



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
PROGRAMAS DE RESIDÊNCIA MÉDICA EM PSIQUIATRIA

WELINGTON DE SOUZA OLIVEIRA

**INTELIGÊNCIA ARTIFICIAL APLICADA AO CUIDADO DO TEA: REVISÃO
CRÍTICA E PROPOSTA DE PROTOCOLO ASSISTENCIAL**

Uberlândia-MG

2026

WELINGTON DE SOUZA OLIVEIRA

**INTELIGÊNCIA ARTIFICIAL APLICADA AO CUIDADO DO TEA: REVISÃO
CRÍTICA E PROPOSTA DE PROTOCOLO ASSISTENCIAL**

Trabalho de Conclusão de Curso de
Residência Médica em Psiquiatria ao
programa de Pós-graduação em
Residência Médica da Universidade
Federal de Uberlândia como requisito
parcial para obtenção do título de
especialista em Psiquiatria.

Área de concentração: **Psiquiatria da
Infância e Adolescência**

Orientador: Tiago Castro e Couto

Uberlândia-MG

2026

Ata de defesa do Trabalho de Conclusão da Residência

Aos 30 dias do mês de janeiro do ano de 2026, realizou-se a sessão pública de defesa do Trabalho de Conclusão de Residência Médica apresentado pelo(a) Residente Welington de Souza Oliveira, além do orientador Tiago Castro Couto presidente desta banca, constituíram a banca examinadora os seguintes membros Marcelo Marquez Gabriel e Mariana Messias Marinho todos os membros com formação médica e titulação em psiquiatria.

Após a finalização da apresentação do TCRM pelo residente, a banca examinadora iniciou a sua arguição. Os examinadores reuniram-se e deram o parecer final do trabalho escrito e a apresentação oral e atribuíram as seguintes notas:

Avaliador 1:

Nota final: ____ 10 ____

Avaliador 2:

Nota final: ____ 10 ____

Obtendo como média de nota atribuída pelos dois avaliadores a nota final ____ 10 ____.

Divulgado o resultado pelo presidente da banca examinadora, os trabalhos foram encerrados e eu Tiago Castro Couto lavro a presente ata que assino juntamente com os demais membros da banca examinadora.

Uberlândia, 30 de janeiro de 2026.

Documento assinado digitalmente
 **TIAGO CASTRO E COUTO**
Data: 11/02/2026 09:30:31 -0300
Verifique em <https://validar.iti.gov.br>

Orientador

Documento assinado digitalmente
 **MARCELO MARQUEZ GABRIEL**
Data: 11/02/2026 11:16:49-0300
Verifique em <https://validar.iti.gov.br>

Membro da Banca Avaliadora
Marcelo Marquez Gabriel

Membro da Banca Avaliadora
Mariana Messias Marinho
Assinado digitalmente por:
MARIANA MESSIAS MARINHO
Data: 11/02/2026 - 13:14:16h

Resumo

O Transtorno do Espectro Autista (TEA) apresenta desafios clínicos significativos, incluindo a heterogeneidade fenotípica e o atraso no diagnóstico definitivo, frequentemente agravados pela escassez de especialistas e pela subjetividade das avaliações comportamentais. A Inteligência Artificial (IA) emerge como uma tecnologia promissora para oferecer suporte à decisão clínica, embora sua aplicabilidade em contextos de recursos limitados, como o Sistema Único de Saúde (SUS), permaneça pouco explorada. Diante desse cenário, este estudo teve como objetivo realizar uma revisão integrativa da literatura (2010–2025) sobre aplicações de IA no diagnóstico, prognóstico e intervenção no TEA, analisando criticamente a qualidade das evidências e barreiras de implementação, culminando na proposição de um protocolo institucional para adoção responsável dessas tecnologias em um hospital universitário. Metodologicamente, trata-se de um estudo de revisão integrativa seguido de proposta de intervenção gestora, no qual foram analisados 31 estudos, categorizados por domínio de aplicação e maturidade tecnológica. Os resultados evidenciam um crescimento exponencial no uso de *Deep Learning* e análise de dados não estruturados (vídeo, neuroimagem). Embora os modelos demonstrem alta acurácia técnica em ambientes controlados (*in silico*), observa-se uma lacuna crítica de validação externa em cenários clínicos reais (*in vivo*), além de barreiras substanciais como viés demográfico nas bases de dados, baixa explicabilidade dos algoritmos ("caixa-preta") e desafios ético-legais. Conclui-se que a IA encontra-se majoritariamente em estágio de prova de conceito, não estando pronta para substituir o julgamento clínico; contudo, seu potencial como ferramenta de triagem e suporte é robusto. O presente trabalho propõe, portanto, um protocolo de governança e validação local para viabilizar a integração segura da IA na prática assistencial, mitigando riscos e priorizando a equidade no acesso ao diagnóstico.

Palavras-chave: Transtorno do Espectro Autista; Inteligência Artificial; Diagnóstico Precoce; Protocolos Clínicos; Saúde Digital.

ABSTRACT

Autism Spectrum Disorder (ASD) presents significant clinical challenges, including phenotypic heterogeneity and delays in definitive diagnosis, often exacerbated by a shortage of specialists and the subjectivity of behavioral assessments. Artificial Intelligence (AI) emerges as a promising technology to offer clinical decision support, although its applicability in resource-limited settings, such as the Brazilian Unified Health System (SUS), remains underexplored. Therefore, this study aimed to conduct an integrative literature review (2010–2025) on AI applications in ASD diagnosis, prognosis, and intervention, critically analyzing evidence quality and implementation barriers, culminating in the proposal of an institutional protocol for the responsible adoption of these technologies in a university hospital. The method consisted of an integrative review study followed by a management intervention proposal, analyzing thirty-one studies categorized by application domain and technological maturity. The literature evidence exponential growth in the use of Deep Learning and unstructured data analysis (video, neuroimaging). Although models demonstrate high technical accuracy in controlled environments (*in silico*), a critical gap in external validation within real-world clinical scenarios (*in vivo*) is observed, alongside substantial barriers such as demographic bias in databases, low algorithm explainability ("black box"), and ethical-legal challenges. In conclusion, AI is predominantly at the proof-of-concept stage and is not ready to replace clinical judgment; however, its potential as a screening and support tool is robust. Thus, this work proposes a governance and local validation protocol to enable the safe integration of AI into clinical practice, mitigating risks and prioritizing equity in diagnostic access.

Keywords: Autism Spectrum Disorder; Artificial Intelligence; Early Diagnosis; Clinical Protocols; Digital Health.

LISTA DE TABELAS

Tabela 1 - Critérios de seleção das referências utilizadas. -----	15
Tabela 2 - Referências dos trabalhos selecionados-----	17
Tabela 3 - Composição e características das 31 referências incluídas na revisão ----	22
Tabela 4 - Domínios de aplicação de IA em TEA (nas 31 referências) -----	23
Tabela 5 - Distribuição das modalidades de dados nos estudos incluídos -----	24
Tabela 6 - Síntese comparativa (reportada) de desempenho de modelos de IA -----	26
Tabela 7 - Síntese (nas 31 referências) de evidências em prognóstico/monitoramento No TEA-----	28
Tabela 8 - Síntese qualitativa de evidência em intervenções tecnológicas/IA para TEA (nas 31 referências) -----	30
Tabela 9 - Síntese estruturada de barreiras e recomendações para implementação clínica de IA em TEA -----	33

LISTA DE FIGURAS

- Figura 1: Distribuição temporal das 31 referências incluídas (2012–2025) -----21
- Figura 2: Tipos de técnicas de IA mais frequentes entre os estudos incluídos----24

LISTA DE ABREVIATURAS E SIGLAS

ABA – Applied Behavior Analysis (Análise do Comportamento Aplicada)

ABIDE – Autism Brain Imaging Data Exchange

ADI-R – Autism Diagnostic Interview–Revised (Entrevista Diagnóstica para Autismo Revisada)

ADOS-2 – Autism Diagnostic Observation Schedule – 2ª edição (Escala/Protocolo de Observação Diagnóstica para Autismo)

AGHU – Aplicativo de Gestão para Hospitais Universitários

AUC – Area Under the Curve (Área sob a Curva ROC)

CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CEP – Comitê de Ética em Pesquisa

CFM – Conselho Federal de Medicina

CFP – Conselho Federal de Psicologia

CNN – Convolutional Neural Network (Rede Neural Convolucional)

CNS – Conselho Nacional de Saúde

DL – Deep Learning (Aprendizado Profundo)

DSM-5 – Diagnostic and Statistical Manual of Mental Disorders – 5ª edição

EBSERH – Empresa Brasileira de Serviços Hospitalares

EHR – Electronic Health Record (Prontuário Eletrônico em Saúde)

EMR – Electronic Medical Record (Registro Médico Eletrônico)

fMRI – functional Magnetic Resonance Imaging (Ressonância Magnética Funcional)

GPU – Graphics Processing Unit (Unidade de Processamento Gráfico)

HCU-UFU – Hospital de Clínicas da Universidade Federal de Uberlândia

IA – Inteligência Artificial

IC 95% – Intervalo de Confiança de 95%

IoT – Internet of Things (Internet das Coisas)

ITS – Intelligent Tutoring Systems (Sistemas Tutores Inteligentes)

LGPD – Lei Geral de Proteção de Dados (Lei nº 13.709/2018)

LIME – Local Interpretable Model-Agnostic Explanations

M-CHAT – Modified Checklist for Autism in Toddlers

MEDLINE – Medical Literature Analysis and Retrieval System Online

ML – Machine Learning (Aprendizado de Máquina)

MRI – Magnetic Resonance Imaging (Ressonância Magnética)

OMS – Organização Mundial da Saúde

PRISMA – Preferred Reporting Items for Systematic Reviews and Meta-Analyses

RCT – Randomized Controlled Trial (Ensaio Clínico Randomizado)

RMSE – Root Mean Square Error (Raiz do Erro Quadrático Médio)

RNN – Recurrent Neural Network (Rede Neural Recorrente)

ROC – Receiver Operating Characteristic (Curva Característica de Operação do Receptor)

ROI – Return on Investment (Retorno sobre Investimento)

SaMD – Software as a Medical Device (Software como Dispositivo Médico)

SHAP – SHapley Additive exPlanations

SUS – Sistema Único de Saúde

SVM – Support Vector Machine (Máquina de Vetores de Suporte)

TCRM – Trabalho de Conclusão de Residência Médica

TEA – Transtorno do Espectro Autista

TI – Tecnologia da Informação

VR – Virtual Reality (Realidade Virtual)

WEIRD – Western, Educated, Industrialized, Rich, Democratic

SUMÁRIO

1.	INTRODUÇÃO	9
2.	JUSTIFICATIVA	12
3.	OBJETIVOS	13
4.	METODOLOGIA.....	13
5.	RESULTADOS	17
5.1.1	Seleção dos estudos e distribuição temporal	21
5.1.2	Distribuição geográfica e contexto clínico	21
5.1.3	Domínios de aplicação e modalidade de dados	22
5.2.1	Visão geral e relevância clínica.....	25
5.2.2	Biomarcadores digitais: rastreamento ocular e análise de vídeo.....	25
5.2.3	neuroimagem e dados tabulares.....	25
5.2.4	Síntese de desempenho e limitações	26
5.3.1	Definição e estado da arte	27
5.3.2	Referências no domínio prognóstico/monitoramento e preditores	28
5.3.3	Desafios técnicos e clínicos	28
5.4.1	Visão geral das intervenções nas referências incluídas	29
5.4.2	Robótica social e interação humano-robô	29
5.4.3	Tecnologias educacionais, suporte digital e gamificação/engajamento	29
5.4.4	Síntese de eficácia e comparação com terapias padrão.....	30
5.5.1	Transição metodológica: do ml clássico ao deep learning.....	31
5.5.2	Integração multimodal emergente	31
5.6.1	Barreiras metodológicas críticas	32
5.6.2	Barreiras clínicas e operacionais.....	32
5.6.3	Barreiras éticas e de governança.....	32
5.6.4	Barreiras de equidade e acesso.....	32
5.6.5	Síntese integrativa: framework de ação	33
6.	DISCUSSÃO	36
6.1.1	Panorama geral da literatura identificada	37
6.1.2	Diagnóstico e triagem: desempenho e significado clínico	38
6.1.3	Intervenções terapêuticas mediadas por tecnologia/ia.....	38
6.1.4	Prognóstico e monitoramento: lacuna crítica	38
6.2.1	O paradoxo do desempenho técnico e o hiato translacional.....	39

6.2.2	volução tecnológica e o trade-off entre desempenho e explicabilidade.....	40
7.	CONCLUSÃO.....	43
8.	REFERÊNCIAS.....	45

1. INTRODUÇÃO

O Transtorno do Espectro Autista (TEA) é uma condição neuro desenvolvimental caracterizada por déficits persistentes na comunicação e interação social, acompanhados por padrões restritos e repetitivos de comportamento, interesses ou atividades, conforme critérios diagnósticos do Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-5-TR) (AMERICAN PSYCHIATRIC ASSOCIATION, 2022). Sua prevalência tem aumentado globalmente nas últimas décadas, com estimativas recentes indicando aproximadamente 1 em 36 crianças nos Estados Unidos (MAENNER et al., 2023). No Brasil, dados do Censo 2022 identificaram 2,4 milhões de pessoas com TEA (1,2% da população), com maior prevalência no sexo masculino (1,5%) e concentração em crianças e adolescentes de 5 a 9 anos (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2023). Estudos epidemiológicos apontam que o TEA é cerca de quatro vezes mais frequente em meninos do que em meninas, embora essa diferença possa refletir, em parte, subdiagnóstico em mulheres, especialmente em idades precoces (LOOMES et al., 2017; LAI et al., 2017).

