

# Aplicações de Machine Learning na Detecção e Monitoramento de Distúrbios de Neurodesenvolvimento

Maria Eduarda Maia Pereira<sup>1</sup>, Fábio Ventura Lima<sup>1</sup>

<sup>1</sup>Instituto de Computação – Universidade Federal de Mato Grosso (UFMT)  
Caixa Postal 78060 – 900 – Cuiabá – MT – Brazil

{ maria.pereira10, fabio.lima1}@sou.ufmt.br

**Abstract.** This article presents a Systematic Literature Mapping (SLM) on the use of ML in the detection and monitoring of Autism Spectrum Disorder (ASD), Attention Deficit Hyperactivity Disorder (ADHD), and Dyslexia. The objective is to investigate and analyze the application of ML algorithms for the diagnosis, monitoring, and support of these disorders. Following the PRISMA protocol, a search in IEEE Xplore resulted in 82 articles, with 50 included. The findings indicate a growing and promising use of ML, assessing its effectiveness compared to traditional methods.

**Resumo.** Este artigo apresenta um Mapeamento Sistemático da Literatura (MSL) sobre o uso de ML na detecção e monitoramento de Transtorno do Espectro Autista (TEA), Transtorno de Déficit de Atenção e Hiperatividade (TDAH) e Dislexia. O objetivo é investigar e analisar a aplicação de algoritmos de ML para diagnóstico, monitoramento e suporte desses distúrbios. Seguindo o protocolo PRISMA, a busca na IEEE Xplore resultou em 82 artigos, com 50 incluídos. Os achados indicam um uso crescente e promissor de ML, avaliando sua eficácia em relação aos métodos tradicionais.

## 1. Introdução

A crescente prevalência e o impacto significativo dos distúrbios de neurodesenvolvimento, como o Transtorno do Espectro Autista (TEA), Transtorno de Déficit de Atenção e Hiperatividade (TDAH) e a Dislexia representam um desafio complexo para indivíduos, familiares e sistemas de saúde em todo o mundo [Martins 2022, Fombonne 2003].

O diagnóstico destes distúrbios é um processo complexo que requer uma gama de profissionais envolvidos, como psicólogos, fonoaudiólogos, neuropediatrias e outros profissionais. Os métodos tradicionais de diagnóstico para TEA, TDAH e Dislexia são exclusivamente clínicos que dependem de avaliações clínicas subjetivas, histórico de desenvolvimento e aplicação de escalas de avaliação comportamental [Silva and Mulick 2009, Souza and outros 2007]. Embora essenciais, esses métodos podem ser demorados e exigir conhecimento especializado. Além disso, a variabilidade dos sintomas e sua sobreposição com outros transtornos frequentemente atrasam o diagnóstico, especialmente em fases iniciais do desenvolvimento, prejudicando o desenvolvimento neural e social do indivíduo.

Nesse contexto, a aplicação de técnicas de Machine Learning (ML) surge como uma área de pesquisa promissora para complementar e eminentemente aprimorar os métodos tradicionais de detecção e monitoramento de distúrbios de neurodesenvolvimento [Briguglio et al. 2023, Heinsfeld et al. 2017].

Este trabalho visa identificar e analisar as aplicações de Machine Learning na detecção de distúrbios de neurodesenvolvimento, buscando mapear as abordagens mais utilizadas, avaliar a eficácia dos modelos e compreender os desafios enfrentados na implementação dessas técnicas.

## 2. Metodologia

O seguinte Mapeamento Sistemático da Literatura (MSL) seguiu as diretrizes do protocolo PRISMA [Moher et al. 2009], que consiste em três fases: planejamento, condução e extração de resultados. O MSL teve o propósito de responder à seguinte questão de pesquisa: *Quais são as vantagens e desafios do uso de Machine Learning na detecção e monitoramento de distúrbios do neurodesenvolvimento em comparação aos métodos tradicionais, considerando eficácia, segurança e aplicabilidade?*

Na etapa de planejamento, foi pré-estabelecido o protocolo do MSL, definindo diretrizes a serem seguidas ao longo da revisão, como: objetivos, questão de pesquisa, palavras-chave, bases de dados científicas nas quais as strings de buscas foram aplicadas, os critérios de inclusão e exclusão de artigos e uma breve descrição dos procedimentos aplicados nas fases do estudo. A base de dados utilizada foi a *IEEE Digital Library*.

