da depressão em acadêmicos. 2023.108F. Dissertação (Mestrado em Psicologia) - Programa de Pós-Graduação Mestrado Profissional em Psicologia, Universidade do Vale do Itajaí, Itajaí, 2023.
- DOKI, S. et al. Comparison of predicted psychological distress among workers between artificial intelligence and psychiatrists: a cross-sectional study in Tsukuba Science City, Japan. **BMJ open**, v. 11, n. 6, p. e046265, 2021. DOI: <https://doi.org/10.1136/bmjopen-2020-046265>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34162646/>. Acesso em: 22 nov. 2024.
- DOURADO JÚNIOR, F. W. et al. Tecnologias da Informação e Comunicação no cuidado de enfermagem pós-moderno: perspectivas filosóficas. **Revista Enfermagem Atual In Derme**, v. 97, n. (ed. esp), p. e023036, 2023. DOI: [https://doi.org/10.31011/reaid-2023-v.97-n.\(esp\)-art.1654](https://doi.org/10.31011/reaid-2023-v.97-n.(esp)-art.1654). Disponível em: <https://revistaenfermagematual.com/index.php/revista/article/view/1654>. Acesso em: 12 jun. 2024.
- DOURADO JÚNIOR, F. W. et al. Teoria da Intervenção Prática da Enfermagem em Saúde Coletiva: aplicação em um grupo de idosos. **Revista Brasileira de Pesquisa em Saúde**, v. 24, n. 1, p. 48–58, 2022. DOI: <https://doi.org/10.47456/rbps.v24i1.36540>. Disponível em: <https://periodicos.ufes.br/rbps/article/view/36540>. Acesso em: 21 abr. 2024.
- DUONG, C. D. et al. Compulsive ChatGPT usage, anxiety, burnout, and sleep disturbance: A serial mediation model based on stimulus-organism-response perspective. **Acta Psychologica**, v. 251, p. 104622, 2024. DOI: <https://doi.org/10.1016/j.actpsy.2024.104622>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0001691824005006>. Acesso em: 03 fev. 2025.
- EGAN, S. J. et al. A pilot study of the perceptions and acceptability of guidance using artificial intelligence in internet cognitive behaviour therapy for perfectionism in young people. **Internet interventions**, v. 35, p. 100711, 2024. DOI: <https://doi.org/10.1016/j.invent.2024.100711>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38313140/>. Acesso em: 23 nov. 2024.
- ELYOSEPH, Z. et al. Capacity of Generative AI to Interpret Human Emotions From Visual and Textual Data: Pilot Evaluation Study. **JMIR mental health**, v. 11, p. e54369, 2024. DOI:

<https://doi.org/10.2196/54369>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38319707/>. Acesso em: 23 nov. 2024.

ELYOSEPH, Z.; LEVKOVICH, I. Comparing the Perspectives of Generative AI, Mental Health Experts, and the General Public on Schizophrenia Recovery: Case Vignette Study. **JMIR mental health**, v. 11, p. e53043, 2024. DOI: <https://doi.org/10.2196/53043>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38533615/>. Acesso em: 20 nov. 2024.

FERNANDES, F. T.; CHIAVEGATTO FILHO, A. D. P. Perspectivas do uso de mineração de dados e aprendizado de máquina em saúde e segurança no trabalho. **Revista Brasileira de Saúde Ocupacional**, v. 44, p. e13, 2019. DOI: <https://doi.org/10.1590/2317-6369000019418>. Disponível em: <https://www.scielo.br/j/rbso/a/NgxW5qxzQWhcD4KrTHLxxGG/#>. Acesso em: 22 abr. 2024.

FULMER, R. et al. Using Psychological Artificial Intelligence (Tess) to Relieve Symptoms of Depression and Anxiety: Randomized Controlled Trial. **JMIR mental health**, v. 5, n. 4, p. e64, 2018. DOI: <https://doi.org/10.2196/mental.9782>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30545815/>. Acesso em: 23 nov. 2024.

GAO, J. et al. Mental health problems and social media exposure during COVID-19 outbreak. **Plos One**, v. 15, n. 4, p. e0231924. DOI: <https://doi.org/10.1371/journal.pone.0231924>. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0231924>. Acesso em: 07 fev. 2025.

GARCÍA-VALDEZ, A. A. et al. Identifying PTSD sex-based patterns through explainable artificial intelligence in biometric data. **Netw Model Anal Health Inform Bioinforma**, n. 13, p. 49, 2024. DOI: <https://doi.org/10.1007/s13721-024-00485-y>. Disponível em: <https://link.springer.com/article/10.1007/s13721-024-00485-y#citeas>. Acesso em: 20 nov. 2024.

GIORGI, S. et al. Evaluating generative AI responses to real-world drug-related questions. **Psychiatry Research**, v. 39, p. 116058, 2024. DOI: <https://doi.org/10.1016/j.psychres.2024.116058>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0165178124003433>. Acesso em: 20 nov. 2024.

GOLDBERG, D. P.; HUXLEY, P. **Common mental disorders: A bio-social model**. Abingdon: Tavistock/Routledge, 1992.

GOLDBERG, S. B. et al. Machine learning and natural language processing in psychotherapy research: Alliance as example use case. **Journal of counseling psychology**, v. 67, n. 4, p. 438–448, 2020. DOI: <https://doi.org/10.1037/cou0000382>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32614225/>. Acesso em: 25 nov. 2024.

GOMES, C. F. M. *et al.* Common mental disorders in university students: epidemiological approach about vulnerabilities. **SMAD - Revista Eletrônica Saúde Mental Álcool e Drogas**, v. 16, n. 1, p. 1-8, 2020. DOI: <https://doi.org/10.11606/issn.1806-6976.smad.2020.157317>. Disponível em: http://pepsic.bvsalud.org/scielo.php?pid=S1806-69762020000100009&script=sci_abstract&tlng=en. Acesso em: 13 jun. 2024.

GRADUS, J. L. et al. Predicting Sex-Specific Nonfatal Suicide Attempt Risk Using Machine Learning and Data From Danish National Registries. **American journal of epidemiology**, v.

190, n. 12, p. 2517–2527, 2021. DOI: <https://doi.org/10.1093/aje/kwab112>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/33877265/>. Acesso em: 20 nov. 2024.