O TEA apresenta etiologia multifatorial, envolvendo interação entre fatores genéticos de alta hereditariedade e fatores ambientais não genéticos (LORD et al., 2020; BAI et al., 2019). Sua heterogeneidade fenotípica e a sobreposição de sintomas com outros transtornos do neurodesenvolvimento ou psiquiátricos — como TDAH, TOC, ansiedade e deficiência intelectual — dificultam o diagnóstico preciso e oportuno, elevando o risco de identificação tardia ou incorreta (LOMBARDO et al., 2019; HOSSEINI et al., 2018; LAI et al., 2019).

Diagnósticos precoces e intervenções oportunas estão associados a melhores prognósticos no TEA (ZWAIGENBAUM et al., 2015). Contudo, os métodos convencionais de avaliação diagnóstica baseiam-se em instrumentos comportamentais extensos, dependentes da expertise de especialistas e sujeitos à subjetividade interpretativa. A Entrevista Diagnóstica para Autismo Revisada (ADI-R), por exemplo, inclui 93 questões e demanda sessão estruturada com duração média de 2,5 horas, o que pode limitar sua aplicação em cenários de alta demanda assistencial (RUTTER et al., 2003). Esse cenário contribui para atrasos diagnósticos: muitas crianças recebem diagnóstico definitivo apenas entre 4 e 6 anos, perdendo a janela crítica de intervenção

precoce (VAN'T HOF et al., 2021). A literatura internacional descreve intervalos de até 13 meses entre triagem inicial e confirmação diagnóstica, com maior demora em populações minoritárias ou de baixo nível socioeconômico, o que impacta o acesso a terapias fonoaudiológicas e comportamentais com benefícios mais expressivos quando iniciadas precocemente (ZUCKERMAN et al., 2017; FULLER e KAISER, 2020).

A motivação desta pesquisa fundamenta-se nas experiências acumuladas durante a residência médica em Psiquiatria, especialmente no atendimento de crianças e adolescentes no Ambulatório de Neuropediatria do Hospital de Clínicas de Uberlândia da Universidade Federal de Uberlândia (HCU-UFU/EBSERH). Nesse contexto, observou-se a complexidade do manejo clínico do TEA, marcado por heterogeneidade fenotípica, comorbidades e elevada demanda por acompanhamento multidisciplinar. Entre os desafios práticos, destacam-se: (a) dificuldade de acesso a avaliações especializadas, (b) tempo limitado de consultas ambulatoriais, (c) variabilidade das informações provenientes de familiares, escolas e outros profissionais e (d) necessidade de monitoramento longitudinal estruturado. No SUS e em instituições de referência como o HCU-UFU/EBSERH, essas limitações tendem a ser potencializadas por capacidade assistencial restrita e acesso desigual a serviços especializados (PAULA et al., 2020).

Frente a essas limitações estruturais e operacionais, a inteligência artificial (IA) surge como tecnologia emergente com potencial de suporte clínico por meio de ferramentas voltadas à triagem, análise de padrões comportamentais, integração de dados complexos e auxílio à decisão baseada em evidências (THABTAH, 2019). IA refere-se a sistemas computacionais capazes de executar tarefas normalmente associadas à inteligência humana, como reconhecimento de padrões, aprendizado a partir de dados e suporte à decisão clínica (RUSSELL; NORVIG, 2022). Subcampos como machine learning (ML) e deep learning (DL) permitem extrair conhecimento de dados heterogêneos — vídeos, áudio, neuroimagem, dados genéticos e sinais fisiológicos — para identificar marcadores sutis de TEA e apoiar decisões clínicas (LECUN et al., 2015; HYDE et al., 2019).

Nos últimos 15 anos, aplicações de IA no TEA expandiram-se em três frentes principais. No diagnóstico e triagem, algoritmos de visão computacional analisam expressões faciais, contato visual e comportamentos sociais em vídeos para inferir risco em idades precoces, e sistemas de processamento de voz avaliam características

prosódicas e padrões de vocalização (CARPENTER et al., 2021; BONE et al., 2014). Redes neurais profundas aplicadas a neuroimagem e eletroencefalografia também têm sido utilizadas para identificar alterações neurobiológicas associadas ao transtorno (KHOSLA et al., 2019). No prognóstico e monitoramento, dispositivos vestíveis com sensores e algoritmos de IA vêm sendo investigados para detectar padrões comportamentais e fisiológicos em tempo real, auxiliando a antecipação de desfechos ou a identificação de crises iminentes (TORRADO et al., 2017). Por fim, no domínio das intervenções, robôs sociais, aplicativos de realidade virtual (VR) e tutores inteligentes adaptativos têm sido utilizados para mediar terapias e treinar habilidades sociais, personalizando estratégias conforme necessidades individuais (SCASSELLATI et al., 2018; BOUCENNA et al., 2014).

Apesar desses avanços, persiste lacuna na síntese rigorosa e contextualizada das evidências sobre IA no TEA, especialmente quanto à aplicabilidade clínica em contextos do SUS e de instituições brasileiras. Muitas publicações concentram-se em países de alta renda, apresentam heterogeneidade metodológica e raramente tratam de aspectos éticos críticos — viés algorítmico, privacidade de dados sensíveis, interpretabilidade (“caixa-preta”) e responsabilidade profissional — essenciais para adoção segura em ambientes clínicos reais (WOLFERS et al., 2019). Ademais, são escassas diretrizes práticas sobre integração dessas ferramentas aos fluxos clínicos, critérios de qualidade e segurança para seleção de tecnologias e treinamento de profissionais para uso complementar ao julgamento clínico.

Diante desse cenário, esta investigação é orientada pelas perguntas norteadoras: como a inteligência artificial vem sendo aplicada no diagnóstico/triagem, monitoramento/prognóstico e intervenção no TEA? qual a qualidade e consistência das evidências disponíveis e como essas aplicações podem ser integradas na prática clínica institucional de forma segura, ética e responsável? Espera-se, com esta revisão integrativa, oferecer síntese estruturada que subsidie decisões sobre adoção (ou não) de ferramentas de IA no HCU-UFU/EBSERH e em instituições similares, com foco em reduzir atraso diagnóstico, personalizar intervenções terapêuticas e fortalecer estratégias de monitoramento contínuo do cuidado ao TEA.

2. JUSTIFICATIVA

A detecção precoce e a intervenção oportuna no TEA associam-se a melhores prognósticos funcionais, maior qualidade de vida na idade adulta e menor necessidade de apoios intensivos a longo prazo (ZWAIGENBAUM et al., 2015). Contudo, atrasos diagnósticos de até 13 meses são amplamente descritos, especialmente em populações minoritárias, de baixa renda ou em regiões com escassez de especialistas (ZUCKERMAN et al., 2017). No Brasil, no contexto do SUS, esse cenário é agravado pela disponibilidade limitada e distribuição desigual de profissionais e serviços especializados, além do acesso heterogêneo a instrumentos diagnósticos padronizados (PAULA et al., 2020). Assim, ferramentas tecnológicas que acelerem a triagem, reduzam a variabilidade/subjectividade clínica e apoiem a detecção precoce em ambientes de menor especialização — como atenção primária e consultas pediátricas gerais — podem contribuir para maior equidade diagnóstica e otimização de recursos institucionais (ABBAS et al., 2018).

Do ponto de vista científico, ainda faltam sínteses estruturadas que integrem criticamente as aplicações de IA no TEA para além da eficácia técnica, contemplando implementabilidade, viés algorítmico, privacidade de dados, generalização para populações diversas e integração aos fluxos clínicos. Muitas revisões se concentram apenas no diagnóstico ou em modalidades específicas (por exemplo, neuroimagem ou rastreamento ocular), sem integrar evidências sobre prognóstico/monitoramento e intervenções (SONG et al., 2019). Uma revisão integrativa que abarque diagnóstico/triagem, prognóstico/monitoramento e intervenções terapêuticas, com análise crítica de limitações metodológicas e barreiras de implementação, pode preencher lacuna relevante e orientar pesquisas e estratégias locais.

Este trabalho é particularmente pertinente ao HCU-UFU/EBSERH, instituição que em Minas Gerais faz atendimento a crianças e adolescentes com TEA e seus familiares. Uma síntese informada, associada à proposição de protocolo institucional para uso responsável de IA, pode subsidiar decisões de gestão sobre adoção de sistemas, capacitação de equipes e organização de fluxos clínicos em que a IA atue como complemento — e não substituição — ao julgamento clínico. No contexto do Trabalho de Conclusão de Residência Médica (TCRM) em Psiquiatria, o estudo reforça a

capacidade de síntese crítica de evidências e a contribuição aplicada à qualidade da prática assistencial.

3. OBJETIVOS

O objetivo geral deste trabalho é realizar uma revisão integrativa da literatura (2010–2025) sobre aplicações de inteligência artificial no diagnóstico/triagem, prognóstico/monitoramento e intervenções terapêuticas no Transtorno do Espectro Autista, considerando a qualidade metodológica das evidências, identificando barreiras práticas e éticas para implementação clínica e propondo protocolo institucional para uso responsável e seguro de ferramentas de IA no contexto assistencial do HCU-UFU/EBSERH.

Como objetivos específicos, listam-se:

- Mapear e descrever as principais aplicações de IA identificadas na literatura, categorizando-as por domínio de aplicação (diagnóstico/triagem, prognóstico/monitoramento, intervenções) e por tipo de tecnologia utilizada.
- Sintetizar as métricas de desempenho reportadas e avaliar a consistência dos achados entre estudos dentro de cada domínio de aplicação.
- Identificar barreiras metodológicas, clínicas e éticas para implementação de IA no TEA.
- Descrever elementos essenciais de governança, segurança e responsabilidade profissional associados à adoção de ferramentas de IA em contexto hospitalar ou ambulatorial.
- Elaborar proposição de protocolo institucional de triagem assistida por IA (não diagnóstica) para TEA, definindo escopo de uso, responsabilidades profissionais, critérios de avaliação de ferramentas e requisitos mínimos de qualidade, segurança e transparência.

4. METODOLOGIA

4.1 Tipo de Estudo

Este trabalho consiste em **revisão integrativa da literatura**, modalidade de síntese que permite reunir evidências de diferentes delineamentos (estudos originais, revisões

sistemáticas/meta-análises e diretrizes/documentos) para responder a questões amplas e orientar decisões clínicas e institucionais. Optou-se por essa abordagem por sua adequação ao mapeamento de um campo emergente (IA aplicada ao TEA) e à produção de recomendações aplicáveis ao contexto do **Trabalho de Conclusão de Residência Médica (TCRM)**.

4.2 Estratégia de Busca

A busca bibliográfica foi realizada nas bases **PubMed/MEDLINE** e **Google Scholar** entre **outubro de 2025** e **janeiro de 2026**, visando identificar literatura biomédica indexada e literatura ampliada/literatura cinzenta acadêmica (incluindo trabalhos de conferências). O recorte temporal **2010–2025** foi adotado para capturar a evolução das aplicações de IA no TEA, incluindo desenvolvimentos recentes até **maio de 2025**.

Utilizaram-se combinações de termos-chave em inglês: ("**Autism Spectrum Disorder**" OR "**ASD**" OR "**autism**") AND ("**Artificial Intelligence**" OR "**Machine Learning**" OR "**Deep Learning**" OR "**Neural Network**") AND ("**diagnosis**" OR "**screening**" OR "**prognosis**" OR "**monitoring**" OR "**intervention**" OR "**therapy**").

Adicionalmente, realizou-se **rastreamento manual de referências** a partir de revisões sistemáticas e meta-análises recentes (2019–2025), para identificar estudos-chave. A estratégia combinada (busca direta + rastreamento de citações) foi adotada para maximizar sensibilidade na identificação de evidências relevantes.

4.3 Critérios de Seleção

Os critérios de seleção de inclusão e exclusão estão resumidos na Tabela 1. Esses critérios visaram garantir evidências com **qualidade mínima (revisão por pares)** e aplicabilidade direta ao cuidado humano.

Inclusão	Exclusão
1. Tipo de publicação: artigos originais revisados por pares, revisões sistemáticas, meta-análises e diretrizes clínicas internacionais;	1. Relatos/séries de casos sem grupo controle/comparador; 2. Revisões narrativas, comentários, editoriais ou cartas ao editor sem

2. População: amostras humanas com TEA confirmado ou em risco de TEA (qualquer faixa etária) ou cuidadores/profissionais diretamente envolvidos no cuidado; 3. Intervenção: aplicação primária e explícita de IA (não apenas menção incidental) para diagnóstico, triagem, prognóstico, monitoramento ou intervenção/tratamento no TEA; 4. Idioma: inglês ou português; 5. Período: 2010–2025.	síntese sistemática (consultados apenas para contextualização); 3. Estudos sem método claramente descrito ou reflexões puramente teóricas sem aplicação metodológica definida; 4. Pré-prints ou publicações não revisadas por pares; 5. Estudos exclusivamente com modelos animais ou simulações sem validação em dados reais de pacientes humanos.
--	--

Tabela 1 – Critérios de seleção das referências utilizadas.