Na etapa de condução, foram buscados artigos publicados nos últimos sete anos (de 2019 a 2024), a fim de obter abordagens e limitações atualizadas. A condução foi dividida em duas etapas: uma seleção preliminar, baseada na leitura de títulos e resumos, e uma análise detalhada com a leitura completa de 50 artigos. A seleção considerou os objetivos da pesquisa e os critérios de inclusão e exclusão definidos previamente.

### **Critérios de Inclusão (CI):**

- Estudos publicados em periódicos ou conferências indexadas nas bases selecionadas;
- Estudos que apresentem resultados experimentais com métricas de avaliação;
- Trabalhos publicados entre 2019 e 2024;
- Trabalhos que descrevam o uso de Machine Learning na detecção ou monitoramento de distúrbios do neurodesenvolvimento.

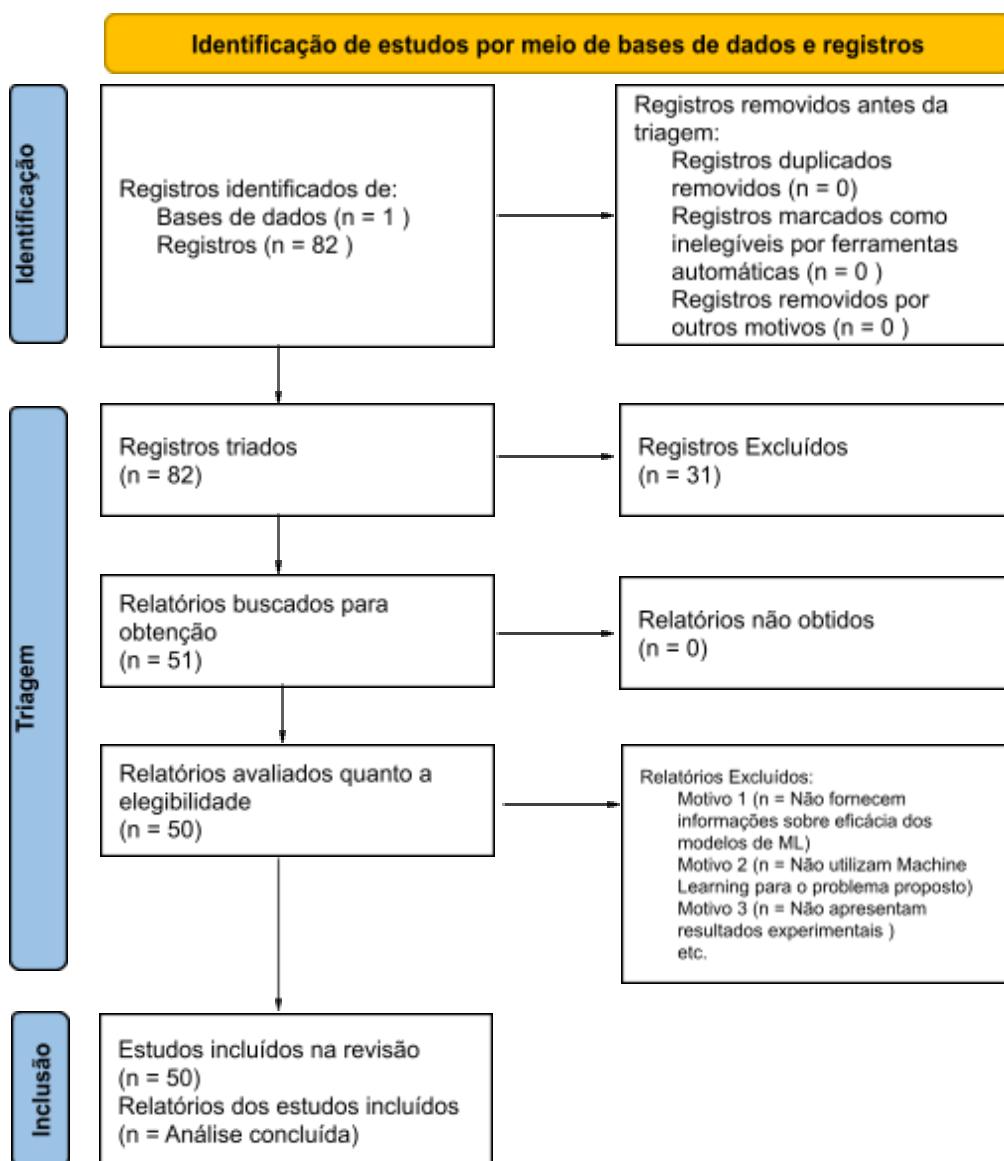
### **Critérios de Exclusão (CE):**

- Artigos de revisão sem meta-análise;
- Estudos que não fornecem informações sobre a eficácia dos modelos de Machine Learning ou os desafios de implementação;
- Estudos que não são baseados em dados empíricos (como revisões não sistemáticas ou opiniões);
- Estudos que não utilizam Machine Learning para o problema proposto;
- Trabalhos que não apresentem resultados experimentais;
- Trabalhos que não estejam em inglês ou português;
- Trabalhos que não estejam no período de 2019 a 2024.

Os artigos foram aceitos ou rejeitados com base na aplicação rigorosa dos critérios acima. Após a leitura dos títulos e resumos, foi realizada uma análise mais detalhada dos artigos aceitos, que incluiu a avaliação da qualidade por meio de uma escala definida.

Na etapa de extração de dados, foram definidos campos essenciais para capturar informações relevantes sobre os estudos selecionados. Foram extraídos detalhes como:

título, autores, ano de publicação, base de dados, objetivos do estudo, tipo de distúrbio do neurodesenvolvimento abordado, técnicas de Machine Learning utilizadas, base de dados empregada para o treinamento dos modelos, métricas de desempenho, comparações com métodos tradicionais, principais resultados e limitações identificadas. Além disso, coletaram-se informações sobre o contexto de aplicação (clínico, educacional ou digital), bem como os desafios e perspectivas futuras indicados pelos autores. O objetivo da extração foi organizar e estruturar os achados para facilitar a análise e a síntese dos resultados do MSL.



