

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

**Auxílio no diagnóstico do Transtorno do Espectro
Autista por meio de rastreamento ocular utilizando
Aprendizado de Máquina**

Alexandre Guidio Wolf

Monografia - MBA em Inteligência Artificial e Big Data

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Alexandre Guidio Wolf

Auxílio no diagnóstico do Transtorno do Espectro Autista por meio de rastreamento ocular utilizando Aprendizado de Máquina

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Filipi Nascimento Silva

Versão original

São Carlos

2025

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

W853a Wolf, Alexandre Guidio
 Auxílio no diagnóstico do Transtorno do Espectro
Autista por meio de rastreamento ocular utilizando
Aprendizado de Máquina / Alexandre Guidio Wolf;
orientador Filipi Nascimento Silva. -- São Carlos,
2025.
 55 p.

 Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2025.

 1. Transtorno do Espectro autista. 2.
Rastreamento Ocular. 3. Aprendizado de Máquina. 4.
Inteligência Artificial Explicável. I. Silva, Filipi
Nascimento, orient. II. Título.

Alexandre Guidio Wolf

**Assistance in the diagnosis of Autism Spectrum Disorder
through eye tracking using Machine Learning**

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Prof. Dr. Filipi Nascimento Silva

Original version

São Carlos

2025

Dedico este trabalho à minha esposa e à minha família, pelo amor, apoio e paciência em todos os momentos desta jornada.

Ao meu sobrinho José Antônio, que está dentro do espectro autista e é luz em nossas vidas.

E às pessoas da APAE de Piraju, com quem convivi por quatro anos como monitor de transporte escolar e de quem aprendi, a cada dia, o verdadeiro significado de humanidade, empatia e superação.

AGRADECIMENTOS

Agradeço ao corpo docente do MBA em Inteligência Artificial e Big Data da Universidade de São Paulo, em especial às professoras Doutoras Solange Oliveira Rezende e Roseli Aparecida Francelin Romero, pela idealização e construção deste curso que tanto contribuiu para minha formação acadêmica e profissional.

À Prof.^a Dra. Juliana de Souza Moraes, pela valiosa orientação metodológica e por conduzir com clareza e rigor científico o desenvolvimento desta pesquisa.

Ao Prof. Dr. Ricardo Marcondes Marcacini, pelo exemplo de didática, dedicação e entusiasmo, que serviram de inspiração para a prática profissional e acadêmica.

Ao meu orientador, Prof. Dr. Filipi Nascimento Silva, pela orientação, paciência e disponibilidade, mesmo diante das limitações de agenda, oferecendo contribuições essenciais para o aprimoramento deste trabalho.

Por fim, à minha esposa Ana Gabriella, pelo amor, apoio incondicional e compreensão em relação ao tempo dedicado aos estudos, que tornaram possível a realização desta jornada.

*“Que a tua vida não seja uma vida estéril.
- Sê útil. - Deixa rasto.”
São Josemaria Escrivá*

RESUMO

WOLF, A. G. **Auxílio no diagnóstico do Transtorno do Espectro Autista por meio de rastreamento ocular utilizando Aprendizado de Máquina**. 2025. 55 p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

O diagnóstico tardio e subjetivo do Transtorno do Espectro Autista (TEA) resulta em atraso no acompanhamento multidisciplinar de indivíduos que necessitam de estímulos e apoio desde a primeira infância. Este trabalho aborda a necessidade de maior acesso e agilidade na identificação de pessoas no espectro, propondo uma solução para o apoio diagnóstico por meio do rastreamento ocular. O método revela medidas objetivas da atenção visual, elemento que apresenta um padrão distinto em indivíduos com TEA. Para a análise, utilizou-se uma rede neural LSTM (*Long Short-Term Memory*) bidirecional com mecanismo de atenção para obter métricas temporais e espaciais. Adicionalmente, foi aplicada a Inteligência Artificial Explicável (XAI) sobre os *scanpaths* (trajetórias visuais) para compor um suporte visual interpretável aos profissionais de saúde. A abordagem, validada em uma base de dados de uso público, mostrou-se relevante para o apoio à decisão. Os resultados são promissores para aumentar a objetividade, a escalabilidade e a precocidade do diagnóstico de TEA, com potencial para impactar positivamente o prognóstico e a qualidade de vida dos pacientes.