4.4 Seleção dos Estudos

Os resultados foram organizados em planilha eletrônica, registrando autor(es), ano, título, periódico e disponibilidade de acesso ao texto completo. A triagem inicial foi realizada por títulos e resumos, seguida de leitura de texto completo dos estudos potencialmente elegíveis, obtidos por portais institucionais.

A estratégia foi aplicada em **outubro de 2025 e janeiro de 2026**, com identificação inicial de aproximadamente **850 registros**: PubMed/MEDLINE (n≈420), Google Scholar (primeiras 15 páginas de resultados relevantes, n≈380) e rastreamento manual de referências (n=50). Após remoção manual de duplicatas óbvias e triagem inicial por relevância, foram avaliados **312 títulos e resumos**, com exclusão de **267** por não atenderem aos critérios. Motivos principais de exclusão: ausência de aplicação primária de IA (n=112), população não relacionada ao TEA (n=68), tipo de publicação inadequado (editoriais/comentários/sem revisão por pares) (n=54), idioma diferente de inglês/português (n=21) e período anterior a 2010 ou dados insuficientes (n=12). Foram avaliados **45 textos completos**, com exclusão de **14** por: método insuficientemente descrito/ausência de validação dos algoritmos (n=7), estudos puramente teóricos ou simulações sem dados reais de pacientes (n=4) e duplicação de análise de mesma coorte já incluída em publicação mais recente (n=3). O processo resultou em **31 trabalhos incluídos** na síntese integrativa: **08 estudos originais**, **19 revisões sistemáticas/meta-análises** (para contextualização e validação de achados) e **3 documentos metodológicos/diretrizes internacionais** (PRISMA 2020, diretrizes de ética em IA da

OMS, DSM-5-TR). Todos os 31 trabalhos foram acessados na íntegra para extração de informações e análise crítica.

4.5 Extração de Dados

Dos **08 estudos originais**, extraíram-se: autores/ano; país; delineamento (transversal, caso-controle, coorte prospectiva, ensaio clínico randomizado); tamanho e características da amostra (n, idade/faixa etária, sexo, critérios diagnósticos — DSM-5, ADOS, ADI-R); técnica de IA (p.ex., SVM, Random Forest, CNN, RNN) e tipo de dado de entrada (comportamental, vídeo, neuroimagem estrutural/funcional, biomarcadores moleculares, sensores fisiológicos); domínio de aplicação (diagnóstico/triagem precoce, predição prognóstica/monitoramento, intervenção terapêutica); principais achados quantitativos (acurácia, sensibilidade, especificidade, AUC, tamanho de efeito e métricas de viabilidade/usabilidade clínica). Também foram registrados: limitações relatadas, presença de validação externa (testes em amostras independentes) e considerações sobre relevância clínica/aplicabilidade. Das **10 revisões sistemáticas/meta-análises**, extraíram-se: número de estudos incluídos, populações agregadas, principais conclusões quantitativas (p.ex., acurácia média **pooled**, tamanho de efeito combinado) e avaliações de qualidade metodológica/heterogeneidade, para contextualizar e contrastar os achados dos estudos originais.

4.6 Síntese e Análise dos Dados

Realizou-se síntese qualitativa estruturada, organizando evidências em três domínios: (1) IA em diagnóstico/triagem do TEA, (2) IA em prognóstico/monitoramento e (3) IA em intervenções terapêuticas. Em cada domínio, descreveram-se tendências metodológicas (algoritmos e tipos de dados), resultados consistentes ou divergentes e limitações recorrentes (viés de seleção, validade externa limitada, heterogeneidade de protocolos). Revisões sistemáticas/meta-análises foram utilizadas para identificar padrões consolidados e áreas de incerteza.

A síntese culminou na identificação de barreiras práticas, metodológicas e éticas para implementação (viés algorítmico, privacidade, explicabilidade, integração em fluxos assistenciais, custos e escalabilidade) e na proposição fundamentada de protocolo institucional para uso responsável de IA no HCU-UFU/EBSERH. Não foi realizada meta-

análise quantitativa devido à alta heterogeneidade de desfechos, algoritmos, tipos de dados e populações, o que tornaria o agrupamento estatístico metodologicamente inadequado e potencialmente enganoso.

4.7 Considerações Éticas

Por tratar-se de revisão de literatura baseada exclusivamente em publicações científicas e documentos de domínio público, o estudo não envolveu pesquisa com seres humanos nem coleta de dados primários, não requerendo aprovação do Comitê de Ética em Pesquisa (CEP) conforme Resolução CNS nº 510/2016. Ainda assim, foram priorizadas na análise crítica e nas recomendações: vies algorítmico, privacidade de dados sensíveis, transparência/explicabilidade (“caixa-preta”), consentimento informado em ferramentas assistidas por IA e responsabilidade profissional pela interpretação e ação a partir dos outputs dos sistemas.

5. RESULTADOS

Este capítulo apresenta a síntese dos dados extraídos exclusivamente das 31 referências listadas na Tabela 2 e a análise crítica dos achados, organizados em: caracterização geral da literatura incluída e análise por domínios de aplicação da Inteligência Artificial (IA) no Transtorno do Espectro Autista (TEA), com ênfase em diagnóstico/triagem, além de prognóstico/monitoramento, intervenções terapêuticas e tendências tecnológicas relevantes para a translação clínica.

Tabela 2 – Referências dos trabalhos selecionados (n = 31).

#	Autor(e)	Ano	Título abreviado / Tema	Tipo	Veículo/Nota
1	American Psychiatric Association	2022	DSM-5-TR (critérios diagnósticos)	Normativo	DSM-5-TR, APA

2	Solek et al.	2025	IA para ferramentas de diagnóstico precoce (revisão sistemática)	Revisão Sist.	Turkish Archives of Pediatrics, 60(2), 126–140
3	Landa	2018	Eficácia de intervenções precoces em risco de TEA	Revisão	International Review of Psychiatry, 30(1), 25–39
4	Kotsi et al.	2025	Intervenções com IA para estudantes com TEA	Revisão	Disabilities, 5, 7. DOI: 10.3390/disabilities5010007
5	Ghosh et al.	2021	IA e IoT em triagem e manejo do TEA	Revisão	Sustainable Cities and Society, 74, 103189
6	Do Carmo	2025	IA no suporte a pessoas com TEA: tendências/direções	Preprint	University of Maryland, 2025
7	Villamarín et al.	2024	IA na detecção de TEA (revisão sistemática)	Revisão	In: ICIVC (Springer), 21–32
8	Pandya et al.	2024	Promessas/abordagens de IA em pesquisa sobre TEA	Revisão/Overview	Computers in Biology and Medicine, 168, 107801
9	Wankhede et al.	2024	Tendências e perspectivas IA no diagnóstico/tratamento do TEA	Revisão	Asian Journal of Psychiatry, 101, 104241
10	Joudar et al.	2022	IA para triagem/priorização + contribuição gênica (revisão sistemática)	Revisão Sist.	Computer Methods and Programs in Biomedicine, 146, 105553
11	Chaddad et al.	2021	“Pode-se diagnosticar TEA com IA?” (revisão narrativa)	Revisão	Diagnostics, 11(11), 2032

12	Zhang	2025	Triagem, diagnóstico e intervenção assistidos por IA em crianças pequenas	Revisão/Overview	Frontiers in Psychiatry, 16, 1513809
13	Wall et al.	2012	IA para encurtar diagnóstico comportamental (ADI-R)	Original	PLoS ONE, 7(8), e43855
14	Jaradat et al.	2025	ML para diagnóstico por eye-tracking	Original	Diagnostics, 15(1), 66
15	Ahmed et al.	2022	Eye-tracking: diagnóstico/detecção precoce com ML/DL	Original	Electronics, 11(4), 530
16	Wei et al.	2023	Eye-tracking + ML: revisão sistemática e meta-análise	Meta-análise	Journal of Biomedical Informatics, 137, 104254
17	Moon et al.	2019	Acurácia de ML em MRI para TEA (revisão + meta)	Meta-análise	JMIR Mental Health, 6(12), e14108
18	Meng et al.	2023	Diagnóstico precoce por movimentos oculares (faces reais vs artificiais)	Original	Frontiers in Neuroscience, 17, 1170951
19	Bahado-Singh et al.	2019	IA em marcadores epigenômicos neonatais para risco TEA	Original	Brain Research, 1724, 146457
20	Rahman et al.	2020	EMR/EHR + ML para identificar recém-nascidos em risco	Original	European Psychiatry, 63(1), e22
21	Megerian et al.	2022	Avaliação de dispositivo médico IA para diagnóstico (Canvas Dx)	Original	npj Digital Medicine, 5, 57

22	Sohl et al.	2022	IA no modelo ECHO Autism (protocolo de integração)	Protocolo	JMIR Research Protocols, 11(8), e37576
23	Lamos et al.	2021	IA para selecionar estratégias de comunicação docente	Original	NPJ Science of Learning, 6, 25
24	Kouroupa et al.	2022	Robôs sociais: revisão sistemática e meta-análise	Meta-análise	PLoS ONE, 17(6), e0269800
25	Puglisi et al.	2022	Robôs humanoides sociais no TEA: modalidades/limites	Revisão	Children, 9(7), 953
26	Vagnetti et al.	2024	Robôs sociais no TEA: revisão sistemática e análise crítica	Revisão	Review Journal of Autism and Developmental Disorders (no prelo)
27	Jaliaawala & Khan	2020	Survey: tecnologia de intervenção assistida por IA no TEA	Revisão	Artificial Intelligence Review, 53, 1039–1069
28	World Health Organization (WHO)	2021	Ética e governança de IA em saúde	Diretriz	WHO Guidance, 2021
29	Cañete & Peralta	2022	Tecnologia assistiva e colaboração em crianças com TEA	Revisão	Sensors, 22(21), 8321
30	Huijnen et al.	2016	Robôs: objetivos terapêuticos e educacionais no TEA	Revisão	Journal of Autism and Developmental Disorders, 46(6), 2100–2114
31	Page et al.	2021	PRISMA 2020 (diretriz de relato de revisões)	Diretriz	BMJ, 372, n71

Fonte: Elaborado pelo autor.

5.1 Caracterização Geral da Literatura Incluída

5.1.1 Seleção dos Estudos e Distribuição Temporal

A busca, conduzida conforme critérios de revisão integrativa, resultou na inclusão de 31 referências. A amostra compõe-se de 08 estudos originais (primários) e 23 referências secundárias/normativas (incluindo revisões sistemáticas, meta-análises, revisões/overviews, protocolos e diretrizes/documentos), conforme síntese apresentada nas tabelas consolidadas (Tabelas 2–4).

A análise temporal evidencia crescimento progressivo da produção científica sobre IA aplicada ao TEA, com concentração na última década. Observa-se um período de consolidação inicial (2012–2015, n=3), seguido por fase de expansão (2016–2019, n=8) e aceleração significativa a partir de 2020 (2020–2022, n=12). O período mais recente (2023–2025) contribuiu com n=8 referências, indicando diversificação temática e aumento de sínteses secundárias (revisões e overviews) que refletem maturação do campo




Figura 1: Distribuição temporal das 31 referências incluídas (2012–2025).

5.1.2 Distribuição Geográfica e Contexto Clínico

A geografia da produção científica, quando considerada no conjunto das referências incluídas (Tabela 3), aponta predominância de trabalhos oriundos do Norte Global, com os Estados Unidos concentrando a maior parcela. Esta distribuição é consistente com a discussão sobre viés **WEIRD** (Western, Educated, Industrialized, Rich, Democratic), frequentemente identificada em tecnologias biomédicas emergentes.

A Tabela 3 sintetiza a distribuição geográfica e o contexto dos trabalhos incluídos, indicando que a maior parte das publicações se origina de ambientes acadêmicos/universitários e centros de pesquisa, com menor proporção relacionada a cenários de saúde pública. Além disso, a predominância de estudos conduzidos em centros universitários e ambientes controlados levanta questionamentos sobre validade ecológica e escalabilidade, especialmente para o Sistema Único de Saúde (SUS), tema que reaparece nas barreiras operacionais e de equidade discutidas transversalmente no capítulo.

Tabela 3 – Composição e características das 31 referências incluídas na revisão

Aspecto	Categoria	Frequência (n)	Percentual (%)
<i>Tipos de referência</i>	Originais (primários)	08	26%
	Revisões/Meta-análises e outras secundárias/normativas	23	74%
<i>Período</i>	2012–2015	1	3%
	2016–2019	4	13%
	2020–2022	15	48%
	2023–2025	11	36%
<i>Geografia</i>	EUA	10	31%
	Europa	7	23%
	Ásia-Pacífico	13	43%
	America Latina	1	3%
<i>Contexto</i>	Pesquisa universitária	26	85%
	Clínica privada	2	6%
	Sistema público (SUS)	2	6%
	Normativo (DSM)	1	3%

Fonte: Elaborado pelo autor.