**Figure 1. Fluxograma PRISMA do Mapeamento Sistematico.**

Durante o processo de Mapeamento Sistemático da Literatura (MSL), foram utilizadas ferramentas baseadas em Inteligência Artificial Generativa para auxiliar em diferentes etapas da pesquisa. O ChatGPT, modelo de linguagem da OpenAI, foi empregado para revisão e reestruturação do texto, garantindo assim coesão e clareza do mesmo. Já o

Notebook LM, desenvolvido pela Google DeepMind, foi utilizado como uma ferramenta de apoio na etapa de condução e extração de dados. Sua capacidade de busca inteligente permitiu o gerenciamento eficiente dos 50 artigos selecionados para a análise detalhada. A ferramenta auxiliou na categorização automática de técnicas de Machine Learning, tipos de distúrbio e métricas de desempenho. A combinação dessas duas ferramentas permitiu acelerar e otimizar na tomada de decisões de inclusão e exclusão dos artigos, sendo todas as tomadas de decisão revisadas pelos autores sem comprometer a validade metodológica do mapeamento.

### **3. Resultados do Mapeamento Sistemático**

Esta seção aborda os resultados obtidos a partir do Mapeamento Sistemático da Literatura dos 50 artigos, ela está estruturada em três seções relacionadas às questões da pesquisa.

#### **3.1. Abordagens de Machine Learning para a Detecção e Monitoramento de Distúrbios de Neurodesenvolvimento**

Devido à sua robustez e eficiência computacional em visão computacional, as Redes Neurais Convolucionais (CNNs) são amplamente utilizadas na classificação do Transtorno do Espectro Autista (TEA), empregando dados neurofisiológicos e comportamentais, como a análise de neuroimagem por meio de Ressonância Magnética Funcional (fMRI) [Liang et al. 2021, Wang et al. 2019], eletroencefalograma (EEG) [Al-Qazzaz et al. 2024], dados de rastreamento ocular [Kavadi et al. 2024], análise da marcha [Henderson et al. 2023] e dados multimodais [Robles et al. 2022]. O uso consistente dessa técnica se justifica pelo seu alto desempenho de classificação de imagens, sendo capaz de detectar padrões sutis em exames, apresentando altas taxas de precisão.

No Transtorno de Déficit de Atenção e Hiperatividade (TDAH), o uso de CNNs também é utilizado com dados de fMRI [Wang et al. 2019] e EEG [Zhang et al. 2024], também tendo mostrado métricas de desempenho elevadas.