HADAR-SHOVAL, D. et al. Assessing the Alignment of Large Language Models With Human Values for Mental Health Integration: Cross-Sectional Study Using Schwartz's Theory of Basic Values. **JMIR mental health**, v. 11, p. e55988, 2024. DOI: <https://doi.org/10.2196/55988>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38593424/>. Acesso em: 25 nov. 2024.

HE, Y. et al. Mental Health Chatbot for Young Adults With Depressive Symptoms During the COVID-19 Pandemic: Single-Blind, Three-Arm Randomized Controlled Trial. **Journal of Medical Internet Research**, v. 24, n. 11, p. e40719. DOI: <https://doi.org/10.2196/40719>. Disponível em: <https://www.jmir.org/2022/11/e40719/>. Acesso em: 03 fev. 2025.

HEBB, D. O. **The Organization of Behavior: A Neuropsychological Theory**. 1. ed. New York: Psychology Press, 2022.

HEIN, K. et al. Examining how gamers connect with their avatars to assess their anxiety: A novel artificial intelligence approach. **Acta psychologica**, v. 246, p. 104298, 2024. DOI: <https://doi.org/10.1016/j.actpsy.2024.104298>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38701623/>. Acesso em: 20 nov. 2024.

HEINZ, M. V. et al. Testing domain knowledge and risk of bias of a large-scale general artificial intelligence model in mental health. **Digital health**, v. 9, p. 20552076231170499, 2023. DOI: <https://doi.org/10.1177/20552076231170499>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37101589/>. Acesso em: 21 nov. 2024.

HELOU, R. I., et al. Use of a smartphone app to inform healthcare workers of hospital policy during a pandemic such as COVID-19: A mixed methods observational study. **PloS One**, v. 17, n. 1, p. e0262105, 2022. DOI: <https://doi.org/10.1371/journal.pone.0262105>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8730417/>. Acesso em: 24 maio. 2024.

HOFMANN, A. B. et al. Sociodemographic Variables in Offender and Non-Offender Patients Diagnosed with Schizophrenia Spectrum Disorders-An Explorative Analysis Using Machine Learning. **Healthcare (Basel, Switzerland)**, v. 12, n. 17, p. 1699. DOI: <https://doi.org/10.3390/healthcare12171699>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/39273723/>. Acesso em: 20 nov. 2024.

HOHENSTEIN, J. et al. Artificial intelligence in communication impacts language and social relationships. **Scientific reports**, n. 13, v. 1, p. 5487, 2023. DOI: <https://doi.org/10.1038/s41598-023-30938-9>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37015964/>. Acesso em: 30 jan. 2025.

JAIN, G. et al. Revealing the source: How awareness alters perceptions of AI and human-generated mental health responses. **Internet interventions**, v. 36, p. 100745, 2024. DOI: <https://doi.org/10.1016/j.invent.2024.100745>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38746873/>. Acesso em: 20 nov. 2024.

JIN, K. et al. Artificial intelligence in mental healthcare: an overview and future perspectives. **The British Journal of Radiology**, v. 96, n. 1150, p. 20230213, 2023. DOI: <https://doi.org/10.1259/bjr.20230213>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/pmc/articles/PMC10546438/>. Acesso em: 03 fev. 2025.

JOERIN, A.; RAUWS, M.; ACKERMAN, M. L. Psychological Artificial Intelligence Service, Tess: Delivering On-demand Support to Patients and Their Caregivers: Technical Report. *Cureus*, v. 11, n. 1, p. e3972, 2019. <https://doi.org/10.7759/cureus.3972>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30956924/>. Acesso em: 23 nov. 2024.

JORDAN, Z.; DONNELLY, P.; PITTMAN, E. **A short history of a big idea**. Melbourne: The Joanna Briggs Institute, 2006.

KERZ, E. et al. Toward explainable AI (XAI) for mental health detection based on language behavior. *Frontiers in psychiatry*, v. 14, n. 1219479, 2023. DOI: <https://doi.org/10.3389/fpsyt.2023.1219479>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38144474/>. Acesso em: 21 nov. 2024.

KHALIL, H. et al. The role of scoping reviews in reducing research waste, *Journal of Clinical Epidemiology*, v. 152, p. 30-35, 2022. DOI: <https://doi.org/10.1016/j.jclinepi.2022.09.012>. Disponível em: [https://www.jclinepi.com/article/S0895-4356\(22\)00233-5/abstract](https://www.jclinepi.com/article/S0895-4356(22)00233-5/abstract). Acesso em: 15 fev. 2024.

KHAN, M. A. Compressive Strength of Fly-Ash-Based Geopolymer Concrete by Gene Expression Programming and Random Forest. *Advances in Civil Engineering*, v. 2021, p. 1-17, 2021. DOI: <https://doi.org/10.1155/2021/6618407>. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1155/2021/6618407>. Acesso em: 08 fev. 2025.

KHARRAT, F. G. Z. et al. Explainable artificial intelligence models for predicting risk of suicide using health administrative data in Quebec. *PloS one*, v. 19, n. 4, p. e0301117, 2024. DOI: <https://doi.org/10.1371/journal.pone.0301117>, Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38568987/>. Acesso em: 20 nov. 2024.

KHOO, L. S. et al. Machine Learning for Multimodal Mental Health Detection: A Systematic Review of Passive Sensing Approaches. *Sensors (Basel, Switzerland)*, v. 24, n. 2, p. 348. DOI: <https://doi.org/10.3390/s24020348>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38257440/>. Acesso em: 30 já. 2025.

KIM, J. et al. A deep learning model for detecting mental illness from user content on social media. *Scientific reports*, v. 10, n. 1, p. 11846, 2023. DOI: <https://doi.org/10.1038/s41598-020-68764-y>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32678250/>. Acesso em: 20 nov. 2024.

KRASUSKA, M. et al. Technological capabilities to assess digital excellence in hospitals in high performing health care systems: international eDelphi exercise. *Journal of Medical Internet Research*, v. 22, n. 8, p. e17022, 2020. DOI: <https://doi.org/10.2196/17022>. Disponível em: <https://www.jmir.org/2020/8/e17022>. Acesso em: 24 maio. 2024.

KUNDU, A. et al. Correlates of wanting to seek help for mental health and substance use concerns by sexual and gender minority young adults during the COVID-19 pandemic: A machine learning analysis. *PloS one*, v. 17, n. 11, p. e0277438, 2022. DOI: <https://doi.org/10.1371/journal.pone.0277438>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/36383536/>. Acesso em: 20 nov. 2024.