5.1.3 Domínios de Aplicação e Modalidade de Dados

Os trabalhos foram categorizados em quatro domínios principais (Tabela 4), com predominância para Diagnóstico e Triagem (45%), seguido por Intervenção Terapêutica (32%), Pesquisa Básica/Exploratória (13%) e Prognóstico/Monitoramento (10%). Essa distribuição confirma que o uso de IA no TEA está mais consolidado no eixo

diagnóstico/triagem, enquanto prognóstico/monitoramento permanece proporcionalmente menos representado e, em geral, mais heterogêneo quanto a desfechos e desenhos.

Dos 08 estudos originais empíricos, a maior parte se concentra no diagnóstico/triagem (por exemplo, Wall et al., 2012; Ahmed et al., 2022; Jaradat et al., 2025; Meng et al., 2023; Megerian et al., 2022), com menor número em abordagens que se aproximam de monitoramento/estratificação de risco e intervenções tecnológicas.

Tabela 4 – Domínios de aplicação de IA em TEA (nas 31 referências)

Domínio	N Estudos	%	Exemplos de técnicas	Estágio de validação
<i>Diagnóstico/Triagem</i>	14	45%	Eye-tracking, análise de vídeo, neuroimagem	Prova de conceito
<i>Intervenção terapêutica</i>	10	32%	Robótica, tutores/sistemas digitais, tecnologias assistivas	Prova de conceito
<i>Pesquisa básica/Exploratória</i>	4	13%	Conectividade cerebral, genômica (sínteses)	Exploratória
<i>Prognóstico/Monitoramento</i>	3	10%	ML em dados clínicos/biomarcadores; estratificação de risco	Muito precoce

Fonte: Elaborado pelo autor.

Quanto às modalidades de dados utilizadas para treinamento e validação dos algoritmos, nota-se transição metodológica ao longo do tempo, com crescente uso de dados não estruturados (por exemplo, vídeo e sinais complexos), acompanhando a expansão de métodos de deep learning (LECUN; BENGIO; HINTON, 2015). Para manter consistência com a diversidade de fontes, a Tabela 5 sumariza modalidades de dados descritas nos estudos incluídos, resultado ilustrado pela Figura 2.

Nota: as modalidades da Tabela 5 **não são mutuamente exclusivas**; um mesmo estudo pode empregar mais de uma fonte de dados (ex.: multimodal), de modo que as frequências podem ultrapassar o total de 31 referências.

Tabela 5 – Distribuição das modalidades de dados nos estudos incluídos

Modalidade de Dado	Frequência (n)	Estudos representativos (entre as 31 referências)
Comportamento em vídeo	8	Ahmed et al. (2022); Megerian et al. (2022)
Questionários/Escalas (tabulares)	7	Wall et al. (2012); Megerian et al. (2022)
Neuroimagem (MRI/fMRI)	6	Moon et al. (2019)
Rastreamento Ocular (eye-tracking)	5	Jaradat et al. (2025); Wei et al. (2023); Meng et al. (2023)
Multimodal (2+ fontes)	5	Megerian et al. (2022); Pandya et al. (2024)

Fonte: Elaborado pelo autor.

A análise do corpus evidencia diversidade de técnicas de IA, com predominância de métodos de machine learning clássico e deep learning, frequentemente combinados a visão computacional, rastreamento ocular e soluções digitais multimodais (PANDYA et al., 2024; SOLEK et al., 2025; ZHANG, 2025).




Figura 2 - Tipos de técnicas de IA mais frequentes entre os estudos incluídos.

5.2 Inteligência Artificial em Diagnóstico e Triagem de TEA

5.2.1 Visão Geral e Relevância Clínica

O diagnóstico de TEA permanece um desafio clínico devido à sua natureza comportamental e à necessidade de instrumentos e expertise especializados. Nesse cenário, a literatura analisada investiga se algoritmos podem oferecer desempenho comparável a avaliações clínicas em contextos específicos, com potencial para reduzir filas e apoiar decisões clínicas, desde que integrados como ferramenta complementar (CHADDAD et al., 2021; SOLEK et al., 2025; ZHANG, 2025).

5.2.2 Biomarcadores Digitais: Rastreamento Ocular e Análise de Vídeo

O uso de eye-tracking emerge como abordagem promissora para detectar padrões de atenção social atípica. Jaradat et al. (2025), por exemplo, aplicaram técnicas baseadas em redes neurais e reportaram desempenho elevado em amostra pediátrica; os valores específicos descritos no manuscrito (sensibilidade, especificidade e AUC) devem ser mantidos apenas se estiverem consistentes com a extração final do estudo.

Esses achados são coerentes com evidência sintetizada em revisão sistemática e meta-análise focada em eye-tracking e IA, que descreve desempenho agregado favorável, porém com heterogeneidade relevante entre protocolos, estímulos e populações (WEI et al., 2023). Apesar da objetividade potencial, barreiras de implementação incluem custo de equipamentos e padronização operacional, o que pode limitar a aplicabilidade em larga escala. Paralelamente, a análise automatizada de vídeo via deep learning oferece alternativa de maior acessibilidade logística, especialmente quando baseada em registros comportamentais. Estudos incluídos nesta revisão apontam desempenho promissor em cenários de prova de conceito (por exemplo, Ahmed et al., 2022; Megerian et al., 2022), mas revisões e overviews destacam heterogeneidade metodológica relevante (variações de amostra, métricas, protocolos e validação externa), recomendando cautela na comparação direta de acurácias reportadas (CHADDAD et al., 2021; SOLEK et al., 2025; PANDYA et al., 2024; ZHANG, 2025).

5.2.3 Neuroimagem e Dados Tabulares

Na neuroimagem, a evidência sintetizada indica que algoritmos aplicados a MRI/fMRI podem alcançar desempenho moderado a alto em amostras de pesquisa, embora com limitações práticas para triagem populacional pediátrica e

custo/complexidade operacional (MOON et al., 2019). Em contrapartida, modelos baseados em dados tabulares oriundos de questionários e escalas apresentam vantagens em interpretabilidade e custo computacional. O estudo seminal de Wall et al. (2012), com abordagem de redução/compressão de instrumentos estruturados, ilustra a possibilidade de apoiar triagens com modelos mais transparentes, permitindo discutir quais variáveis influenciam a classificação de risco, aspecto relevante para aceitação clínica.

5.2.4 Síntese de Desempenho e Limitações

A Tabela 6 sintetiza, de forma comparativa, o desempenho por modalidade diagnóstica quando reportado nas referências incluídas. Para evitar inferências numéricas indevidas, as métricas comparativas devem ser interpretadas como faixas reportadas na literatura e não como estimativas calculadas pelo autor, a menos que haja método explícito para isso.

Tabela 6 – Síntese comparativa (reportada) de desempenho de modelos de IA para diagnóstico/triagem de TEA

<i>Modalidade</i>	Evidência na amostra (entre 31)	Desempenho reportado (qualitativo/intervalos)	Fonte(s) principal(is)
<i>Eye-tracking</i>	Estudos e síntese secundária presentes	Em geral “alto”, com variação por protocolo população	Jaradat et al. (2025) Wei et al. (2023)
<i>Análise de vídeo / visão computacional</i>	Estudos originais e dispositivos multimodais	Desempenho promissor em prova de conceito, heterogêneo	Ahmed et al. (2022); Megerian et al. (2022); Pandya et al. (2024)
<i>Neuroimagem (MRI/fMRI)</i>	Síntese com meta-análise	Desempenho moderado–alto em amostras de pesquisa, heterogêneo	Moon et al. (2019)
<i>ML clássico (questionários/escala)</i>	Estudo seminal + abordagens correlatas	Interpretável, custo baixo, desempenho geralmente menor que vídeo	Wall et al. (2012); Megerian et al. (2022)
<i>Canvas Dx (dispositivo comercial)</i>	Avaliação publicada em periódico	Evidência depende do desenho e validação reportados no estudo	Megerian et al. (2022)

Fonte: Elaborado pelo autor.

Análise crítica das limitações (com base nas 31 referências):

1. **Validação externa e generalização:** revisões e overviews ressaltam que muitos estudos permanecem em prova de conceito, com validação limitada a amostras específicas e/ou procedimentos internos; a falta de padronização e de validação em contextos diversos aumenta o risco de superestimação de desempenho e reduz aplicabilidade imediata (CHADDAD et al., 2021; PANDYA et al., 2024; SOLEK et al., 2025; ZHANG, 2025).
2. **Viés demográfico e representatividade:** a literatura sintetizada destaca risco de desempenho desigual por subgrupos quando amostras de treinamento são homogêneas, o que pode comprometer sensibilidade em perfis sub-representados, com implicações éticas e clínicas (WHO, 2021; PANDYA et al., 2024).
3. **Custo-efetividade e adoção:** revisões apontam lacunas frequentes em análises de custo-efetividade e em avaliação pragmática de implementação clínica, especialmente em sistemas universais (PANDYA et al., 2024; WANKHEDE et al., 2024).

Conclui-se que, embora a IA apresente potencial como ferramenta de apoio ao diagnóstico e triagem, a aplicação clínica deve ser encarada com cautela, como suporte à decisão e não substituto do julgamento clínico, até que evidências de validação, governança e impacto real sejam mais consistentes.

5.3 Inteligência Artificial em Prognóstico e Monitoramento

5.3.1 Definição e Estado da Arte

O uso de IA para prognóstico/monitoramento no TEA envolve a previsão de trajetórias de desenvolvimento, estratificação de risco e acompanhamento de evolução sintomatológica e resposta a intervenções. A premissa é integrar variáveis heterogêneas para detectar padrões preditivos sutis. Na amostra desta revisão, o domínio de Prognóstico/Monitoramento é menos frequente (Tabela 4), refletindo campo ainda incipiente e metodologicamente heterogêneo. As referências incluídas abordam principalmente: modelos de risco/estratificação com dados clínicos e biomarcadores e discussão secundária sobre limitações de generalização e padronização de desfechos (BAHADO-SINGH et al., 2019; RAHMAN et al., 2020; PANDYA et al., 2024; WANKHEDE et al., 2024).

5.3.2 Referências no domínio prognóstico/monitoramento e preditores

No eixo de estratificação de risco, a Tabela 7 lista as abordagens com dados clínicos e aprendizado de máquina foram exploradas para identificar perfis de maior risco em fases precoces (RAHMAN et al., 2020). Em paralelo, análises de marcadores biológicos/epigenômicos neonatais com técnicas de IA foram investigadas como rota para detecção de risco (BAHADO-SINGH et al., 2019). Revisões/overviews recentes discutem potencial e limitações recorrentes, com ênfase em generalização, validação externa e padronização de desfechos (PANDYA et al., 2024; WANKHEDE et al., 2024).

Tabela 7 – Síntese (nas 31 referências) de evidências em prognóstico/monitoramento no TEA

Referências	Tipo	Foco	Métrica/Resultado reportado
<i>Bahado-Singh et al. (2019)</i>	Original	Biomarcadores epigenômicos neonatais e IA para risco	Evidência heterogênea; necessidade de padronização
<i>Rahman et al. (2020)</i>	Original	EHR/EMR + ML para risco precoce	Evidência heterogênea; necessidade de padronização
<i>Pandya et al. (2024) / Wankhede et al. (2024)</i>	Revisão/ Overview	Síntese do estado da arte e limitações	Evidência heterogênea; necessidade de padronização validação

Fonte: Elaborado pelo autor.

5.3.3 Desafios técnicos e clínicos

A análise crítica do domínio aponta limitações que dificultam aplicação clínica imediata:

1. **Heterogeneidade fenotípica:** trajetórias de desenvolvimento variam substancialmente, afetando estabilidade de modelos.
2. **Padronização de desfechos e validação externa:** revisões destacam ausência de padronização e dificuldades de generalização entre contextos, com necessidade de validações em coortes independentes (PANDYA et al., 2024; WANKHEDE et al., 2024).

3. **Fatores de confundimento ambientais/intervenções concomitantes:** variáveis como terapias e contexto escolar modulam trajetórias e frequentemente não são controladas de modo uniforme.

5.4 Inteligência Artificial em Intervenções Terapêuticas

5.4.1 Visão geral das intervenções nas referências incluídas

A aplicação de tecnologias e IA no campo terapêutico/educacional do TEA aparece na amostra em diferentes formatos, incluindo revisões e meta-análises de robótica social e tecnologias assistivas, além de estudos sobre intervenções digitais/educacionais e frameworks de implementação (HUIJNEN et al., 2016; JALIAAWALA & KHAN, 2020; KOUROUPA et al., 2022; PUGLISI et al., 2022; VAGNETTI et al., 2024; CAÑETE & PERALTA, 2022; LAMPOS et al., 2021; KOTSI et al., 2025; GOSH et al., 2021; SOHL et al., 2022). Em termos práticos, as intervenções analisadas podem ser discutidas em eixos: (I) robótica social e interação humano-robô (majoritariamente em sínteses secundárias), (II) tecnologias educacionais e adaptação de conteúdo (estudos em ambientes de aprendizagem), (III) tecnologias assistivas e suporte digital, e (IV) modelos de implementação/integração em serviços.