Entre os métodos tradicionais de Machine Learning, destacam-se as Máquinas de Vetores de Suporte (SVM), Regressão Logística, Floresta Aleatória, Árvores de Decisão e K-Vizinhos Mais Próximos (KNN). Esses métodos clássicos são frequentemente aplicados devido ao seu baixo custo computacional e boa interpretabilidade, sendo eficazes para analisar dados tabulares como resultados de testes neuropsicológicos, avaliações comportamentais e sinais eletrofisiológicos.

Em situações com grandes volumes de dados complexos, os modelos de Deep Learning demonstram desempenho notório. Modelos como Redes Neurais Profundas são extremamente eficazes na detecção de padrões em imagens, por meio de visão computacional, permitindo a classificação de distúrbios com base em ressonâncias magnéticas.

Além disso, Autoencoders, um método de aprendizado não supervisionado, permite detectar padrões sutis em eletrocardiogramas e neuroimagens, mesmo sem a necessidade de grandes quantidades de dados rotulados [Liang et al. 2021, Kavadi et al. 2024].

**Table 1. Estudos sobre uso de aprendizado de máquina na detecção de distúrbios do neurodesenvolvimento**

Nome do Estudo	Tipo de Distúrbio	Técnica de ML	Base de Dados	Métricas de Desempenho
A Convolutional Neural Network Combined With Prototype Learning Framework for Brain Functional Network Classification of Autism Spectrum Disorder	TEA	CNN com framework de aprendizado por protótipos (CNNPL)	rs-fMRI ABIDE (511 TEA, 561 controles)	Acurácia: ~70%, Precisão: 77%, F1-Score: 77%
A Multimodal Approach for Identifying Autism Spectrum Disorders in Children	TEA	Fusão Multimodal com MMSDAE	40 TEA, 50 TD (3-6 anos)	Acurácia: 95,56%; Sens.: 92,5%; Esp.: 98%; AUC: 0,984
Dilated 3D Convolutional Neural Networks for Brain MRI Data Classification	TDADH	Dilated 3D CNN	ADHD-200 (MRI)	Acurácia: 77%, Precisão: 76,6%, F1-Score: 44%
Transfer Learning and Hybrid Deep CNNs for ASD Classification From EEG Signals	TEA	CNNs híbridas + Transfer Learning	EEG próprio (grupos: controle, leve, moderado, severo)	SqueezeNet + SVM: 87,8%; AlexNet: 83,9%; MobileNetV2: 80,8%; etc.
A Hybrid Machine Learning Model for Accurate Autism Diagnosis	TEA	BDML-MDCASD (ISSA-FS + AE-BOA)	ASD-Children (292), ASD-Adolescent (104), ASD-Adult (704)	Acurácia: ~98% em todos; Sens., Esp., F1 e Kappa: ~98%
Encoding Kinematic and Temporal Gait Data...	TEA	MLP + Random Forest	Base 1 (11 TEA, 11 TD), Base 2 (19 TEA, 19 TD)	CNN: 88,89%-93,33%; RF e MLP: 64,44%-66,67%
A Virtual Reality Based System for the Screening and Classification of Autism	TEA	ML com VR (gaze, voz, movimentos) + MLP, LR, SVM	19 adultos (6 TEA, 13 TD)	Acurácia: 0,77-0,93; Melhor: MLP (0,93)
Fusion of Multi-Task Neurophysiological Data...	TDADH	Fusão de TP, EEG, EMG, HR + DNN	Dados próprios (crianças com TDADH e TD)	Acurácia (4 fusões): 89%
Insights Into Detecting Adult ADHD Symptoms...	TDADH	RF, SVM, DT com votação e concatenação	ISAT Dataset (10 TDADH, 12 controles adultos)	Precisão: 96,36%
Finding Essential Parts of the Brain...	TDADH	SCCNN-RNN	ADHD-200 (rs-fMRI de 5 sites)	Acurácia (LOSO): 70,6% (15 ROIs principais)
Multi-Modal Dyslexia Detection Model via SWIN Transformer...	Dislexia	Ensemble (SWIN, CFC, CatBoost etc.)	Dados públicos (MRI e EEG)	Acurácia: 98,5% (MRI), 98,7% (EEG)
Gaze Patterns in Children With Autism...	TEA	LSTM, SVM, RF, KNN, etc.	Dados próprios (crianças TEA e TD)	Máxima com LSTM: 83%
Acoustic and Text Features Analysis for Adult ADHD Screening...	TDADH	SVM, LR com eGeMAPS + Wav2Vec2.0	ISAT Dataset + DIVA	Acurácia máx.: 0,784 (LR com Wav2Vec2.0)
A Machine Learning Framework for Early-Stage Detection of Autism Spectrum Disorders	TEA	AB, RF, DT, KNN, GNB, LR, SVM, LDA	4 datasets públicos (Kaggle, UCI)	Faixa: LDA (0,85), AB (0,87), LR (0,88)