Palavras-chave: transtorno do espectro autista; rastreamento ocular; aprendizado de máquina; inteligência artificial explicável.

ABSTRACT

WOLF, A. G. Assistance in the diagnosis of Autism Spectrum Disorder through eye tracking using Machine Learning. 2025. 55 p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

The late and subjective diagnosis of Autism Spectrum Disorder (ASD) leads to delays in the multidisciplinary follow-up of individuals who require stimulation and support from a very early age. This research addresses the need for broad access and speed in identifying individuals on the spectrum by proposing and delivering a diagnostic support solution through eye-tracking, which reveals objective measures of visual attention—an element that presents a distinct pattern in individuals on the spectrum. Through machine learning techniques, involving a bidirectional Long Short-Term Memory (LSTM) neural network with an attention mechanism to obtain temporal and spatial metrics, as well as Explainable Artificial Intelligence (XAI) applied to the scanpaths to compose an interpretable visual support for healthcare professionals. The approach, using a public database, proved to be relevant for decision support. The identified results are promising for increasing the objectivity, scalability, and earliness of ASD diagnosis, with the potential to positively impact the prognosis and quality of life of patients.

Keywords: autism spectrum disorder; eye-tracking; machine learning; explainable artificial intelligence.

LISTA DE FIGURAS

Figura 1 – Diagrama representando o fluxo da pesquisa	37
Figura 2 – Comparação de performance por <i>fold</i>	44
Figura 3 – Distribuição de métricas	44
Figura 4 – Comparação ASD e TD onde 10% do tempo = 10% da atenção	46
Figura 5 – Importância global das features via SHAP	47
Figura 6 – Explicação local via LIME para um caso limítrofe	48
Figura 7 – Mapa de calor comparando resultado de <i>scanpath</i> entre ASD e TD . .	49

LISTA DE TABELAS

Tabela 1 – Grupos de características extraídas dos dados de rastreamento ocular .	41
---	----

LISTA DE ABREVIATURAS E SIGLAS

ADI-R	<i>Autism Diagnostic Interview-Revised</i>
ADOS-2	<i>Autism Diagnostic Observation Schedule, Second Edition</i>
AUC-ROC	<i>Area Under the Receiver Operating Characteristic Curve</i>
AOI	<i>Area of Interest</i>
ASD/TEA	<i>Autism Spectrum Disorder / Transtorno do Espectro Autista</i>
AT	<i>Attention</i>
CNN	<i>Convolutional Neural Network</i>
CARS	<i>Childhood Autism Rating Scale</i>
CSV	<i>Comma Separated Values</i>
DSM-5	<i>Diagnostic and Statistical Manual of Mental Disorders</i>
DL	<i>Deep Learning</i>
DSR	<i>Design Science Research</i>
EEG	<i>Electroencephalogram</i>
ET	<i>Eye Tracking</i>
FDA	<i>Food & Drug Administration</i>
FOV	<i>Field of View</i>
GDPR	<i>General Data Protection Regulation</i>
IQR	<i>Interquartile Range</i>
LIME	<i>Local Interpretable Model-Agnostic Explanations</i>
LSTM	<i>Long Short-Term Memory</i>
ML	<i>Machine Learning</i>
MRI	<i>Magnetic Resonance Imaging</i>
PMCID	<i>PubMed Central Identifier</i>
RNN	<i>Recurrent Neural Network</i>

ROI	<i>Region of Interest</i>
SHAP	<i>SHapley Additive exPlanations</i>
SVM	<i>Support Vector Machine</i>
TD	<i>Typically Developing</i>
XAI	<i>Explainable Artificial Intelligence</i>