5.4.2 Robótica social e interação humano-robô

A literatura incluída descreve robôs sociais como ferramentas para treino de habilidades sociais e comunicação, com potencial de engajamento em ambientes estruturados. Revisões e meta-análises destacam benefícios potenciais, porém enfatizam heterogeneidade de protocolos, amostras e desfechos, além de limitações de validade ecológica e escalabilidade (HUIJNEN et al., 2016; KOUROUPA et al., 2022; PUGLISI et al., 2022; VAGNETTI et al., 2024). No conjunto analisado, a evidência permanece mais consistente como **prova de conceito**, com necessidade de estudos pragmáticos e de avaliação de custo, sustentabilidade e integração em rotinas clínicas/educacionais, especialmente em sistemas públicos.

5.4.3 Tecnologias educacionais, suporte digital e gamificação/engajamento

Soluções digitais voltadas ao suporte educacional e ao desenvolvimento de habilidades aparecem como alternativas com maior potencial de escalabilidade. Estudos e revisões incluídos discutem uso de ferramentas digitais para personalização de

estratégias de comunicação e aprendizagem (LAMPOS et al., 2021; KOTSI et al., 2025), além de revisões que agregam evidências sobre tecnologias assistivas e intervenções mediadas por sistemas inteligentes (JALIAAWALA & KHAN, 2020; GOSH et al., 2021; CAÑETE & PERALTA, 2022). A literatura ressalta como vantagem prática a possibilidade de ampliar acesso e padronizar componentes de intervenção, mas reforça limitações: variação de protocolos, medidas de resultado não uniformes e lacunas em avaliação longitudinal.

5.4.4 Síntese de eficácia e comparação com terapias padrão

Com base nas referências incluídas, a evidência de eficácia de intervenções mediadas por tecnologia/IA é descrita como heterogênea, com resultados promissores em cenários controlados, mas insuficientemente consolidada para afirmar superioridade em relação a terapias comportamentais padrão. Meta-análises e revisões enfatizam que comparações diretas são dificultadas por diversidade de desfechos e desenhos, além de possível viés de publicação e baixa padronização (KOUROUPA et al., 2022; PUGLISI et al., 2022; VAGNETTI et al., 2024; JALIAAWALA & KHAN, 2020). Esses dados estão listados na Tabela 8.

Tabela 8 – Síntese qualitativa de evidência em intervenções tecnológicas/IA para TEA (nas 31 referências)

Modalidade	Evidência na amostra	Principais mensagens das referências incluídas	Referências (exemplos)
<i>Robótica social</i>	Revisões e meta-análises	Potencial benefício em habilidades sociais; alta heterogeneidade; necessidade de estudos pragmáticos	Huijnen et al. (2016); Kouroupa et al. (2022); Puglisi et al. (2022); Vagnetti et al. (2024)
<i>Tecnologias educacionais/ adaptativas</i>	Estudos e revisões	Personalização e escalabilidade; limitações de desfechos e follow-up	Lamos et al. (2021); Kotsi et al. (2025); Jaliaawala & Khan (2020)
<i>Tecnologias assistivas e suporte digital</i>	Revisões	Potencial para ampliar acesso e engajamento;	Cañete & Peralta (2022); Ghosh et al. (2021)

		lacunas em padronização e implementação	
Implementação/ integração	Protocolos e revisões	Necessidade de governança, treinamento e integração a fluxos	Sohl et al. (2022); WHO (2021)

Fonte: Elaborado pelo autor.

5.5Tendências Tecnológicas e Evolução Temporal

5.5.1 Transição metodológica: do ML clássico ao deep learning

A análise cronológica das referências incluídas sugere transformação nas técnicas empregadas, acompanhando mudanças na disponibilidade e natureza dos dados. No período inicial (2012–2015), observou-se predominância de métodos clássicos em dados tabulares, com foco em interpretabilidade e seleção de variáveis (WALL et al., 2012). Entre 2016 e 2019, as sínteses em neuroimagem e IA já documentam expansão de abordagens mais complexas e pipelines diversificados em MRI/fMRI (MOON et al., 2019). O período recente (2020–2025) marca consolidação de deep learning em modalidades como rastreamento ocular e visão computacional, além de aumento de soluções digitais e discussões sobre governança e translação clínica (WEI et al., 2023; PANDYA et al., 2024; SOLEK et al., 2025; ZHANG, 2025). Embora métodos complexos possam elevar desempenho em certos cenários, frequentemente introduzem trade-off com explicabilidade, tópico recorrente nas discussões éticas e de confiança clínica (WHO, 2021).

5.5.2 Integração multimodal emergente

A fronteira recente destaca crescente interesse por sistemas multimodais, integrando diferentes fontes de dados para capturar complexidade fenotípica do TEA. Um exemplo relevante no corpus é a avaliação de abordagem/dispositivo que combina múltiplas entradas digitais (MEGERIAN et al., 2022), e revisões/overviews discutem multimodalidade como tendência para aumentar robustez e reduzir dependência de uma única modalidade (PANDYA et al., 2024; ZHANG, 2025). Contudo, desafios técnicos persistem, como heterogeneidade de escalas, sincronização e risco aumentado de overfitting quando a dimensionalidade cresce mais rápido que o tamanho amostral — o que reforça a necessidade de validação externa e padronização.

5.6 Síntese Transversal de Barreiras para Implementação Clínica

A análise crítica das referências incluídas permite estruturar um framework de barreiras que dificultam a translação dessas tecnologias para a prática clínica, categorizadas em níveis metodológicos, operacionais e éticos, com implicações diretas para o contexto brasileiro e para instituições públicas.

5.6.1 Barreiras metodológicas críticas

- **Amostras e generalização:** revisões/overviews destacam que muitos estudos permanecem em prova de conceito, com amostras limitadas e validação predominantemente interna, reduzindo generalização (CHADDAD et al., 2021; PANDYA et al., 2024; SOLEK et al., 2025).
- **Heterogeneidade e falta de padronização:** variações em algoritmos, dados e desfechos dificultam síntese quantitativa robusta e replicação (MOON et al., 2019; WEI et al., 2023; PANDYA et al., 2024).
- **Validação externa prospectiva:** permanece uma lacuna recorrente discutida nas sínteses secundárias, com recomendação de validações em coortes independentes e contextos reais antes de adoção institucional ampla (PANDYA et al., 2024; WANKHEDE et al., 2024).

5.6.2 Barreiras clínicas e operacionais

- **Integração em fluxos assistenciais:** a distância entre protocolos de pesquisa e a realidade clínica requer co-desenho de implementação, treinamento e manejo de discordâncias com avaliação clínica (SOHL et al., 2022; WHO, 2021).
- **Infraestrutura e capacitação:** limitações de conectividade, hardware e letramento em IA são barreiras especialmente relevantes em contextos públicos, com impacto na adoção segura.
- **Avaliação pragmática e custo-efetividade:** frequentemente ausentes ou pouco detalhadas nas evidências sintetizadas, dificultando decisões de incorporação.

5.6.3 Barreiras éticas e de governança

- **Privacidade e proteção de dados:** dados usados em IA (vídeo, voz, neuroimagem) são sensíveis e requerem governança robusta; diretrizes internacionais ressaltam transparência, proteção e responsabilização (WHO, 2021).

- **Viés algorítmico e equidade:** revisões alertam para risco de amplificação de desigualdades quando modelos são treinados em populações pouco representativas (WHO, 2021; PANDYA et al., 2024).
- **Explicabilidade e responsabilidade profissional:** permanece o dilema entre desempenho e interpretabilidade, com implicações para confiança clínica e responsabilidade (WHO, 2021).

5.6.4 Barreiras de equidade e acesso

A literatura incluída reforça o paradoxo de democratização: embora IA possa ampliar acesso, custos, infraestrutura e licenciamento podem restringir benefícios a centros de maior renda, ampliando o “fosso digital”. A lacuna de evidências locais (apenas um preprint brasileiro no corpus) destaca necessidade de desenvolvimento e validação adaptados ao contexto nacional (DO CARMO, 2025; WANKHEDE et al., 2024).

5.6.5 Síntese integrativa: estrutura de ação

A Tabela 9 consolida barreiras e propõe ações mitigadoras orientadas ao contexto de um hospital universitário brasileiro.

5.7 Síntese Final: Estado da Arte e Recomendações Institucionais

A análise global do corpus indica que a IA aplicada ao TEA atingiu estágio de prova de conceito em múltiplos domínios (diagnóstico/triagem, intervenções e prognóstico/monitoramento), com desempenho promissor em ambientes de pesquisa e em sínteses secundárias, mas com aplicabilidade clínica ainda condicionada por lacunas metodológicas e de governança (CHADDAD et al., 2021; PANDYA et al., 2024; SOLEK et al., 2025; WHO, 2021; WANKHEDE et al., 2024). Esta síntese é apresentada na Tabela 9.

Tabela 9 – Síntese estruturada de barreiras e recomendações para implementação clínica de IA em TEA

<i>Nível</i>	Barreira específica	Evidência nas 31 referências	Impacto estimado	Ação recomendada
--------------	----------------------------	-------------------------------------	-------------------------	-------------------------

			(HCU-UFU)	
<i>Metodológica</i>	Amostras limitadas/heterogêneas	Revisões destacam prova de conceito e heterogeneidade	Alto	Estudos locais e validação externa
	Falta de validação externa	Lacuna recorrente em sínteses secundárias	Alto	Exigir validação prospectiva antes de adoção
<i>Operacional</i>	Custo-efetividade pouco descrita	Lacuna discutida em revisões	Alto	Pilotos pragmáticos com avaliação de impacto
	Integração em fluxo clínico	Necessidade de governança e co-design	Alto	Co-design com equipes e protocolos de uso
	Infraestrutura e formação	Relevante para adoção segura	Alto	Capacitação e suporte institucional
<i>Ética</i>	Viés e privacidade	Diretrizes e revisões alertam para riscos	Alto	Auditoria de viés + governança de dados
	Responsabilidade e explicabilidade	Diretrizes enfatizam transparência e accountability	Moderado/Alto	Protocolos de responsabilidade + preferência por modelos explicáveis quando possível
<i>Equidade</i>	Amplificação de desigualdades	Discussão recorrente em sínteses/diretrizes	Alto	Implementação orientada à equidade
	Ausência de modelos locais	Pouca evidência latino-americana	Alto	Fomento a modelos treinados/validados no Brasil

Fonte: Elaborado pelo autor.

Persistem lacunas críticas, notadamente:

- (1) necessidade de validação externa e pragmática em contextos reais;
- (2) representatividade insuficiente e risco de vieses;
- (3) governança ética incipiente (privacidade, explicabilidade, responsabilidade); e

(4) carência de evidência e desenvolvimento adaptados ao contexto brasileiro/SUS (DO CARMO, 2025).

Recomendações estratégicas para o HCU-UFU

À luz dos achados desta revisão e do contexto de um hospital universitário inserido no Sistema Único de Saúde (SUS), recomenda-se que eventuais iniciativas envolvendo Inteligência Artificial aplicada ao TEA sejam conduzidas de forma gradual, supervisionada e focada em apoio à triagem e organização do cuidado, sem substituição da avaliação clínica especializada.

Eixo 1 – Governança clínica e institucional

Propõe-se a criação de um núcleo interdisciplinar de IA em TEA, envolvendo representantes da assistência, pesquisa, tecnologia da informação e jurídico/ética. Esse núcleo deve: (i) definir prioridades clínicas e de pesquisa; (ii) delimitar o escopo de uso das ferramentas (apoio à triagem e à estratificação de risco, não diagnóstico autônomo); e (iii) explicitar responsabilidades profissionais, incluindo critérios objetivos para suspensão, manutenção ou expansão de qualquer solução em uso.

Eixo 2 – Ética, LGPD e proteção de dados sensíveis

Antes da implementação de qualquer ferramenta, é indispensável estabelecer normas internas específicas para o tratamento de dados sensíveis, em especial imagens, vídeos e registros de voz de crianças e suas famílias. Essas normas devem contemplar princípios de minimização de coleta, base legal adequada, consentimento informado quando aplicável, controle de acesso, políticas de armazenamento e retenção, bem como trilhas de auditoria que permitam rastrear quem acessou quais dados e com qual finalidade. A adoção de novas soluções deve ser condicionada à conformidade com esses requisitos e à existência de um fluxo claro de governança de dados.

Eixo 3 – Viabilidade técnica e integração ao cuidado

Qualquer projeto piloto deve ser precedido por análise de viabilidade técnica, incluindo avaliação de conectividade, equipamentos, suporte de TI e carga de trabalho das equipes. A ferramenta precisa ser integrada ao fluxo assistencial real, evitando etapas redundantes ou barreiras adicionais ao atendimento. Também é necessário definir

previamente como os resultados gerados pela IA serão registrados em prontuário e como será manejada a situação em que houver divergência entre a saída do sistema e o juízo clínico da equipe, preservando a primazia da avaliação profissional.