### 3.2. Base de Dados e Métricas de Avaliação

Os estudos analisados utilizaram diversas bases de dados, o que contribui para treinar os modelos. Uma das bases mais recorrentes foi a **ABIDE (Autism Brain Imaging Data**

**Exchange**)[Liang et al. 2021], uma iniciativa que compartilha dados de exames de ressonância magnética de indivíduos com TEA e neurotípicos de diferentes clínicas internacionais.

A **ADHD-200** [Kim et al. 2023] é uma iniciativa popular que compartilha dados de fMRI em estado de repouso e conjuntos de dados anatômicos agregados de indivíduos com TDAH e com desenvolvimento típico.

A **Saliency4ASD** [Zhou et al. 2024] é um banco de dados público que contém informações sobre rastreamento ocular de crianças com TEA e crianças típicas. Outros exemplos incluem a **DIVA** [Zhou et al. 2024] (*Diagnostic Interview for ADHD in Adults*), composta por gravações de áudio de entrevistas semiestruturadas, além de repositórios como o **Kaggle** e o **UCI Machine Learning Repository** [Hasan et al. 2023], que disponibilizam diversos conjuntos de dados. Em alguns estudos, os próprios autores construíram seus próprios conjuntos de dados.

Estes exemplos destacam a importância do compartilhamento livre de informações, que impulsiona o avanço no estudo dos transtornos de neurodesenvolvimento.

Em relação às métricas, elas são utilizadas para certificar a eficiência e o desempenho do modelo. Essa etapa é de suma importância na pesquisa, pois as métricas indicam se o modelo está aprendendo e classificando de maneira correta, o que diminui os erros de diagnóstico.

As principais métricas empregadas nos estudos incluem a **acurácia**, que mostra a proporção de acertos em relação ao número total de amostras; a **sensibilidade**, que mede a capacidade do modelo em diagnosticar corretamente indivíduos com o transtorno; e a **especificidade**, que avalia a capacidade de identificar corretamente indivíduos sem o transtorno. Outras métricas utilizadas são a **precisão**, **F1-score**, **AUC**, **Kappa score**, **Log Loss** e **t-IoU**. Essas métricas são escolhidas conforme a natureza do problema, de modo a garantir a confiabilidade dos modelos aplicados em contextos clínicos.

**Table 2. Bases de dados utilizadas em estudos sobre TDAH e TEA**

Base de Dados	Tipo de Dados	Tamanho da Amostra	Tarefa Principal	Métricas de Avaliação
ABIDE	rs-fMRI, sMRI	871 – 1112	Classificação TEA vs. Grupo Típico	Acurácia, F1, AUC
TDAH-200	rs-fMRI, sMRI, Fenotípicos	121 – 973	Classificação TDAH vs. Grupo Típico	Acurácia, F1, AUC
UCI ML Repository, Kaggle (TDAH)	Questionários (Q-CHAT-10, AQ-10)	98 – 1054	Classificação TDAH vs. Controlo	Acurácia, F1, Kappa
EEG Dataset (TDAH-200)	EEG (Resting-State)	121	Classificação TDAH vs. Grupo Típico	Acurácia, AUC
NDAR	fMRI (Resposta à Fala)	157	Classificação Severidade TDAH	Acurácia, Sensibilidade
VR Supermercado	Dados Não Verbais (Gaze, Movimento)	19	Classificação TDAH vs. Grupo Típico	Acurácia, Sensibilidade
Multi-modal DIVA	Áudio (Fala), Texto	22	Classificação TDAH vs. Grupo Típico	Acurácia, F1, AUC
Dataset Kinemático	Amplitude, Velocidade, Aceleração	43	Classificação TDAH vs. Grupo Típico	Acurácia, Sensibilidade
Robótico (Casa)	Sensores (Luz, Temperatura, Som)	12	Reconhecimento de Atividade	Acurácia (Comparação com Especialista)

### 3.3. Desafios, Limitações e Desempenho das Técnicas de Machine Learning

Apesar do potencial significativo das técnicas de *Machine Learning* na detecção e classificação desses transtornos, elas enfrentam desafios e limitações que impactam diretamente sua aplicabilidade clínica e desempenho.