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Objetivos	28
1.2	Nota do autor	29
2	REFERENCIAL TEÓRICO	31
2.1	Transtorno do Espectro Autista (TEA)	31
2.2	Rastreamento ocular e atenção visual	31
2.3	Aprendizado de máquina (<i>machine learning</i>)	32
2.4	Redes neurais recorrentes e mecanismos de atenção	33
2.5	Inteligência Artificial Explicável (XAI)	33
2.6	Trabalhos correlatos e síntese crítica	33
3	METODOLOGIA	37
3.1	Abordagem metodológica	37
3.2	Tipo de pesquisa	38
3.3	Ambiente computacional	38
3.4	Obtenção e descrição dos dados	38
3.5	Análise exploratória e pré-processamento	39
3.6	Modelagem e otimização	40
3.7	Características extraídas (<i>features</i>)	40
3.7.1	Grupos de <i>features</i> utilizadas	41
3.8	Aplicação das técnicas de explicabilidade	41
3.9	Avaliação da capacidade explicativa	42
3.10	Desenvolvimento da interface	42
4	AVALIAÇÃO EXPERIMENTAL	43
4.1	Avaliação experimental do modelo	43
4.1.1	Configuração do experimento	43
4.1.2	Métricas de desempenho	43
4.1.3	Distribuição e variabilidade das métricas	44
4.1.4	Comparação com o estado da arte	45
4.2	Análise de explicabilidade	45
4.2.1	Mecanismo de atenção	45
4.2.2	Contribuições globais via <i>SHAP</i>	46
4.2.3	Explicações locais via <i>LIME</i>	47
4.3	Limitações	48

4.4	Implicações clínicas e práticas	49
4.4.1	Potencial para triagem	49
4.4.2	Apoio ao diagnóstico	49
4.4.3	Considerações de implementação	49
5	CONCLUSÃO E TRABALHOS FUTUROS	51
5.1	Trabalhos futuros	52
	REFERÊNCIAS	53

1 INTRODUÇÃO

O Transtorno do Espectro Autista (TEA) é uma condição do neurodesenvolvimento caracterizada por dificuldades persistentes na comunicação social e na reciprocidade interpessoal, bem como pela presença de padrões restritos e repetitivos de comportamento, interesses e atividades (American Psychiatric Association, 2013). O reconhecimento precoce do TEA é fundamental para o início de intervenções multidisciplinares que contribuem significativamente para o desenvolvimento cognitivo, emocional e social do indivíduo (Zwaigenbaum *et al.*, 2015). No entanto, o processo diagnóstico permanece complexo, dependente de observações clínicas subjetivas e fortemente limitado pela disponibilidade de especialistas, especialmente em regiões carentes (Lord *et al.*, 2020).

Estudos recentes apontam que o diagnóstico do autismo pode ocorrer tardiamente — muitas vezes apenas após os quatro anos de idade — mesmo quando sinais comportamentais já são perceptíveis na primeira infância (Maenner *et al.*, 2023). Essa demora afeta o acesso a intervenções precoces e reduz as chances de desenvolvimento adaptativo (Pierce *et al.*, 2019). De acordo com a Organização Mundial da Saúde (2025), estima-se que uma em cada 100 crianças no mundo esteja no espectro autista, reforçando a relevância de soluções tecnológicas que ampliem o acesso a métodos de triagem e apoio diagnóstico.

O rastreamento ocular (*eye tracking*) emerge como uma ferramenta promissora nesse contexto, por permitir a medição objetiva da atenção visual — um dos marcadores de interesse social frequentemente alterados em indivíduos com TEA (Jones; Klin, 2013). Crianças no espectro tendem a fixar o olhar em elementos não sociais de uma cena, ao contrário de crianças com desenvolvimento típico, que priorizam rostos e expressões (Chita-Tegmark, 2016). A análise dessas trajetórias visuais, ou *scanpaths*, pode revelar padrões quantitativos úteis para a identificação precoce de sinais do transtorno (Papagiannopoulou *et al.*, 2014).

O avanço do aprendizado de máquina (*Machine Learning*) possibilitou a extração e modelagem desses padrões com maior precisão. Modelos baseados em redes neurais recorrentes, como as LSTM (*Long Short-Term Memory*), têm-se mostrado eficazes na detecção de sequências temporais complexas, como o movimento ocular (Hochreiter; Schmidhuber, 1997; Chen *et al.*, 2021). Além disso, a adoção de abordagens baseadas em Inteligência Artificial Explicável (*XAI – Explainable Artificial Intelligence*) permite compreender as razões pelas quais o modelo classifica um indivíduo como pertencente ou não ao espectro, favorecendo a transparência e a confiança dos profissionais de saúde (Doshi-Velez; Kim, 2017; Lundberg; Lee, 2017).