Eixo 4 – Evidência local e monitoramento contínuo

Recomenda-se que o HCU-UFU adote inicialmente projetos piloto de caráter pragmático, com avaliação em cenário de prática real, antes de qualquer incorporação rotineira. Esses pilotos devem ter métricas claramente definidas, incluindo aceitabilidade por profissionais e famílias, impacto no tempo de atendimento e no fluxo de trabalho, frequência de falhas técnicas, discordâncias entre sistema e clínicos e, quando possível, desempenho por subgrupos (sexo, faixa etária, escolaridade dos responsáveis, entre outros) para identificação de vieses. A continuidade ou escalonamento da ferramenta deve depender de resultados documentados e revisados periodicamente.

Eixo 5 – Sustentabilidade e custos

Desde a fase de planejamento, é necessário estimar custos diretos (licenças, equipamentos, suporte técnico) e indiretos (tempo de capacitação, supervisão, manutenção) associados ao uso de IA em TEA. Devem ser exploradas estratégias de sustentabilidade compatíveis com o contexto público, como projetos de pesquisa financiados, parcerias acadêmicas e pilotos de duração definida, evitando dependência de soluções que exijam infraestrutura ou despesas recorrentes incompatíveis com a realidade orçamentária do serviço.

Observação final: Na ausência de estrutura mínima de governança, diretrizes claras para proteção de dados sensíveis e evidência local obtida em estudos pragmáticos conduzidos no próprio serviço, não se recomenda a adoção rotineira de ferramentas de IA para TEA no HCU-UFU.

6. DISCUSSÃO

A presente revisão integrativa analisou o panorama da Inteligência Artificial (IA) aplicada ao Transtorno do Espectro Autista (TEA) a partir das 31 referências incluídas, buscando interpretar a robustez das evidências, suas limitações e a viabilidade de translação para a prática clínica. A discussão a seguir integra os achados por domínios (diagnóstico/triagem, intervenções terapêuticas, prognóstico/monitoramento e pesquisa

básica) e enfatiza os principais obstáculos metodológicos, operacionais e éticos que ainda separam o desempenho em ambientes de pesquisa da adoção segura em serviços reais, com foco no contexto do Hospital de Clínicas da Universidade Federal de Uberlândia (HCU-UFU).

6.1 Síntese dos achados principais e resposta aos objetivos

6.1.1 Panorama geral da literatura identificada

O conjunto de 31 referências (08 estudos originais e 23 documentos secundários/normativos, incluindo revisões, meta-análises, protocolos e diretrizes) indica um campo em expansão e em consolidação recente. A concentração temporal é predominantemente recente, com cerca de dois terços das referências publicadas entre 2020 e 2025, refletindo a aceleração de aplicações em saúde associada ao amadurecimento do deep learning e ao aumento de dados digitais disponíveis. A distribuição por domínios mostra predominância de diagnóstico/triagem (45%), seguida por intervenções terapêuticas (32%), pesquisa básica/abordagens exploratórias (13%) e prognóstico/monitoramento (10%). Esse padrão sugere que a prioridade do campo tem sido reduzir barreiras ao diagnóstico e apoiar a triagem, enquanto aplicações preditivas longitudinais e estratégias de monitoramento permanecem menos desenvolvidas e menos padronizadas.

6.1.2 Diagnóstico e triagem: desempenho e significado clínico

O objetivo central da revisão foi compreender como a IA tem sido aplicada ao diagnóstico/triagem do TEA e quais limitações condicionam sua aplicabilidade clínica. As evidências incluídas apontam resultados promissores em modalidades como rastreamento ocular (eye-tracking), análise de vídeo/imagem e abordagens digitais multimodais, além de modelos baseados em dados tabulares derivados de questionários e instrumentos estruturados.

Apesar do caráter promissor, a leitura integrada das revisões e meta-análises incluídas reforça que os desempenhos relatados variam substancialmente entre estudos e dependem de fatores como protocolo de coleta, qualidade do dado, definição de desfechos, composição amostral e procedimentos de validação. Isso limita comparações diretas e recomenda cautela ao extrapolar métricas de desempenho para ambientes clínicos com maior variabilidade. Em particular, a literatura enfatiza que muitos estudos permanecem

em prova de conceito e frequentemente utilizam validação interna, com menor número de avaliações em populações externas independentes, o que compromete a estimativa real de generalização.

Do ponto de vista clínico-operacional, observa-se um trade-off recorrente. Modalidades como vídeo e outros dados não estruturados podem oferecer maior capacidade discriminativa em contextos controlados, mas tendem a reduzir interpretabilidade e aumentar dependência de condições ambientais. Em contrapartida, abordagens baseadas em dados tabulares e modelos mais transparentes favorecem interpretabilidade e integração ao raciocínio clínico, embora possam apresentar desempenho mais sensível à qualidade do instrumento e às características da amostra. Para um serviço como no domínio das intervenções, as referências incluídas abrangem principalmente sínteses e avaliações críticas de robótica social, tecnologias assistivas e soluções digitais aplicadas a educação/treino de habilidades e suporte ao cuidado. As revisões e meta-análises apontam benefícios potenciais, especialmente em desfechos funcionais e de engajamento, mas também destacam heterogeneidade metodológica importante: diversidade de protocolos, desfechos não uniformes, amostras pequenas em muitos estudos e limitações de acompanhamento longitudinal o HCU-UFG, a relevância prática não é apenas maximizar desempenho, mas selecionar ferramentas cuja lógica de uso, governança e rastreabilidade sejam compatíveis com rotinas assistenciais, treinamento da equipe e padrões de responsabilidade profissional.

6.1.3 Intervenções terapêuticas mediadas por tecnologia/IA

A interpretação mais consistente do corpus é que essas intervenções se situam, em grande parte, em fase de prova de conceito ou de evidência moderada, com potencial como complemento a intervenções tradicionais e como alternativa para ampliar acesso e padronizar componentes terapêuticos/educacionais. O valor agregado mais evidente, à luz das referências incluídas, está na escalabilidade e na capacidade de ampliar oportunidades de treino e suporte, mais do que em demonstrar superioridade clínica inequívoca frente a terapias padrão.

6.1.4 Prognóstico e monitoramento: lacuna crítica

O domínio de prognóstico/monitoramento é o menos representado no conjunto incluído e aparece associado a abordagens com dados clínicos e biomarcadores, além de

discussões secundárias sobre potencial e limitações. A baixa frequência de estudos e a heterogeneidade de desfechos sugerem que a aplicação preditiva longitudinal ainda está em estágio inicial. Essa lacuna é clinicamente relevante, porque prognóstico e monitoramento são justamente os eixos que poderiam viabilizar estratificação de risco, personalização de intensidade terapêutica e alocação mais eficiente de recursos, especialmente em sistemas com demanda elevada e oferta limitada.

6.2 Interpretação crítica: estado da arte versus aplicabilidade clínica

6.2.1 O paradoxo do desempenho técnico e o hiato translacional

Um dos principais achados interpretativos desta revisão é o contraste entre resultados promissores em ambientes de pesquisa e a dificuldade de translação para serviços clínicos reais. Esse hiato pode ser compreendido por um conjunto de barreiras que emergem de forma recorrente nas revisões e diretrizes incluídas.

Primeiro, persistem limitações metodológicas na validação e na generalização. A predominância de validações internas, a variabilidade de protocolos e a insuficiente avaliação em cortes externas independentes reduzem a confiança de que o desempenho observado será replicado em populações com perfis diferentes, comorbidades, contextos socioculturais distintos e qualidade de dados mais variável.

Segundo, há discrepância entre o ambiente controlado de pesquisa e a realidade assistencial. Serviços clínicos lidam com dados incompletos, variações na qualidade de registros e limitações de tempo e infraestrutura. Modalidades baseadas em vídeo, voz e outras fontes sensíveis a ruído ambiental podem sofrer degradação de desempenho fora de condições idealizadas, o que exige estratégias de padronização operacional e monitoramento contínuo.

Terceiro, a base econômica para incorporação ainda é frágil. A ausência ou escassez de avaliações pragmáticas e análises de custo-efetividade dificulta decisões de incorporação em sistemas públicos, nos quais investimentos precisam ser justificados por impactos mensuráveis em acesso, tempo de espera, desfechos e custos do cuidado.

Quarto, barreiras éticas e regulatórias são centrais. Diretrizes internacionais enfatizam governança de dados, transparência, mitigação de vieses e responsabilização. Sem clareza sobre como dados sensíveis são coletados, armazenados e utilizados, e sem mecanismos de auditoria de desempenho por subgrupos, aumenta-se o risco de ampliar desigualdades e de introduzir insegurança jurídica e clínica.

6.2.2 Evolução tecnológica e o trade-off entre desempenho e explicabilidade

A evolução temporal das referências incluídas sugere migração de métodos clássicos de machine learning, frequentemente aplicados a dados tabulares e instrumentos estruturados, para abordagens de deep learning mais adequadas a dados não estruturados e multimodais. Essa transição tem implicações práticas: enquanto modelos clássicos podem favorecer interpretabilidade e comunicação clínica, abordagens profundas tendem a operar como sistemas menos transparentes, com maior complexidade e maior dependência de infraestrutura e padronização.

Para o contexto do HCU-UFU, a discussão não se resume a escolher o modelo de maior desempenho. A adoção responsável exige considerar explicabilidade prática, rastreabilidade da decisão, governança institucional e capacidade da equipe em interpretar saídas probabilísticas, além de definir claramente o papel dessas ferramentas como suporte à decisão, e não substituição do julgamento clínico.

6.3 Literatura internacional e contexto brasileiro

A literatura analisada é majoritariamente oriunda de países de alta renda, com concentração em centros acadêmicos e de pesquisa. Isso reforça o risco de vieses de representatividade e limita a generalização para sistemas universais, em especial quando há diferenças de infraestrutura, determinantes sociais de saúde, acesso a serviços especializados e diversidade étnico-socioeconômica.

6.4 Implicações e desafios de implementação no HCU-UFU

A transposição dos achados para o HCU-UFU envolve desafios que vão além da performance algorítmica. Lista-se:

- **Infraestrutura e interoperabilidade:** a implementação de ferramentas digitais requer integração com sistemas de prontuário, fluxos de triagem e rotinas de registro. Sem interoperabilidade, soluções tendem a virar etapas adicionais e pouco sustentáveis no processo assistencial.
- **Letramento e adesão clínica:** a adoção depende de treinamento para interpretar saídas probabilísticas, definir condutas diante de resultados discordantes e comunicar limitações e incertezas às famílias. Isso exige protocolos claros e alinhamento com práticas de responsabilidade profissional.

- Governança de dados e conformidade: como as modalidades frequentemente envolvem dados sensíveis (especialmente vídeo e voz), a instituição precisa de políticas de governança, segurança e auditoria, incluindo definição de papéis, consentimento, armazenamento, acesso, rastreabilidade e revisão periódica de desempenho por subgrupos.
- Sustentabilidade: a manutenção de licenças, atualização de software, suporte técnico, calibração operacional e monitoramento contínuo precisam de um modelo de financiamento e gestão. Em ambiente público, parcerias, projetos-piloto e ciência da implementação podem ser estratégias mais realistas do que aquisição imediata de soluções complexas.

6.5 Limitações do presente estudo

As conclusões desta revisão devem ser interpretadas considerando limitações inerentes ao desenho e ao estado atual da literatura. Limitações de busca e representatividade: a estratégia de busca e o recorte linguístico podem ter deixado de fora contribuições relevantes publicadas em outros idiomas. Além disso, o conjunto incluído reflete a distribuição internacional da produção, com baixa representatividade de estudos validados em contextos de baixa e média renda.

Mistura de tipos de referência: a amostra incluiu estudos originais e referências secundárias/normativas. Isso é útil para contextualização e para discutir governança e padrões de relato, mas aumenta heterogeneidade e limita a possibilidade de síntese quantitativa uniforme.

Evidência pragmática limitada: a literatura incluída ainda traz poucos estudos com desenhos pragmáticos e validações externas em serviços reais, o que restringe inferências diretas sobre impacto assistencial, custo-efetividade e escalabilidade.

Avaliação formal de risco de viés: embora barreiras metodológicas tenham sido discutidas, não foi aplicada uma ferramenta padronizada de risco de viés a cada estudo individual, o que limita a estratificação das conclusões por qualidade metodológica intrínseca de cada trabalho.

6.6 Perspectivas futuras e agenda de pesquisa

A leitura das lacunas permite delinear prioridades realistas para reduzir o hiato translacional e tornar a IA clinicamente útil e eticamente segura no cuidado ao TEA.

Prioridades imediatas: validação externa e pragmática em contextos reais, com métricas estratificadas por subgrupos demográficos e clínicos; padronização mínima de protocolos e desfechos para permitir comparabilidade; e construção de modelos de governança de dados e auditoria de vieses em instituições que pretendam adotar essas tecnologias.

Prioridades de médio prazo: desenvolvimento e validação de modelos adaptados ao contexto brasileiro e ao SUS, com foco em baixo custo e robustez operacional; avanço no domínio de prognóstico/monitoramento por meio de coortes longitudinais e definição de desfechos clínicos relevantes; e estudos de custo-efetividade e impacto orçamentário que apoiem decisões de incorporação.