A escassez de dados é um grande obstáculo: vários estudos mencionam a limitação do tamanho dos conjuntos de dados como um fator que dificulta a generalização dos resultados e o treinamento de modelos de *Aprendizado de Máquina*, especialmente os mais complexos, como as Redes Neurais Profundas [Robles et al. 2022, Henderson et al. 2023]

Estudos de neuroimagem, por exemplo, possuem dados reduzidos em relação ao número de parâmetros exigidos, o que pode levar ao sobreajuste e ao aumento da complexidade computacional. Uma possível solução seria a construção de bases de dados colaborativas, com maior diversidade populacional.

Além disso, a diversidade dos sintomas e a sobreposição com outros transtornos dificultam ainda mais a aplicação desses modelos. Isso evidencia a necessidade de abordagens mais sensíveis às diferenças de cada indivíduo, como levantado por [Zhang et al. 2024], que propôs um método guiado por *EAG-RS*, um *framework* baseado em explicabilidade que seleciona regiões de interesse do cérebro considerando as características de cada paciente.

O uso de dados multimodais torna-se relevante, pois integra informações fisiológicas e comportamentais, o que capacita os modelos a reconhecer sinais mais sutis e contextuais [Han et al. 2022].

## 4. Discussões

A partir da análise dos estudos foi possível identificar padrões comuns nos usos das tecnologias de *Machine Learning* (ML) para diagnóstico de distúrbios do neurodesenvolvimento, com o Aprendizado Supervisionado sendo a técnica mais aplicada, utilizando métodos como *Support Vector Machines* (SVM), *Random Forests*, Redes Neurais (NN) e *Deep Learning* (CNNs, RNNs, LSTMs, *Transformers*). Esses métodos se mostraram eficazes tanto na classificação quanto na detecção dos distúrbios.

Existem outras técnicas promissoras porém ainda pouco convencionais, como a Técnica de Aprendizado Não Supervisionado *Temporal Coherency Deep Networks* (TCDN) e as Redes Adversariais Generativas (GANs). A primeira baseia-se na extração de traços de comportamentos autoestimulatórios observados em crianças com TEA a partir de vídeos. Esses comportamentos, como movimentos repetitivos variados, são indicadores essenciais para o diagnóstico e monitoramento do TEA. Já a segunda é uma técnica de *deep learning* que utiliza imagens de ressonância magnética estrutural (sMRI) para identificar marcadores comuns de TEA como *outliers*. Ao se basear em cérebros saudáveis, torna possível identificar anomalias em pessoas com TEA, o que é fundamental para o diagnóstico e monitoramento da condição.

O Transtorno do Espectro Autista (TEA) e o Transtorno do Déficit de Atenção e Hiperatividade (TDAH) estão entre os transtornos do neurodesenvolvimento mais pesquisados, possivelmente devido à sua crescente incidência, complexidade e impacto significativo no crescimento e vida dos indivíduos. Por outro lado, a dislexia recebe

menos atenção, talvez pelas dificuldades associadas à identificação de padrões em dados multimodais ou pela crença de que os métodos diagnósticos atuais já são suficientes.

Alguns dos dados mais usados nos estudos analisados são de neuroimagem (fMRI e sMRI), eletroencefalografia (EEG), dados comportamentais (incluindo *scanspaths*, tarefas de desenho, medições de marcha, características da fala, comportamentos autoestimulatórios) e dados fisiológicos (como Variabilidade da Frequência Cardíaca - HRV e sinais de *Functional Near-Infrared Spectroscopy* - fNIRs).

É notável também o potencial em dados que não são tão explorados, e que demonstram ser eficientes, como a integração de variados tipos de dados (*multimodal*), que consiste basicamente na combinação de diferentes dados para cobrir com mais fidelidade a dimensão das características dos transtornos e assim facilitar o diagnóstico.