O uso de técnicas explicáveis é especialmente relevante em contextos clínicos, onde

decisões automatizadas devem ser acompanhadas de justificativas interpretáveis (Ribeiro; Singh; Guestrin, 2016). Ferramentas como SHAP (*SHapley Additive exPlanations*), LIME (*Local Interpretable Model-agnostic Explanations*) e *Attention Visualization* têm sido amplamente aplicadas para atribuir importância às variáveis de entrada e destacar regiões de maior relevância nos dados, tornando visível o raciocínio interno de modelos complexos (Vilone; Longo, 2021; Bahdanau; Cho; Bengio, 2015; Xu *et al.*, 2015)

Dessa forma, o problema central deste trabalho consiste em compreender como dados de rastreamento ocular podem ser utilizados em conjunto com técnicas de aprendizado de máquina e inteligência artificial explicável para auxiliar no diagnóstico do Transtorno do Espectro Autista, reduzindo o caráter subjetivo e a morosidade do processo clínico.

A motivação para esta pesquisa advém da necessidade de promover ferramentas acessíveis, interpretáveis e eticamente responsáveis, capazes de apoiar profissionais de saúde e ampliar o alcance do diagnóstico em populações com menor acesso a especialistas. O desenvolvimento de soluções tecnológicas baseadas em IA, especialmente aquelas com foco em explicabilidade e suporte visual interpretável, representa um passo relevante em direção à medicina de precisão e à inclusão de pessoas no espectro.

1.1 Objetivos

O objetivo geral deste trabalho é desenvolver um sistema de apoio ao diagnóstico do Transtorno do Espectro Autista (TEA) que, a partir da análise de sequências de fixações oculares, seja capaz de classificar indivíduos em grupos de TEA ou de desenvolvimento típico. A proposta fundamenta-se na utilização de aprendizado de máquina para capturar padrões temporais e espaciais do comportamento visual e, assim, oferecer suporte quantitativo ao processo diagnóstico.

Para alcançar esse propósito, foram definidos os seguintes objetivos específicos:

- Utilizar um conjunto de dados público de rastreamento ocular contendo *scanpaths* de indivíduos diagnosticados com TEA e de participantes com desenvolvimento típico;
- Extrair métricas temporais e espaciais que descrevam a sequência de fixações e sacadas, representando de forma estruturada os padrões de atenção visual;
- Treinar e avaliar uma arquitetura de rede neural recorrente do tipo LSTM (*Long Short-Term Memory*) bidirecional com mecanismo de atenção, aplicada à tarefa de classificação binária;
- Incorporar técnicas de Inteligência Artificial Explicável (XAI), como *SHAP*, *LIME* e *Attention Visualization*, com o intuito de evidenciar as regiões do *scanpath* que mais contribuíram para as decisões do modelo;

- Desenvolver uma interface web interativa e de uso intuitivo, que permita a profissionais de saúde submeter dados de rastreamento ocular e visualizar tanto a predição quanto as interpretações correspondentes.

Esses objetivos buscam integrar avanços recentes em aprendizado profundo e explicabilidade para promover uma ferramenta interpretável, acessível e potencialmente útil no apoio à triagem e ao diagnóstico precoce do TEA.

1.2 Nota do autor

Durante a elaboração deste trabalho, o autor fez uso de ferramentas baseadas em inteligência artificial, dentre as quais se destacam *ChatGPT*, *Gemini* e *Cursor Code*. Tais recursos foram empregados com o propósito de aprimorar a clareza e a fluidez textual, apoiar traduções entre português e inglês, e otimizar a escrita e a organização de trechos de código e referências técnicas.

Todas as sugestões e conteúdos gerados por essas ferramentas foram cuidadosamente revisados, editados e validados pelo autor, que exerceu juízo crítico sobre o material produzido. O uso de inteligência artificial restringiu-se a apoio técnico e linguístico, não substituindo o processo reflexivo, analítico e autoral que fundamenta a pesquisa acadêmica. O autor assume inteira responsabilidade pelo conteúdo apresentado neste trabalho.

2 REFERENCIAL TEÓRICO

Neste capítulo, são apresentados os fundamentos teóricos que sustentam o desenvolvimento deste estudo. Inicialmente, aborda-se o Transtorno do Espectro Autista (TEA), suas características e desafios diagnósticos. Em seguida, são explorados os princípios do rastreamento ocular e sua relevância no contexto clínico. Posteriormente, são introduzidos os conceitos de aprendizado de máquina, redes neurais recorrentes e mecanismos de atenção, bem como as abordagens de Inteligência Artificial Explicável (XAI). Por fim, são discutidos os trabalhos correlatos e o estado da arte em aplicações de IA e *eye tracking* voltadas ao diagnóstico do TEA.