LEANDRO, B. B. da S. Cidades inteligentes, desigualdades territoriais e saúde pública: reflexões necessárias. *Asklepion: Informação em Saúde*, v. 1, n. 2, p. 1–16, 2021. DOI: <https://doi.org/10.21728/asklepion.2021v1n2.p1-16>. Disponível em: <https://asklepionrevista.info/asklepion/article/view/25>. Acesso em: 05 fev. 2025.

- LEE, C. et al. Large Language Models Versus Expert Clinicians in Crisis Prediction Among Telemental Health Patients: Comparative Study. **JMIR mental health**, v. 11, p. e58129, 2024. DOI: <https://doi.org/10.2196/58129>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38876484/>. Acesso em: 21 nov. 2024.
- LEE, K.; YI, J.; LEE, S-H. Effects of community-based fall prevention interventions for older adults using information and communication technology: A systematic review and meta-analysis. **Health Informatics Journal**, v. 30, n. 2, p. 24-100, 2024. DOI: <https://doi.org/10.1177/14604582241259324>. Disponível em: <https://journals.sagepub.com/doi/10.1177/14604582241259324>. Acesso em: 10 jun. 2024.
- LEIVA-PEÑA, V.; RUBÍ-GONZÁLEZ, P.; VICENTE-PARADA, B. Determinantes sociais da saúde mental: políticas públicas a partir do modelo biopsicossocial em países latino-americanos. **Revista Panamericana de Salud Publica**, v. 45, e158, 2021. DOI: <https://doi.org/10.26633/RPSP.2021.158>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8678097/>. Acesso em: 21 abr. 2024.
- LEVAC, D.; COLQUHOUN, H.; O'BRIEN, K. K. Scoping studies: advancing the methodology. **Implementation Science**, v. 5, n. 1, p. 5-69, 2010. DOI: <https://doi.org/10.1186/1748-5908-5-69>. Disponível em: <https://doi.org/10.1186/1748-5908-5-69>. Acesso em: 20 fev. 2024.
- LIANG, L. et al. Exploration and Strategy Analysis of Mental Health Education for Students in Sports Majors in the Era of Artificial Intelligence. **Frontiers in psychology**, v. 12, p. 762725, 2022. DOI: <https://doi.org/10.3389/fpsyg.2021.762725>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/35308079/>. Acesso em: 25 nov. 2024.
- LUDERMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35, n. 101, p. 85-94, jan. 2021. DOI: <https://doi.org/10.1590/s0103-4014.2021.35101.007>. Disponível em: <https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd/?lang=pt&format=html#>. Acesso em: 22 abr. 2024.
- MACIEL, L. ChatGPT and the ethical aspects of artificial intelligence. **Revista de Gestão**, v. 30, n. 2, p. 110-112, 2023. DOI: <https://doi.org/10.1108/REGE-04-2023-207>. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/REGE-04-2023-207/full/html>. Acesso em: 27 jun. 2024.
- MAJEED, A.; HWANG, S. O. Data-Driven Analytics Leveraging Artificial Intelligence in the Era of COVID-19: An Insightful Review of Recent Developments. **Symmetry**, v. 14, n. 1, p. 16. DOI: <https://doi.org/10.3390/sym14010016>. Disponível em: <https://www.mdpi.com/2073-8994/14/1/16>. Acesso em: 03 fev. 2024.
- MARGETTS, H.; DUNLEAVY, P. The political economy of digital government: How Silicon Valley firms drove conversion to data science and artificial intelligence in public management. **Public Money & Management**, v. 1, n. 1, p. 1-11, 2024. DOI: <https://doi.org/10.1080/09540962.2024.2389915>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/09540962.2024.2389915#abstract>. Acesso em: 05 fev. 2025.
- MARR, D.; POGGIO, T. From understanding computation to understanding neural circuitry. **Neurosciences Research Program Bulletin**, v. 14, p. 470-488, 1976.

MARTINS, J. C. M. T. Sistema leves: utilizando o aprendizado de máquina para o monitoramento de transtornos mentais comuns no trabalho. 2022. 148f. Dissertação (Mestrado Profissional em Ciência, Tecnologia e Inovação) - Escola de Ciências e Tecnologia, Universidade Federal do Rio Grande do Norte, Natal, 2022.

MATTOS, B. P.; MATTJIE, C. **Machine Learning na Saúde Mental: um ramo emergente**. In: GONÇALVES, J. (Ed.). *Perspectivas em Psicologia*. Editora Lógica Psicológica, 2024. p. 44-49. Disponível em: <https://doi.org/10.5281/zenodo.10420581>. Acesso em: 07 fev. 2025.

MCGINTY, K. R. et al. Comparing self-reported quality of life in youth with bipolar versus other disorders. **Bipolar Disorders**, v. 25, n. 8, p. 648-660, 2023. DOI: <https://doi.org/10.1111/bdi.13320>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/bdi.13320>. Acesso em: 20 jun. 2024.

MEDRADO, A. C.; LIMA, M. Saúde mental feminina e ciclo reprodutivo: uma revisão de literatura. **Nova Perspectiva Sistêmica**, v. 29, n. 67, p. 70-84, 2020. DOI: <https://doi.org/10.38034/nps.v29i67.560>. Disponível em: <https://www.revistanps.com.br/nps/article/view/560>. Acesso em: 22 abr. 2024.

MEHTA, A. et al. Acceptability and Effectiveness of Artificial Intelligence Therapy for Anxiety and Depression (Youper): Longitudinal Observational Study. **Journal of medical Internet research**, v. 23, n. 6, p. e26771, 2021. DOI: <https://doi.org/10.2196/26771>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34155984/>. Acesso em: 22 nov. 2024.

MEZZA, M.; DE TORRENTÉ, M. de O. N. A Reforma Psiquiátrica Brasileira como luta pelo reconhecimento e progresso moral. **Saúde em Debate**, v. 44, n. spe 3, p. 235-249, 2020. DOI: <https://doi.org/10.1590/0103-11042020E320>. Disponível em: <https://www.scielo.org/article/sdeb/2020.v44nspe3/235-249/#>. Acesso em: 22 abr. 2024.

MILNE-IVES, M. et al. The effectiveness of artificial intelligence conversational agents in health care: systematic review. **Journal of Medical Internet Research**, v. 22, n. 10, e20346. DOI: <https://doi.org/10.2196/20346>. Disponível em: <https://www.jmir.org/2020/10/e20346>. Acesso em: 06 fev. 2025.