Existe também uma perceptível lacuna nas investigações, que poderiam ser mais aprofundadas se considerassem de forma mais detalhada as nuances das mudanças dos transtornos ao longo do tempo, pois não são estáticos. Eles evoluem, mudam de intensidade e se manifestam de maneiras diferentes nas fases da vida do indivíduo. Ampliar o foco da coleta dos dados para um recorte temporal maior pode se mostrar benéfico no diagnóstico, intervenção e previsão da progressão do transtorno. A adoção do uso de dados longitudinais, que consiste na realização de várias medições ao longo do tempo para um mesmo indivíduo, embora desafiadora, pode oferecer informações valiosas sobre a evolução e o desenvolvimento dos distúrbios, porém ainda é frequentemente menos aplicada em comparação com os dados transversais.

Muitos estudos se baseiam em conjuntos de dados abertamente disponíveis, como o ABIDE para TEA e o ADHD-200 [Kim et al. 2023] para TDAH, o que facilita a pesquisa e a comparação entre os estudos, mas também traz desafios, como a limitação da generalização dos modelos devido a fatores como conjuntos de dados pequenos, heterogeneidade não controlada e amostras restritas a contextos clínicos ou laboratoriais [Henderson et al. 2023]. Além disso, os estudos tendem a se basear em dados de países desenvolvidos, o que levanta questões sobre a validade desses resultados para populações diversas. A falta de diversidade nas amostras, evidenciada pela sub-representação de diferentes faixas etárias, gêneros, etnias e localidades geográficas, constitui um viés relevante que deve ser abordado em futuras pesquisas [Liang et al. 2021].

Algumas das métricas de avaliação mais encontradas são: acurácia, AUC, sensibilidade, especificidade, precisão e *F1-score*. As métricas *F1-score* e o coeficiente de Matthews (MCC) se mostraram mais adequadas para casos em que os dados estão desbalanceados, ou seja, quando a quantidade de amostras em uma categoria é consideravelmente maior que nas outras. No entanto, essas métricas ainda são pouco utilizadas, sendo comum o uso de métricas como a acurácia, que apresenta apenas a proporção geral de classificações corretas, mesmo sendo ineficaz em cenários com desbalanceamento.

A principal função das métricas é medir o desempenho dos modelos de classificação. A notável falta de padronização entre elas acarreta em problemas na comparação dos resultados, dificultando a determinação de qual abordagem é superior, o que representa um atraso na consolidação do conhecimento.

O desenvolvimento dessas ferramentas de detecção de distúrbios ainda enfrenta outros sérios desafios, como problemas éticos e sociais, especialmente em torno da pri-

vacidade e da coleta de dados. É de suma importância trabalhar para reduzir o impacto dos sistemas de monitoramento sensorial nos usuários, para que não se tornem estímulos comprometedores à saúde mental. Além disso, o design desses sistemas deve levar em conta a variedade de comportamentos sensoriais atípicos presentes em pessoas com TEA.

Outro fator importante é a possibilidade de diagnósticos incorretos, devido a limitações dos modelos, dos dados ou interpretações errôneas, o que compromete a aplicação.

## 5. Conclusão

A análise dos estudos demonstrou que há grande potencial para avanços na área da saúde no futuro com o auxílio da tecnologia, especialmente no diagnóstico de transtornos neurodivergentes. No entanto, ainda há desafios significativos, como a falta de padronização, amostras pequenas e heterogeneidade descontrolada, que podem resultar em diagnósticos incorretos, viés nos algoritmos e questões relacionadas à privacidade dos dados.

Diante desse cenário, trabalhos futuros poderiam se concentrar em padronizar os métodos de coleta e análise de dados, bem como na ampliação da diversidade e tamanho das amostras afim de promover melhor representatividade e confiabilidade dos resultados. Além disso, a integração de dados multimodais tem se mostrado um campo promissor o que pode contribuir significativamente para a melhoria da acurácia dos diagnósticos.

É recomendado também a exploração de técnicas emergentes como Modelos Ocultos (HMMs), Redes Adversárias Generativas (GANs), aprendizado não supervisionado e aprendizado federativo, sendo este último relevante por preservar a privacidade dos dados. Tais direções tem o potencial para enriquecer e refinar os modelos atuais.