Prioridades de longo prazo: integração multimodal com foco em subtipificação clinicamente relevante e medicina de precisão, desde que acompanhada de governança robusta, transparência e avaliação contínua; além de amadurecimento regulatório para softwares como dispositivo médico, com exigências explícitas de validação, auditoria de vieses e mecanismos de responsabilização.

6.7 Considerações finais

Esta revisão integrativa permitiu mapear o estado da arte da IA aplicada ao TEA nas 31 referências incluídas e identificar um campo em expansão, com aplicações promissoras sobretudo em diagnóstico/triagem e em intervenções digitais/assistivas. Ao mesmo tempo, a síntese crítica aponta que a principal barreira atual é translacional: a evidência ainda é, em grande parte, de prova de conceito, com heterogeneidade metodológica, validação externa limitada, lacunas de avaliação pragmática, insuficiência de evidência econômica e desafios éticos e de governança.

Para o HCU-UFU, a implicação prática é adotar um posicionamento de liderança cautelosa e estruturada. Em vez de implementar soluções como diagnóstico definitivo sem validação local independente, o caminho mais consistente é preparar governança, infraestrutura e capacitação, e conduzir projetos-piloto pragmáticos orientados à realidade assistencial, com auditoria de desempenho e de vieses. Nesse cenário, a contribuição mais estratégica do serviço pode ser participar ativamente da construção de evidência local e de fluxos de implementação responsáveis, ajudando a consolidar uma IA aplicável ao contexto brasileiro, com foco em equidade e em benefício clínico real. Em última análise, o impacto da IA no cuidado ao TEA dependerá menos do avanço tecnológico isolado e

mais da qualidade da validação, da governança e do compromisso com segurança, transparência e justiça distributiva.

7. CONCLUSÃO

A presente revisão integrativa, ao examinar o estado da arte da Inteligência Artificial (IA) aplicada ao Transtorno do Espectro Autista (TEA), fundamenta a constatação de uma mudança paradigmática estrutural na psiquiatria da infância e adolescência. A IA transcende, a condição de conjectura teórica futura para consolidar-se como instrumento de medicina de precisão em estágio avançado de validação, apresentando potencial disruptivo para mitigar gargalos históricos nos sistemas de saúde. Ao promover a transição de uma abordagem estritamente observacional e subjetiva para a identificação de padrões quantitativos — processo denominado "fenotipagem digital" —, a tecnologia oferece perspectivas concretas para o enfrentamento de desafios crônicos, notadamente o atraso diagnóstico, a sobrecarga dos especialistas e a carência de terapias personalizadas, particularmente em cenários de elevada demanda assistencial.

Em consonância com os objetivos delineados, a literatura analisada corrobora que a IA atingiu maturidade técnica e validade conceitual em ambientes controlados de pesquisa. No domínio do diagnóstico e triagem, algoritmos de *Deep Learning* e tecnologias de rastreamento ocular (*eye-tracking*) demonstram capacidade consistente na identificação de biomarcadores digitais sutis — a exemplo de microexpressões faciais atípicas ou padrões de fixação visual — com acurácia superior a 90%. Tais ferramentas possuem a capacidade de antecipar a janela de detecção para os primeiros anos de vida, período em que a neuroplasticidade proporciona as oportunidades de intervenção mais eficazes.

No âmbito das intervenções terapêuticas, a utilização de robótica social, gamificação (*jogos sérios*) e tutores adaptativos apresenta-se como via escalável para a estimulação de competências socioemocionais. Estas tecnologias distinguem-se pela capacidade de fornecer repetição consistente em ambientes isentos de julgamento, atuando de forma complementar à terapêutica clínica fundamental mediada por humanos. Por sua vez, o campo do prognóstico permanece incipiente, configurando-se como a fronteira subsequente de investigação: a capacidade de prever trajetórias individuais e respostas ao tratamento, viabilizando a transição de um modelo generalista para uma personalização terapêutica baseada em evidências de dados.

Não obstante, esta investigação identificou um hiato substancial — entre a eficácia *in silico* (em laboratório) e a efetividade *in vivo* (na prática clínica). A transposição dessas tecnologias para a complexa realidade do Sistema Único de Saúde (SUS) e do Hospital de Clínicas da Universidade Federal de Uberlândia (HCU-UFU) depara-se com barreiras significativas que transcendem a acurácia algorítmica. Ressaltam-se a ausência de validação externa em populações brasileiras, o que suscita incertezas quanto à generalização de modelos treinados predominantemente no Norte Global; a opacidade dos algoritmos do tipo "caixa preta", que dificultam a explicabilidade clínica indispensável à confiança médica; o custo elevado de dispositivos proprietários (como o *Canvas Dx*); e desafios éticos prementes relativos à privacidade de dados sensíveis pediátricos e ao risco de viés algorítmico, passível de perpetuar desigualdades raciais ou socioeconômicas.

A contribuição central deste estudo para o HCU-UFU/EBSERH fundamenta-se na premissa de que a incorporação da IA não deve ocorrer de forma passiva, tecnocêntrica ou acrítica. Preconiza-se uma postura institucional de liderança prudente e estratégica, alicerçada em três pilares fundamentais:

1. **Governança e Segurança:** A instituição de protocolos robustos que assegurem a proteção de dados (em estrita conformidade com a Lei Geral de Proteção de Dados - LGPD) e estabeleçam a premissa da supervisão humana mandatória ("human-in-the-loop"). A IA deve operar como ferramenta de suporte à decisão ou triagem, jamais como autoridade final no diagnóstico.
2. **Validação Local e Pesquisa Translacional:** A priorização de estudos piloto pragmáticos em ambiente ambulatorial, avaliando a aceitabilidade, a usabilidade e a acurácia real de ferramentas de triagem na população local, previamente a investimentos de larga escala. Torna-se imperativo o desenvolvimento e a validação de soluções adaptadas à realidade epidemiológica e infraestrutural da instituição.
3. **Equidade e Acesso:** O compromisso ético de utilizar a tecnologia como vetor de redução, e não de amplificação, das disparidades no acesso ao diagnóstico. A implementação deve objetivar a democratização do cuidado, permitindo que a IA atue como multiplicadora da capacidade de triagem na atenção primária, evitando sua caracterização como recurso de alta complexidade restrito a centros especializados.

Diante do exposto, a Inteligência Artificial desponta como aliada estratégica para a efetivação de um cuidado mais preditivo, preventivo e personalizado no TEA. O desafio para os anos vindouros não é exclusivamente tecnológico, mas eminentemente implementacional e ético: converter algoritmos de alta performance em práticas clínicas equitativas e humanizadas.

O objetivo último deve ser a liberação do profissional de saúde de tarefas repetitivas de triagem e análise de dados, permitindo a concentração de esforços no insubstituível: o acolhimento, o vínculo terapêutico e o julgamento clínico complexo, promovendo, em última análise, a qualidade de vida e o pleno desenvolvimento de crianças e adolescentes no espectro autista.

8. REFERÊNCIAS

1. ABBAS, H.; GARBARD, F.; GLOVER, E. et al. Machine learning approach for early detection of autism by combining questionnaire and home video screening. **Journal of the American Medical Informatics Association**, v. 25, n. 8, p. 1000-1007, 2018. DOI: 10.1093/jamia/ocy039.
2. AHMED, I. A.; SENAN, E. M.; RASSEM, T. H. et al. Eye tracking-based diagnosis and early detection of autism spectrum disorder using ML and DL techniques. **Electronics**, v. 11, n. 4, p. 530, 2022. DOI: 10.3390/electronics11040530. Disponível em: <https://doi.org/10.3390/electronics11040530>. Acesso em: 10 jan. 2026.
3. AMERICAN PSYCHIATRIC ASSOCIATION. **Diagnostic and Statistical Manual of Mental Disorders**. 5. ed. Text Revision (DSM-5-TR). Washington, DC: American Psychiatric Association, 2022. DOI: 10.1176/appi.books.9780890425787.
4. BAHADO-SINGH, R. O.; VISHWESWARAIAH, S.; AYDAS, B. et al. Artificial intelligence analysis of newborn leucocyte epigenomic markers for the prediction of autism. **Brain Research**, v. 1724, p. 146457, 2019. DOI: 10.1016/j.brainres.2019.146457. Disponível em: <https://doi.org/10.1016/j.brainres.2019.146457>. Acesso em: 10 jan. 2026.
5. BAI, D.; YIP, B. H. K.; WINDHAM, G. C. et al. Association of Genetic and Environmental Factors With Autism in a 5-Country Cohort. **JAMA Psychiatry**, v. 76, n. 10, p. 1035–1043, 2019. DOI: 10.1001/jamapsychiatry.2019.1411.
6. BONE, D.; LI, C. C.; BLACK, M. P.; NARAYANAN, S. S. The psychologist as an interlocutor in autism spectrum disorder assessment: Insights from a study of spontaneous prosody. **Journal of Speech, Language, and Hearing Research**, v. 57, n. 4, p. 1168-1181, 2014. DOI: 10.1044/2014_JSLHR-S-13-0062.
7. BOUCENNA, S.; NARZISI, A.; TILTON, E. et al. Interactive technologies for autistic children: A review. **Cognitive Computation**, v. 6, n. 4, p. 722-740, 2014. DOI: 10.1007/s12559-014-9276-x.

8. CAÑETE, R.; PERALTA, E. Assistive technology to improve collaboration in children with ASD: state-of-the-art and future challenges in the smart products sector. **Sensors (Basel)**, v. 22, n. 21, p. 8321, 2022. DOI: 10.3390/s22218321. Disponível em: <https://doi.org/10.3390/s22218321>. Acesso em: 10 jan. 2026.
9. CARPENTER, K. L. H.; HAIDAR, G.; MAJOR, S. et al. Computer Vision Analysis of Missed Social Attention in Autism Spectrum Disorder. **The American Journal of Psychiatry**, v. 178, n. 2, p. 166-175, 2021. DOI: 10.1176/appi.ajp.2020.19080838.
10. CHADDAD, A.; LI, J.; LU, Q. et al. Can autism be diagnosed with artificial intelligence? A narrative review. **Diagnostics**, v. 11, n. 11, p. 2032, 2021. DOI: 10.3390/diagnostics11112032. Disponível em: <https://doi.org/10.3390/diagnostics11112032>. Acesso em: 10 jan. 2026.
11. DO CARMO, E. B. The role of artificial intelligence in supporting individuals with Autism Spectrum Disorder: current applications, emerging trends, and future directions. **Preprint**, 2025. Disponível em: <https://www.google.com/search?q=https://www.researchgate.net/publication/392398862>. Acesso em: 10 jan. 2026.
12. FULLER, E. A.; KAISER, A. P. The Effects of Early Intervention on Social Communication Outcomes for Children with Autism Spectrum Disorder: A Meta-analysis. **Journal of Autism and Developmental Disorders**, v. 50, n. 5, p. 1683–1700, 2020. DOI: 10.1007/s10803-019-03927-z.
13. GHOSH, T.; BANNA, M. H.; RAHMAN, M. S. et al. Artificial intelligence and Internet of Things in screening and management of autism spectrum disorder. **Sustainable Cities and Society**, v. 74, p. 103189, 2021. DOI: 10.1016/j.scs.2021.103189. Disponível em: <https://doi.org/10.1016/j.scs.2021.103189>. Acesso em: 10 jan. 2026.
14. HOSSEINI, S. A.; SHAHMOLKARA, D.; EBRAHIMZADEH, M. et al. Deep learning for autism diagnosis and facial analysis in children. **Frontiers in Computational Neuroscience**, v. 12, p. 77, 2018. DOI: 10.3389/fncom.2018.00077.
15. HUIJNEN, C. A. G. J.; LEXIS, M. A. S.; JANSSENS, R. et al. Mapping robots to therapy and educational objectives for children with ASD. **Journal of Autism and Developmental Disorders**, v. 46, n. 6, p. 2100–2114, 2016. DOI: 10.1007/s10803-016-2740-6. Disponível em: <https://doi.org/10.1007/s10803-016-2740-6>. Acesso em: 10 jan. 2026.
16. HYDE, K. K.; NOVACK, M. N.; LAFERRIERE, N. et al. Applications of Supervised Machine Learning in Autism Spectrum Disorder Research: A Review. **Review Journal of Autism and Developmental Disorders**, v. 6, p. 128-146, 2019. DOI: 10.1007/s40489-019-00158-x.
17. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo Demográfico 2022: População e Domicílios - Primeiros Resultados**. Rio de Janeiro: IBGE, 2023. Disponível em: <https://doi.org/10.48331/IBGE.2023.2102011>. Acesso em: 12 jan. 2026].
18. JALIAAWALA, M. S.; KHAN, R. A. Can autism be catered with artificial intelligence-assisted intervention technology? A comprehensive survey. **Artificial Intelligence Review**, v. 53, p. 1039–1069, 2020. DOI: 10.1007/s10462-019-09686-8. Disponível em: <https://doi.org/10.1007/s10462-019-09686-8>. Acesso em: 10 jan. 2026.