MIURA, C. et al. Assisting Personalized Healthcare of Elderly People: Developing a Rule-Based Virtual Caregiver System Using Mobile Chatbot. **Sensors**, v. 22, n. 10, p. 3829. DOI: <https://doi.org/10.3390/s22103829>. Disponível em: <https://www.mdpi.com/1424-8220/22/10/3829>. Acesso em: 06 fev. 2025.

MONTANG, C. et al. On artificial intelligence and global mental health. **Asian Journal of Psychiatry**, v. 91, p. 103855, 2024. DOI: <https://doi.org/10.1016/j.ajp.2023.103855>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1876201823004124?via%3Dihub#fig0010>. Acesso em: 27 jun. 2024.

MOREIRA, P. S. da C.; SALERNO, B. N.; TSUNODA, D. F. Internet das coisas e aprendizado de máquina na área da saúde: uma análise bibliométrica da produção científica de 2009 a 2019. **Revista Eletrônica de Comunicação, Informação & Inovação em Saúde**, v. 14, n. 1, 2020. DOI: <https://doi.org/10.29397/reciis.v14i1.1807>. Disponível em: <https://www.reciiis.iciet.fiocruz.br/index.php/reciis/article/view/1807>. Acesso em: 22 abr. 2024.

MUNN, Z. et al. Systematic review or scoping review? Guidance for authors when choosing between a systematic or scoping review approach. **BMC Medical Research Methodology**, v.18, n. 143, p.1-7, 2018. DOI: <https://doi.org/10.1186/s12874-018-0611-x>. Disponível em: <https://link.springer.com/article/10.1186/s12874-018-0611-x#citeas>. Acesso em: 15 fev. 2024.

MURNEY, M. A. et al. Stigma and discrimination related to mental health and substance use issues in primary health care in Toronto, Canada: a qualitative study. **International Journal of Qualitative Studies on Health and Well-being**, v. 15, n. 1, p. 1744926, 2020. DOI: <https://doi.org/10.1080%2F17482631.2020.1744926>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7170302/>. Acesso em: 21 abr. 2024.

NA, K. S.; CHO, S. E.; CHO, S. J. Machine learning-based discrimination of panic disorder from other anxiety disorders. **Journal of affective disorders**, n. 278, p. 1–4, 2021. DOI: <https://doi.org/10.1016/j.jad.2020.09.027>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32942220/>. Acesso em: 21 nov. 2024.

NASH, C.; NAIR, R.; NAQVI, S. M. Machine Learning in ADHD and Depression Mental Health Diagnosis: A Survey. **IEEE Access**, v. 11, p. 86297-86317, 2023. Disponível em: <https://doi.org/10.1109/ACCESS.2023.3304236>. Disponível em: <https://ieeexplore.ieee.org/document/10214293>. Acesso em: 21 nov. 2024.

NEMESURE, M. D. et al. Predictive modeling of depression and anxiety using electronic health records and a novel machine learning approach with artificial intelligence. **Scientific reports**, v. 11, n. 1, p. 1980, 2021. DOI: <https://doi.org/10.1038/s41598-021-81368-4>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/33479383/>. Acesso em: 22 nov. 2024.

NOWAKOWSKA, K. et al. AI-Enhanced Predictive Modeling for Identifying Depression and Delirium in Cardiovascular Patients Scheduled for Cardiac Surgery. **Diagnostics (Basel, Switzerland)**, v. 14, n. 1, p. 67. DOI: <https://doi.org/10.3390/diagnostics14010067>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38201376/>. Acesso em: 21 nov. 2024.

OH, B. et al. Prediction of Suicidal Ideation among Korean Adults Using Machine Learning: A Cross-Sectional Study. **Psychiatry investigation**, v. 17, n. 4, p. 331–340. DOI: <https://doi.org/10.30773/pi.2019.0270>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32213803/>. Acesso em: 21 nov. 2024.

OJEDA, M. et al Artificial Intelligence Language Models and the Future of Academic Research in Surgery: Exploring Opportunities and Concerns. **Annals of Plastic Surgery**, v. 93, n. 1, p 1-2, 2024. DOI: 10.1097/SAP.0000000000003935. Disponível em: https://journals.lww.com/annalsplasticsurgery/citation/2024/07000/artificial_intelligence_language_models_and_the.1.aspx. Acesso em: 24 jun. 2024.

OLCZAK, J. et al. Presenting artificial intelligence, deep learning, and machine learning studies to clinicians and healthcare stakeholders: an introductory reference with a guideline and a Clinical AI Research (CAIR) checklist proposal. **Acta Orthopaedica**, v. 92, n. 5, p. 513–525, 2021. DOI: <https://doi.org/10.1080/17453674.2021.1918389>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/17453674.2021.1918389>. Acesso em: 27 jun. 2024.

OLIVEIRA DO Ó, D. M. S. et al. Barreiras de acessibilidade à atenção básica em assentamento em Pernambuco, Brasil, sob a ótica de camponesas, profissionais de saúde e gestão. **Cadernos de Saúde Pública**, v. 38, n. 10, p. e00072322, 2022. DOI:

<https://doi.org/10.1590/0102-311XPT072322>. Disponível em:
<https://www.scielo.br/j/csp/a/SGSD9chMg7RCYhrk5V6d4Sq/#>. Acesso em: 22 abr. 2024.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU). **Report of the Secretary-General on SDG progress. Special edition**. Nova Iorque: ONU, 2019. Disponível em:
https://sustainabledevelopment.un.org/content/documents/24978Report_of_the_SG_on_SDG_Progress_2019.pdf.

ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **Depression and other common mental disorders: global health estimates**. Relatório técnico, OMS, 2017.

ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **Ethics and governance of artificial intelligence for health**. Geneva: OMS, 2021. Disponível em:
<https://www.who.int/publications/i/item/9789240029200>. Acesso em: 27 mai. 2024.

ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **Mental health action plan 2013-2020**. Relatório técnico, OMS, 2013.

ORGANIZAÇÃO MUNDIAL DE SAÚDE (OMS). **Depression; c2022**. Relatório técnico, OMS, 2022.

ORGANIZAÇÃO PARA A COOPERAÇÃO E O DESENVOLVIMENTO ECONÔMICO (OCDE). **Recommendation of the Council on Artificial Intelligence**. Paris: OCDE, 2019. Disponível em: <https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449#main>. Acesso em: 24 jun. 2024.