## 6. Referências

### References

- Al-Qazzaz, N. K., Aldoori, A. A., Buniya, A. K., Ali, S. H. B. M., and Ahmad, S. A. (2024). Transfer learning and hybrid deep convolutional neural networks models for autism spectrum disorder classification from eeg signals. *IEEE Access*, 12:64510–64530.
- Bruguglio, M., Turriziani, L., Currò, A., Gagliano, A., Di Rosa, G., Caccamo, D., Tonacci, A., and Gangemi, S. (2023). A machine learning approach to the diagnosis of autism spectrum disorder and multi-systemic developmental disorder based on retrospective data and ados-2 score. *Brain Sciences*.
- Fombonne, E. (2003). Epidemiological surveys of autism and other pervasive developmental disorders: An update. *Journal of Autism and Developmental Disorders*, 33(4):365–382.
- Han, J., Jiang, G., Ouyang, G., and Li, X. (2022). A multimodal approach for identifying autism spectrum disorders in children. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30:2003–2011.
- Hasan, S. M. M., Uddin, M. P., Mamun, M. A., Sharif, M. I., Ulhaq, A., and Krishnamoorthy, G. (2023). A machine learning framework for early-stage detection of autism spectrum disorders. *IEEE Access*, 11:2168–21785.

- Heinsfeld, A. S., Franco, A. R., Craddock, R. C., Buchweitz, A., and Meneguzzi, F. (2017). Identification of autism spectrum disorder using deep learning and the abide dataset. *NeuroImage: Clinical*.
- Henderson, B., Yogarajah, P., Gardiner, B., and McGinnity, T. M. (2023). Encoding kinematic and temporal gait data in an appearance-based feature for the automatic classification of autism spectrum disorder. *IEEE Access*, 11:134100–134117.
- Kavadi, D. P., Chirra, V. R. R., Kumar, P. R., Veesam, S. B., Yeruva, S., and Pappala, L. K. (2024). A hybrid machine learning model for accurate autism diagnosis. *IEEE Access*, 12:194911–194921.
- Kim, B., Park, J., Kim, T., and Kwon, Y. (2023). Finding essential parts of the brain in rs-fmri can improve adhd diagnosis using deep learning. *IEEE Access*, 11:116065–116075.
- Liang, Y., Liu, B., and Zhang, H. (2021). A convolutional neural network combined with prototype learning framework for brain functional network classification of autism spectrum disorder. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29:2193–2202.
- Martins, F. (2022). Entre 5% e 8% da população mundial apresenta transtorno de déficit de atenção com hiperatividade. <https://www.gov.br/saude/pt-br/assuntos/noticias/2022/setembro/entre-5-e-8-da-populacao-mundial-apresenta-transtorno-de-deficit-de-> Acesso em: 15 abr. 2025.
- Moher, D., Liberati, A., Tetzlaff, J., and Altman, D. G. (2009). Preferred reporting items for systematic reviews and meta-analyses: The prisma statement. *PLoS Medicine*.
- Robles, M., Namdarian, N., Otto, J., Wassiljew, E., Navab, N., Falter-Wagner, C. M., and Roth, D. (2022). A virtual reality based system for the screening and classification of autism. *IEEE Access*, 28:2168–21785.
- Silva, M. and Mulick, J. A. (2009). Diagnosticando o transtorno autista: aspectos fundamentais e considerações práticas. *Psicologia: Ciência e Profissão*.
- Souza, I. G. S. d. and outros (2007). Dificuldades no diagnóstico de tda em crianças. *Jornal Brasileiro de Psiquiatria*.
- Wang, Z., Sun, Y., Shen, Q., and Cao, L. (2019). Dilated 3d convolutional neural networks for brain mri data classification. *IEEE Access*.
- Zhang, K.-F., Yeh, S.-C., Wu, E. H.-K., Xu, X., Tsai, H.-J., and Chen, C.-C. (2024). Fusion of multi-task neurophysiological data to enhance the detection of attention-deficit/hyperactivity disorder. *IEEE Journal of Translational Engineering in Health and Medicine*, 12:668–674.
- Zhou, Y., Gao, L., Wu, Z., Guo, X., and Chen, F. (2024). Automated multi-modal asd diagnosis using deep learning. *IEEE Transactions on Medical Imaging*.