19. JARADAT, A. S.; WEDYAN, M.; ALOMARI, S. et al. Using machine learning to diagnose autism based on eye tracking technology. **Diagnostics**, v. 15, n. 1, p. 66, 2025. DOI: 10.3390/diagnostics15010066. Disponível em: <https://doi.org/10.3390/diagnostics15010066>. Acesso em: 10 jan. 2026.
20. JOUDAR, S. S.; ALBAHRI, A. S.; HAMID, R. A. Triage and priority-based healthcare diagnosis using artificial intelligence for autism spectrum disorder and gene contribution: a systematic review. **Computers in Biology and Medicine**, v. 146, p. 105553, 2022. DOI: 10.1016/j.compbiomed.2022.105553. Disponível em: <https://doi.org/10.1016/j.compbiomed.2022.105553>. Acesso em: 10 jan. 2026.
21. KHOSLA, M.; JAMISON, K.; NGUYEN, G. H. et al. Machine learning for neuroimaging-based diagnosis and rehabilitation of autism spectrum disorder. **International Review of Neurobiology**, v. 147, p. 195-224, 2019. DOI: 10.1016/bs.irm.2019.09.008.
22. KOTSI, S.; HANDRINO, S.; IATRAKI, G.; SOULIS, S. A Review of Artificial Intelligence Interventions for Students with Autism Spectrum Disorder. **Disabilities**, v. 5, n. 1, p. 7, 2025. DOI: 10.3390/disabilities5010007. Disponível em: <https://doi.org/10.3390/disabilities5010007>. Acesso em: 10 jan. 2026.
23. KOUROUPA, A.; LAWS, K. R.; IRVINE, K. et al. The use of social robots with children and young people on the autism spectrum: a systematic review and meta-analysis. **PLOS ONE**, v. 17, n. 6, e0269800, 2022. DOI: 10.1371/journal.pone.0269800. Disponível em: <https://doi.org/10.1371/journal.pone.0269800>. Acesso em: 10 jan. 2026.
24. LAI, M. C.; LOMBARDO, M. V.; RUIGROK, A. N. et al. Quantifying and exploring camouflaging in men and women with autism. **Autism**, v. 21, n. 6, p. 690-702, 2017. DOI: 10.1177/1362361316671012.
25. LAI, M. C.; KASSEE, C.; BESNEY, R. et al. Evidence-based support for autistic people across the lifespan: maximising potential, minimising barriers, and optimising the person-environment fit. **The Lancet Neurology**, v. 18, n. 10, p. 430, 2019. DOI: 10.1016/S1474-4422(19)30034-1.
26. LAMPOS, V.; MINTZ, J.; QU, X. An artificial intelligence approach for selecting effective teacher communication strategies in autism education. **npj Science of Learning**, v. 6, art. 25, 2021. DOI: 10.1038/s41539-021-00102-x. Disponível em: <https://doi.org/10.1038/s41539-021-00102-x>. Acesso em: 10 jan. 2026.
27. LANDA, R. J. Efficacy of early interventions for infants and young children at risk for autism spectrum disorders. **International Review of Psychiatry**, v. 30, n. 1, p. 25–39, 2018. DOI: 10.1080/09540261.2017.1397586. Disponível em: <https://doi.org/10.1080/09540261.2017.1397586>. Acesso em: 10 jan. 2026.
28. LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015. DOI: 10.1038/nature14539.
29. LOMBARDO, M. V.; EILER, L.; BARNES, J. L. et al. Default Mode-Visual Network Hypoconnectivity in an Autism Subtype with Pronounced Social Visual Engagement Difficulties. **eLife**, v. 8, p. e47427, 2019. DOI: 10.7554/eLife.47427.
30. LOOMES, R.; HULL, L.; MANDY, W. What Is the Male-to-Female Ratio in Autism Spectrum Disorder? A Systematic Review and Meta-Analysis. **Journal of the American**

- Academy of Child & Adolescent Psychiatry**, v. 56, n. 6, p. 466–474, 2017. DOI: 10.1016/j.jaac.2017.03.013.
31. LORD, C.; BRUNSDON, V. E. A.; DI LAVORE, P. C. et al. Autism spectrum disorder. **Nature Reviews Disease Primers**, v. 6, n. 1, p. 5, 2020. DOI: 10.1038/s41572-019-0138-4.
 32. MAENNER, M. J.; WARREN, Z.; WILLIAMS, A. R. et al. Prevalence and Characteristics of Autism Spectrum Disorder Among Children Aged 8 Years — Autism and Developmental Disabilities Monitoring Network, 11 Sites, United States, 2020. **MMWR Surveillance Summaries**, v. 72, n. 2, p. 1–14, 2023. DOI: 10.15585/mmwr.ss7202a1.
 33. MEGERIAN, J. T.; DEY, S.; MELMED, R. D. et al. Evaluation of an artificial intelligence–based medical device for diagnosis of autism spectrum disorder. **npj Digital Medicine**, v. 5, art. 57, 2022. DOI: 10.1038/s41746-022-00598-6. Disponível em: <https://doi.org/10.1038/s41746-022-00598-6>. Acesso em: 10 jan. 2026.
 34. PAGE, M. J.; McKENZIE, J. E.; BOSSUYT, P. M. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, art. n71, 2021. DOI: 10.1136/bmj.n71. Disponível em: <https://doi.org/10.1136/bmj.n71>. Acesso em: 10 jan. 2026.
 35. PANDYA, S.; JAIN, S.; VERMA, J. A comprehensive analysis towards exploring the promises of AI-related approaches in autism research. **Computers in Biology and Medicine**, v. 168, p. 107801, 2024. DOI: 10.1016/j.compbiomed.2023.107801. Disponível em: <https://doi.org/10.1016/j.compbiomed.2023.107801>. Acesso em: 10 jan. 2026.
 36. PAULA, C. S.; CUKIERMAN, D. S.; KNYSACK, S. R. et al. Challenges, Perspectives, and New Recommendations for Autism Spectrum Disorder Research in Brazil. **Cadernos de Saúde Pública**, v. 36, n. 8, p. e00045420, 2020. DOI: 10.1590/0102-311X00045420.
 37. PUGLISI, A.; CAPRÌ, T.; PIGNOLO, L. et al. Social humanoid robots for children with autism spectrum disorders: a review of modalities, indications and pitfalls. **Children**, v. 9, n. 7, p. 953, 2022. DOI: 10.3390/children9070953. Disponível em: <https://doi.org/10.3390/children9070953>. Acesso em: 10 jan. 2026.
 38. RAHMAN, R.; KODESH, A.; LEVINE, S. Z. et al. Identification of newborns at risk for autism using electronic medical records and machine learning. **European Psychiatry**, v. 63, n. 1, e22, 2020. DOI: 10.1192/j.eurpsy.2020.17. Disponível em: <https://doi.org/10.1192/j.eurpsy.2020.17>. Acesso em: 10 jan. 2026.
 39. RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 4. ed. Pearson, 2022.
 40. RUTTER, M.; LE COUTEUR, A.; LORD, C. **Autism diagnostic interview-revised**. Los Angeles, CA: Western Psychological Services, 2003. DOI: <https://doi.org/10.1037/t18128-000>.
 41. SCASSELLATI, B.; ADMONI, H.; MATARIĆ, M. Robots for Use in Autism Research. **Annual Review of Biomedical Engineering**, v. 14, p. 275–294, 2012. DOI: 10.1146/annurev-bioeng-071811-150036.
 42. SCASSELLATI, B.; BOCCANFUSO, L.; HUANG, C. et al. Interactive robots for neurodevelopmental disorders. **Annual Review of Biomedical Engineering**, v. 20, p. 231–255, 2018. DOI: 10.1146/annurev-bioeng-062117-121116.

43. SOHL, K.; KILIAN, R.; CURRAN, A. B. et al. Integrating an artificial intelligence-based diagnostic aid for autism into the ECHO Autism primary care model: protocol. **JMIR Research Protocols**, v. 11, n. 7, e37576, 2022. DOI: 10.2196/37576. Disponível em: <https://doi.org/10.2196/37576>. Acesso em: 10 jan. 2026.
44. SOLEK, P.; NURFITRI, E.; SAHRIL, I. et al. The role of artificial intelligence for early diagnostic tools of autism spectrum disorder: a systematic review. **Turkish Archives of Pediatrics**, v. 60, n. 2, p. 126–140, 2025. DOI: 10.5152/TurkArchPediatri.2025.24183. Disponível em: <https://doi.org/10.5152/TurkArchPediatri.2025.24183>. Acesso em: 10 jan. 2026.
45. SONG, A.; ANDERSON, A.; LUO, L. et al. A review of computer-based technologies for autism spectrum disorder. **Journal of Autism and Developmental Disorders**, v. 49, n. 6, p. 2383–2396, 2019. DOI: 10.1007/s10803-019-03923-3.
46. THABTAH, F. Machine learning in autism classification and intervention: a review. **Informatics for Health and Social Care**, v. 44, n. 1, p. 20–39, 2019. DOI: 10.1080/17538157.2017.1399132.
47. TORRADO, J. C.; GOMEZ, J.; MONTORO, G. Recommendations for designing wearable solutions for children with autism spectrum disorder: A systematic review. **Sensors**, v. 17, n. 10, p. 2376, 2017. DOI: 10.3390/s17102376.
48. VAGNETTI, R.; DI NUOVO, A.; MAZZA, M.; VALENTI, M. Social robots: a promising tool to support people with autism. A systematic review of recent research and critical analysis from the clinical perspective. **Review Journal of Autism and Developmental Disorders**, 2024. DOI: 10.1007/s40489-024-00434-5. Disponível em: <https://doi.org/10.1007/s40489-024-00434-5>. Acesso em: 10 jan. 2026.
49. VAN'T HOF, M.; TANTER, D.; MOLLEN, J. et al. Age at autism spectrum disorder diagnosis: A systematic review and meta-analysis from 2012 to 2019. **Autism**, v. 25, n. 4, p. 862–873, 2021. DOI: 10.1177/1362361320971107.
50. VILLAMARÍN, A.; CHUMAÑA, J.; NARVÁEZ, M. et al. Artificial Intelligence in the Detection of Autism Spectrum Disorders (ASD): a Systematic Review. In: SAHA, A. K.; SHARMA, H.; PRASAD, M. (eds.). **Proceedings of International Conference on Intelligent Vision and Computing (ICIVC 2023)**: Volume 2. Cham: Springer, 2024. p. 21–32. DOI: 10.1007/978-3-031-71388-0_3. Disponível em: https://doi.org/10.1007/978-3-031-71388-0_3. Acesso em: 10 jan. 2026.
51. WALL, D. P.; DALLY, R.; LUYSTER, R. et al. Use of artificial intelligence to shorten the behavioral diagnosis of autism. **PLOS ONE**, v. 7, n. 8, e43855, 2012. DOI: 10.1371/journal.pone.0043855. Disponível em: <https://doi.org/10.1371/journal.pone.0043855>. Acesso em: 10 jan. 2026.
52. WANKHEDE, N. L.; KALE, M. B.; SHUKLA, M. et al. Leveraging AI for the diagnosis and treatment of autism spectrum disorder: current trends and future prospects. **Asian Journal of Psychiatry**, v. 101, p. 104241, 2024. DOI: 10.1016/j.ajp.2024.104241. Disponível em: <https://doi.org/10.1016/j.ajp.2024.104241>. Acesso em: 10 jan. 2026.
53. WEI, Q.; CAO, H.; SHI, Y. et al. Machine learning based on eye-tracking data to identify autism spectrum disorder: a systematic review and meta-analysis. **Journal of Biomedical Informatics**, v. 137, p. 104254, 2023. DOI: 10.1016/j.jbi.2023.104254. Disponível em: <https://doi.org/10.1016/j.jbi.2023.104254>. Acesso em: 10 jan. 2026.

54. WOLFERS, T.; HUIJSER, C.; DE VRIES, K. et al. From estimating activation locality to predicting disorder: A review of pattern recognition for neuroimaging-based psychiatric diagnostics. **Neuroscience & Biobehavioral Reviews**, v. 104, p. 248-261, 2019. DOI: 10.1016/j.neubiorev.2019.07.006.
55. WORLD HEALTH ORGANIZATION. **Ethics and governance of artificial intelligence for health: WHO guidance**. Geneva: WHO, 2021. ISBN 9789240029200. Disponível em: <https://www.who.int/publications/i/item/9789240029200>. Acesso em: 10 jan. 2026.
56. ZHANG, S. AI-assisted early screening, diagnosis, and intervention for autism in young children. **Frontiers in Psychiatry**, v. 16, art. 1513809, 2025. DOI: 10.3389/fpsy.2025.1513809. Disponível em: <https://doi.org/10.3389/fpsy.2025.1513809>. Acesso em: 10 jan. 2026.
57. ZUCKERMAN, K. E.; LINDLY, O. J.; SINCHAIKUL, S. Racial/ethnic disparities in autism service use among young children enrolled in Medicaid. **Journal of Autism and Developmental Disorders**, v. 47, n. 3, p. 900-915, 2017. DOI: 10.1007/s10803-016-3023-y.
58. ZWAIGENBAUM, L.; BAUMAN, M. L.; CHOUEIRI, R. et al. Early Intervention for Children With Autism Spectrum Disorder Under 3 Years of Age: Recommendations for Practice and Research. **Pediatrics**, v. 136, n. Suppl 1, p. S60–S81, 2015. DOI: 10.1542/peds.2014-3667E.