OVIEDO, A. D.; DELGADO, I. A. V.; LICONA, J. F. M.. Habilidades sociales de comunicaci3n en el cuidado humanizado de enfermer3a: Un diagn3stico para una intervenci3n socioeducativa. **Escola Anna Nery**, v. 24, n. 2, p. e20190238, 2020. DOI: <https://doi.org/10.1590/2177-9465-EAN-2019-0238>. Disponível em: <https://www.scielo.br/j/ean/a/pjh385M4RQfKqWbQxrPRmJg#>. Acesso em: 01 out. 2024.

PAGE, M. J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, p. 1-9, 2021. doi: <https://doi.org/10.1136/bmj.n71>. Disponível em: <https://www.bmj.com/content/372/bmj.n71>. Acesso em: 25 jun. 2024.

PALACIOS-ARIZA, M. A. et al. Prediction of patient admission and readmission in adults from a Colombian cohort with bipolar disorder using artificial intelligence. **Frontiers in psychiatry**, v. 14, p. 1266548, 2023. DOI: <https://doi.org/10.3389/fpsy.2023.1266548>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38179255/>. Acesso em: 20 nov. 2024.

PANDA, N. R. et al. A Review on Logistic Regression in Medical Research. **National Journal of Community Medicine**, v. 13, n. 4, p. 265-270, 2022. DOI: <https://10.55489/njcm.134202222>. Disponível em: <https://10.55489/njcm.134202222>. Acesso em: 08 fev. 2025.

PASSOS, I. C.; GALLOIS, C. B. **Psiquiatria Digital**. 1. ed. Porto Alegre: Artmed, 2024.

PETERS, M. D. J. et al. Best practice guidance and reporting items for the development of scoping review protocols. **JBIC Evidence Synthesis**, v. 20, n. 4, p. 953-968, abr. 2022. DOI: <https://doi.org/10.11124/JBIES-21-00242>. Disponível em: https://journals.lww.com/jbisrir/fulltext/2022/04000/Best_practice_guidance_and_reporting_items_for_the.3.aspx. Acesso em 07 abr. 2024.

PETERS, M. D. J. et al. Chapter 11: Scoping Reviews (2020 version). In: AROMATARIS, E.; MUNN, Z. (ed.). **Joanna Briggs Institute Reviewer's Manual**. USA: JBI, 2020.

PIRES, R. R. et al. O cuidado em saúde mental e a participação política de usuários e familiares na ressignificação do estigma sobre os transtornos mentais. **Physis: Revista de Saúde Coletiva**, v. 33, p. e33038, 2023. DOI: <https://doi.org/10.1590/S0103-7331202333038>. Disponível em: <https://www.scielo.br/j/physis/a/MYzrcy8mgPbhP3hDNxgfpmd/#>.

POPESCU, C. et al. Evaluating the Clinical Feasibility of an Artificial Intelligence-Powered, Web-Based Clinical Decision Support System for the Treatment of Depression in Adults: Longitudinal Feasibility Study. **JMIR formative research**, v. 5, n. 10, p. e31862, 2021. DOI: <https://doi.org/10.2196/31862>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34694234/>. Acesso em: 21 nov. 2024.

PORTER, R. J. The biopsychosocial model in mental health. **Australian & New Zealand Journal of Psychiatry**, v. 54, n. 8, p. 773-774, 2020. DOI: <https://doi.org/10.1177/0004867420944464>. Disponível em: <https://journals.sagepub.com/doi/10.1177/0004867420944464>. Acesso em: 21 abr. 2024.

QIAN, K. et al. Automatic Detection of Major Depressive Disorder via a Bag-of-Behaviour-Words Approach, **ACM Digital Library**, v. 1, n. 1, p. 71-75, 2019. DOI: <https://doi.org/10.1145/3364836.3364851>. Disponível em: <https://dl.acm.org/doi/10.1145/3364836.3364851#core-cited-by>. Acesso em: 23 nov. 2024.

REIS, A. B. de M. R. M., et al. Rede universitária de telemedicina no estado de alagoas: um estudo de caso. **Interfaces Científicas - Saúde E Ambiente**, v. 8, n. 3, p. 435-443. DOI: <https://doi.org/10.17564/2316-3798.2021v8n3p435-443>. Disponível em: <https://periodicos.set.edu.br/saude/article/view/10331>. Acesso em: 22 abr. 2024.

REZAPOUR, M.; ELMSHAEUSER, S. K. Artificial intelligence-based analytics for impacts of COVID-19 and online learning on college students' mental health. **PloS one**, v. 17, n. 11, p. e0276767, 2022. DOI: <https://doi.org/10.1371/journal.pone.0276767>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/36399458/>. Acesso em: 22 nov. 2024.

RODRIGUES, C. S. et al. “O que não te desafia, não te transforma”: a liga interdisciplinar em saúde mental e suas ações extensionistas nos meios digitais. **Revista Conexão UEPG**, v. 18, n. 1, p. 01-12, 2022. DOI: <https://doi.org/10.5212/Rev.Conexao.v.18.20579.015>. Disponível em: <https://revistas.uepg.br/index.php/conexao/article/view/20579>. Acesso em: 08 fev. 2025.

ROEHE, M. V. Psicologia, saúde e concepção de homem: um estudo de orientação heideggeriana. **Revista de Psicologia**, v. 11, n. 1, p. 111-124, 2020. DOI: <https://doi.org/10.36517/revpsiufc.11.1.2020.8>. Disponível em: <http://www.periodicos.ufc.br/psicologiaufc/article/view/40853>. Acesso em: 21 abr. 2024.

ROGAN, J.; FIRTH, J.; BUCCI, S. Healthcare Professionals' Views on the Use of Passive Sensing and Machine Learning Approaches in Secondary Mental Healthcare: A Qualitative Study. **Health expectations**, v. 27, n. 6, p. e70116. DOI: <https://doi.org/10.1111/hex.70116>. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11589162/>. Acesso em: 07 fev. 2025.

ROSENBERG, V. Z.; ANTUNES, A. M. DE S. Transferência de tecnologia para vacina contra COVID-19 no Instituto de Tecnologia em Imunobiológicos (Bio-Manguinhos), Fundação Oswaldo Cruz. **Cadernos de Saúde Pública**, v. 40, n. 4, p. e00120023, 2024. DOI:

<https://doi.org/10.1590/0102-311XEN120023>. Disponível em:
<https://www.scielo.br/j/csp/a/DqgphkgtGvnKrpMt7XmqJfR/?lang=en#>. Acesso em: 12 jun. 2024.

SADEH-SHARVIT, S. et al. Effects of an Artificial Intelligence Platform for Behavioral Interventions on Depression and Anxiety Symptoms: Randomized Clinical Trial. **Journal of medical Internet research**, v. 25, p. e46781, 2023. <https://doi.org/10.2196/46781>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37428547/>. Acesso em: 20 nov. 2024.

SALHI, I. et al. Towards developing a pocket therapist: an intelligent adaptive psychological support chatbot against mental health disorders in a pandemic situation. **Indonesian Journal of Electrical Engineering and Computer Science (IJEECS)**, v. 23, n. 2, p. 1200-1211, 2021. DOI: <http://doi.org/10.11591/ijeeecs.v23.i2.pp1200-1211>. Disponível em: <https://ijeeecs.iaescore.com/index.php/IJEECS/article/view/25060>. Acesso em: 25 nov. 2024.

SCHILLINGS, C. et al. Effects of a Chatbot-Based Intervention on Stress and Health-Related Parameters in a Stressed Sample: Randomized Controlled Trial, **JMIR Ment Health**, v. 11, p. e50454, 2024. DOI: <https://doi.org/10.2196/50454>. Disponível em: <https://mental.jmir.org/2024/1/e50454>. Acesso em: 21 nov. 2024.

SECCHI, Á.; SCORTEGAGNA, S. A.; KANTORSKI, L. P. Balint groups using the “coletivos em saúde mental” m-health app during covid-19. **Texto & Contexto - Enfermagem**, v. 32, p. e20220262, 2023. DOI: <https://doi.org/10.1590/1980-265X-TCE-2022-0262pt>. Disponível em: <https://www.scielo.br/j/tce/a/zYcrrjy5m456hN5wBjpfWHw/?lang=pt>. Acesso em: 08 fev. 2025.

SECINARO, S. et al. The role of artificial intelligence in healthcare: a structured literature review. **BMC Medical Informatics and Decision Making**, n. 21, p. 125, 2021. DOI: <https://doi.org/10.1186/s12911-021-01488-9>. Disponível em: <https://link.springer.com/article/10.1186/s12911-021-01488-9#citeas>. Acesso em: 05 fev. 2025.

SHELDON, E. et al. Prevalence and risk factors for mental health problems in university undergraduate students: A systematic review with meta-analysis. **Journal of Affective Disorders**, v. 287, p. 282-292, 2021. DOI: <https://doi.org/10.1016/j.jad.2021.03.054>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0165032721002809>. Acesso em: 07 fev. 2025.

SIDDIQUA, R. et al. AIDA: Artificial intelligence based depression assessment applied to Bangladeshi students. **Array**, v. 18, p. 100291, 2023. DOI: <https://doi.org/10.1016/j.array.2023.100291>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2590005623000164>. Acesso em: 21 nov. 2024.

SINHA, C.; MEHELI, S.; KADABA, M. Understanding Digital Mental Health Needs and Usage With an Artificial Intelligence-Led Mental Health App (Wysa) During the COVID-19 Pandemic: Retrospective Analysis. **JMIR formative research**, v. 7, p. e41913, 2023. DOI: <https://doi.org/10.2196/41913>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/36540052/>. Acesso em: 21 nov. 2024.

SOFIA. et al. Machine learning based model for detecting depression during Covid-19 crisis. **Scientific African**, v. 20, p. e01716, 2023. DOI: <https://doi.org/10.1016/j.sciaf.2023.e01716>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/37214195/>. Acesso em: 20 nov. 2024.

SONG, X. et al. Comparison of machine learning and logistic regression models in predicting acute kidney injury: A systematic review and meta-analysis. **International Journal of Medical Informatics**, v. 151, p. 104484, 2021. DOI: <https://doi.org/10.1016/j.ijmedinf.2021.104484>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1386505621001106>. Acesso em: 08 fev. 2025

STEPHANIE, L., SHARMA, R. S. Digital health eco-systems: an epochal review of practiceoriented research. **International Journal Of Information Management**, v. 53, p. 102032, 2020. DOI: <https://doi.org/10.1016/j.ijinfomgt.2019.10.017>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0268401219300684>. Acesso em: 12 jun. 2024.

SUÁREZ-OBANDO, F. et al. Patterns of digital information and communication technology use among patients at primary health care centres in Colombia: Phase I of the DIADA Project. **Revista Colombiana de Psiquiatria** (English ed.), v. 50, n. (suppl. 1), p. 116-132, 2021. DOI: <https://doi.org/10.1016/j.rcpeng.2021.06.003>. Disponível em: <https://doi.org/10.1016/j.rcpeng.2021.06.003>. Acesso em: 12 jun. 2024.

TALÃO, F. C. de L. M. et al. Fatores que podem contribuir para transtornos psiquiátricos nos habitantes de Cardoso Moreira-RJ. **Biológicas & Saúde**, 10(32), 36-50, 2020. DOI: <https://doi.org/10.25242/8868103220201908>. Disponível em: https://ojs3.perspectivasonline.com.br/biologicas_e_saude/article/view/1908. Acesso em: 13 jun. 2024.

TATE, A. E. et al. Predicting mental health problems in adolescence using machine learning techniques. **PloS one**, v. 15, n. 4, p. e0230389. DOI: <https://doi.org/10.1371/journal.pone.0230389>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32251439/>. Acesso em: 20 nov. 2024.

TOSTI, B.; CORRADO, S.; MANCONE, S. Uso de Chatbots e Agentes Conversacionais para Promoção do Bem-estar e Saúde Mental em Adolescentes: Limitações e Perspectivas. **Revista de Metodologia e Tecnologia Inclusiva em Aprendizagem e Ensino**, v. 4, n. 1, 2024. DOI: <https://doi.org/10.32043/jimtl.v4i1.128>. Disponível em: <https://www.inclusiveteaching.it/index.php/inclusiveteaching/article/view/128>. Acesso em: 06 fev. 2025.

TRICCO, A. C. et al. PRISMA extension for scoping reviews (PRISMA - ScR): checklist and explanation. **Annals of Internal Medicine**, v. 169, n. 7, p. 467-473, 2018. DOI: <https://doi.org/10.7326/M18-0850>. Disponível em: <https://www.acpjournals.org/doi/full/10.7326/M18-0850>. Acesso em: 15 fev. 2024.

TUTUN, S. et al. An AI-based Decision Support System for Predicting Mental Health Disorders. **Information systems frontiers: a journal of research and innovation**, v. 25, n. 3, p. 1261–1276, 2023. DOI: <https://doi.org/10.1007/s10796-022-10282-5>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/35669335/>. Acesso em: 24 nov. 2024.

VAISHYA, R. et al. Artificial Intelligence (AI) applications for COVID-19 pandemic. **Diabetes & Metabolic Syndrome: Clinical Research & Reviews**, v. 14, n. 4, p. 337-339,

2020. DOI: <https://doi.org/10.1016/j.dsx.2020.04.012>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1871402120300771>. Acesso em: 03 fev. 2025.

VASCONCELOS, M. I. O. et al. Validação do aplicativo *helpteen* para prevenção da violência contra adolescentes. **Enfermagem em Foco**, v. 11, n. 4, p. 7-14, 2020. DOI: <https://doi.org/10.21675/2357-707X.2020.v11.n3.3531>. Disponível em: <http://revista.cofen.gov.br/index.php/enfermagem/article/view/3531>. Acesso em: 24 maio. 2024.

VIANA, L. S. et al. Desenvolvimento e validação de um jogo educativo sobre uso abusivo de drogas e o risco de suicídio. **SMAD, Revista Eletrônica Saúde Mental Álcool e Drogas**, v. 19, n. 2, p. 16–25, 2023. DOI: <https://doi.org/10.11606/issn.1806-6976.smad.2023.188483>. Disponível em: <https://www.revistas.usp.br/smad/article/view/188483>. Acesso em: 24 maio. 2024.

VICTOR, E. et al. Detecting depression using a framework combining deep multimodal neural networks with a purpose-built automated evaluation. **Psychological assessment**, v. 31, n. 8, p. 1019–1027, 2019. DOI: <https://doi.org/10.1037/pas0000724>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/31045384/>. Acesso em: 23 nov. 2024.

VIGNOLA, R.C.B. (2013). Escala de depressão, ansiedade e estresse (DASS): adaptação e validação para o português do Brasil. Dissertação (Mestrado em Ciências da Saúde) – Programa de Pós-Graduação Interdisciplinar em Ciências da Saúde, Universidade Federal de São Paulo, Santos, 2013.

VILLA-PÉREZ, M. E. et al. Extracting mental health indicators from English and Spanish social media: a machine learning approach. **IEEE Access**, v. 11, p. 128135-128152, 2023. DOI: <https://10.1109/ACCESS.2023.3332289>. Disponível em: <https://ieeexplore.ieee.org/document/10315126>. Acesso em: 22 nov. 2024.

WANG, S. et al. A deep learning algorithm using CT images to screen for Corona virus disease (COVID-19). **European Radiology**, v. 31, p. 6096–6104, 2021. DOI: <https://doi.org/10.1007/s00330-021-07715-1>. Disponível em: <https://link.springer.com/article/10.1007/S00330-021-07715-1#citeas>. Acesso em: 03 fev. 2024.

WANG, X. et al. Prediction of Mental Health in Medical Workers During COVID-19 Based on Machine Learning. **Frontiers in public health**, v. 9, p. 697850, 2021. DOI: <https://doi.org/10.3389/fpubh.2021.697850>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34557468/>. Acesso em: 22 nov. 2024.

WENG, J. H. et al. Mental Wellness Self-Care in Singapore With mindline.sg: A Tutorial on the Development of a Digital Mental Health Platform for Behavior Change. **Journal of Medical Internet Research**, v. 26, p. e44443. DOI: <https://doi.org/10.2196/2F44443>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC11185903/>. Acesso em: 27 jun. 2024.

YANG, S. et al. Clinical Advice by Voice Assistants on Postpartum Depression: Cross-Sectional Investigation Using Apple Siri, Amazon Alexa, Google Assistant, and Microsoft Cortana. **JMIR mHealth and uHealth**, v. 9, n. 1, p. e24045, 2021. DOI: <https://doi.org/10.2196/24045>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/33427680/>. Acesso em: 22 nov. 2024.

YOO, D. W. et al. Patient Perspectives on AI-Driven Predictions of Schizophrenia Relapses: Understanding Concerns and Opportunities for Self-Care and Treatment. Proceedings of the SIGCHI conference on human factors in computing systems. **CHI Conference**, v. 702, p. 1-41, 2024. DOI: <https://doi.org/10.1145/3613904.3642369>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38894725/>. Acesso em: 20 nov. 2024.

YUNIKE, Y. et al. The Implications of Utilizing Artificial Intelligence-Based Parenting Technology on Children's Mental Health: A Literature Review. **Poltekita: Jurnal Ilmu Kesehatan**, v. 17, n. 3, p. 1083–1099, 2023. DOI: <https://doi.org/10.33860/jik.v17i3.2958>. Disponível em: <https://jurnal.poltekkespalu.ac.id/index.php/JIK/article/view/2958>. Acesso em: 06 fev. 2025.

ZHANG, W. et al. Detecting individuals with severe mental illness using artificial intelligence applied to magnetic resonance imaging. **EBioMedicine**, v. 90, p. 104541, 2023. DOI: <https://doi.org/10.1016/j.ebiom.2023.104541>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/36996601/>. Acesso em: 20 nov. 2024.

APÊNDICES

APÊNDICE A – ITENS DE RELATÓRIO PREFERIDOS PARA REVISÕES SISTEMÁTICAS E EXTENSÃO DE METANÁLISES PARA REVISÕES DE ESCOPO (PRISMA-SCR), LISTA DE VERIFICAÇÃO.

Base da dados	Chaves de busca	Resultado da pesquisa	Total após exclusão das duplicações	Estudos pré-selecionados	Amostra final
MEDLINE (via PUBMED)					
LILACS					
Scopus					
BDEnf					
Web of Science					
Biblioteca Digital de Teses e dissertações da CAPES					
Google Acadêmico					
TOTAL:					

Fonte: elaborado pelo autor (2024).

**APÊNDICE B – FORMULÁRIO DE TRIAGEM DOS ESTUDOS, SEGUNDO OS
CRITÉRIOS DE INCLUSÃO E EXCLUSÃO.**

Justificativa da inclusão	Sim	Não
Artigo científico em saúde que responde à questão norteadora.		
Idioma português do Brasil, espanhol e inglês.		
Justificativa da exclusão	Sim	Não
Estudos que não contemplam o objetivo do estudo.		
Artigos completos não disponibilizados gratuitamente na íntegra.		
Estudos que não contemplam o objetivo do estudo.		

Fonte: elaborado pelo autor (2024).

ANEXOS

ANEXO A – ITENS DE RELATÓRIO PREFERIDOS PARA REVISÕES SISTEMÁTICAS E EXTENSÃO DE METANÁLISES PARA REVISÕES DE ESCOPO (PRISMA-SCR), LISTA DE VERIFICAÇÃO.

ITENS DE RELATÓRIO PREFERIDOS PARA REVISÕES SISTEMÁTICAS E EXTENSÃO DE METANÁLISES PARA REVISÕES DE ESCOPO (PRISMA-SCR) LISTA DE VERIFICAÇÃO			
SEÇÃO	Item	ITEM DA LISTA DE VERIFICAÇÃO PRISMA-ScR	RELATÓRIO NA PÁGINA Nº
TÍTULO	1	Identifique o relatório como uma revisão de escopo.	
RESUMO			
Resumo estruturado	2	Forneça um resumo estruturado que inclua (conforme aplicável): histórico, objetivos, critérios de elegibilidade, fontes de evidências, métodos de mapeamento, resultados e conclusões que se relacionam com as questões e objetivos da revisão.	
INTRODUÇÃO			
Justificativa	3	Descreva a justificativa para a revisão no contexto do que já é conhecido. Explique por que as questões / objetivos da revisão se prestam a uma abordagem de revisão de escopo.	
Objetivos	4	Forneça uma declaração explícita das questões e objetivos sendo abordados com referência aos seus elementos chave (por exemplo, população ou participantes, conceitos e contexto) ou outros elementos-chave relevantes usados para conceituar as questões e / ou objetivos da revisão.	
Métodos			
Protocolos e registros	5	Indique se existe um protocolo de revisão; indique se e onde ele pode ser acessado (por exemplo, um endereço da Web); e, se disponível, forneça informações de registro, incluindo o número de registro.	
Critérios de elegibilidade	6	Especifique as características das fontes de evidência usadas como critérios de elegibilidade (por exemplo, anos considerados, idioma e status de publicação) e forneça uma justificativa.	
Fontes de informação	7	Descreva todas as fontes de informação na pesquisa (por exemplo, bancos de dados com datas de cobertura e contato com os autores para identificar fontes adicionais), bem como a data em que a pesquisa mais recente foi executada.	
Estratégia de busca	8	Apresente a estratégia de busca eletrônica completa para pelo menos 1 banco de dados, incluindo quaisquer limites usados, de forma que possa ser repetida.	
Seleção de fontes de evidência	9	Declare o processo de seleção de fontes de evidência (ou seja, triagem e elegibilidade) incluídas na análise de escopo.	

Continua

Continuação do Anexo A

Avaliação crítica de fontes individuais de evidência	12	Se feito, forneça uma justificativa para conduzir uma avaliação crítica das fontes de evidência incluídas; descrever os métodos usados e como essas informações foram usadas em qualquer síntese de dados (se apropriado).	
Síntese de resultados	13	Descreva os métodos de tratamento e resumo dos dados mapeados.	
RESULTADOS			
Seleção de fontes de evidência	14	Forneça o número de fontes de evidências selecionadas, avaliadas quanto à elegibilidade e incluídas na revisão, com os motivos das exclusões em cada estágio, de preferência usando um diagrama de fluxo.	
Características das fontes de evidência	15	Para cada fonte de evidência, apresente as características para as quais os dados foram mapeados e forneça as citações.	
Avaliação crítica dentro de fontes de evidência	16	Se feito, apresente os dados da avaliação crítica das fontes de evidências incluídas (ver item 12).	
Resultados de fontes individuais de evidência	17	Para cada fonte de evidência incluída, apresente os dados relevantes que foram mapeados e que se relacionam com as questões e os objetivos da revisão.	
Síntese de resultados	18	Resuma e/ou apresente os resultados do gráfico, conforme se relacionam com as questões e os objetivos da revisão.	
DISCUSSÃO			
Resumo da evidência	19	Resuma os principais resultados (incluindo visão geral dos conceitos, temas e tipos de evidências disponíveis), faça um link para as questões e objetivos da revisão e considere a relevância para os grupos-chave.	
Limitações	20	Discuta as limitações do processo de revisão do escopo.	
Conclusão	21	Forneça uma interpretação geral dos resultados, no que diz respeito às questões e aos objetivos da revisão, bem como as possíveis implicações e/ou próximos passos.	
FINANCIAMENTO			
	22	Descreva as fontes de financiamento para as fontes de evidências incluídas, bem como as fontes de financiamento para a revisão do escopo. Descreva a função dos financiadores da revisão do escopo.	

Fonte: Tricco *et al.* (2018).

ANEXO B – DECLARAÇÃO DE REVISÃO LINGUÍSTICA DO TRABALHO.**DECLARAÇÃO**

Declaro para os devidos fins que eu, Luana Monteiro do Nascimento, graduada em Letras, pela Universidade Federal do Ceará, portadora do registro profissional nº 47862817/SEDUC-CE, realizei a revisão linguística do Trabalho de Conclusão do Curso originalmente intitulado **Utilização de inteligência artificial para o cuidado em saúde às pessoas com transtornos mentais: revisão de escopo**, sob autoria de Caio San Rodrigues e orientação da Prof.^ª Dra. Eliany Nazaré Oliveira, apresentado ao Curso de Graduação em Enfermagem, do Centro de Ciências da Saúde, da Universidade Estadual Vale do Acaraú – UVA, Sobral/CE, como requisito parcial à obtenção do grau de Bacharel em Enfermagem.

Fortaleza, 9 de março de 2025.



Prof.^ª Luana Monteiro do Nascimento
Graduada em Letras pela Universidade Federal do Ceará (UFC).
Especialista em Ensino de Língua Materna (UECE).
Especialista em Gestão Escolar (UECE). Mestra em Ensino da
Língua Portuguesa (UFC). Portadora do Registro Profissional
nº. 47862817/SEDUC-CE.
E-mail: rodrigues.esp@gmail.com / luanamonteiro22@hotmail.com

Fone 85 984046530