2.1 Transtorno do Espectro Autista (TEA)

O Transtorno do Espectro Autista (TEA) é uma condição do neurodesenvolvimento caracterizada por dificuldades persistentes na comunicação social, reciprocidade emocional e presença de padrões restritos e repetitivos de comportamento, interesses ou atividades (American Psychiatric Association, 2013). Trata-se de um espectro amplo, com manifestações que variam em intensidade e forma, podendo afetar aspectos cognitivos, motores e sensoriais.

Estudos recentes estimam que uma em cada 100 crianças no mundo esteja no espectro do autismo (Organização Mundial da Saúde, 2025). A variabilidade dos sintomas e a ausência de biomarcadores objetivos tornam o diagnóstico desafiador e frequentemente tardio (Lord *et al.*, 2020). O diagnóstico baseia-se em critérios clínicos descritos no DSM-5 (*Diagnostic and Statistical Manual of Mental Disorders*), observações comportamentais e relatos de familiares, o que torna o processo sujeito à subjetividade do avaliador (Hyman; Levy; Myers, 2020).

O diagnóstico precoce, preferencialmente até os três anos de idade, está associado a melhores desfechos em termos de aprendizado, comunicação e adaptação social (Zwigenbaum *et al.*, 2015). Entretanto, barreiras como escassez de profissionais especializados, custos e diferenças culturais dificultam a identificação em tempo oportuno (Pierce *et al.*, 2019). Essas limitações reforçam a necessidade de métodos complementares, baseados em métricas objetivas e replicáveis, como o rastreamento ocular.

2.2 Rastreamento ocular e atenção visual

O rastreamento ocular (*eye tracking*) é uma tecnologia que permite registrar com alta precisão o movimento dos olhos, fornecendo informações sobre o foco e a trajetória da atenção visual (Holmqvist *et al.*, 2011). Essa técnica mede eventos como fixações

— períodos em que o olhar permanece estável sobre uma região — e sacadas, que são movimentos rápidos entre pontos de interesse. A sequência dessas fixações e sacadas, conhecida como *scanpath*, constitui uma representação temporal do comportamento visual (Noton; Stark, 1971).

No contexto do TEA, o rastreamento ocular tem sido amplamente utilizado para investigar diferenças na atenção a estímulos sociais. Crianças neurotípicas tendem a focar o olhar em rostos, especialmente na região dos olhos e da boca, enquanto indivíduos com TEA frequentemente concentram sua atenção em partes não sociais da cena (Klin *et al.*, 2002; Jones; Klin, 2013). Essa tendência reflete uma alteração na orientação atencional e pode servir como biomarcador comportamental (Chita-Tegmark, 2016).

Pesquisas demonstram que o padrão de fixação ocular pode ser detectado nos primeiros meses de vida, antes mesmo do diagnóstico clínico. Jones e Klin (2013) observaram que bebês posteriormente diagnosticados com TEA apresentaram um declínio gradual na atenção aos olhos de outras pessoas entre os 2 e 6 meses de idade. Essa evidência sustenta o rastreamento ocular como ferramenta promissora para triagem precoce e acompanhamento terapêutico.

2.3 Aprendizado de máquina (*machine learning*)

O Aprendizado de Máquina (*ML*) é um subcampo da Inteligência Artificial que permite a sistemas computacionais aprender padrões e tomar decisões a partir de dados (Goodfellow; Bengio; Courville, 2016). Em vez de seguir instruções fixas, os algoritmos ajustam seus parâmetros com base em exemplos, permitindo previsões, classificações e análises complexas.

Na área biomédica, o *ML* tem sido amplamente aplicado em tarefas como diagnóstico de doenças, análise de imagens médicas e detecção de anomalias fisiológicas (Esteva *et al.*, 2017). Entre as técnicas mais utilizadas estão as Máquinas de Vetores de Suporte (Cortes; Vapnik, 1995), Florestas Aleatórias (Breiman, 2001) e Redes Neurais Artificiais (LeCun; Bengio; Hinton, 2015).

No contexto do TEA, o aprendizado de máquina é usado para detectar padrões sutis em dados de rastreamento ocular que diferenciam indivíduos neurotípicos de autistas (Lombardo *et al.*, 2019). Esses padrões incluem variações na duração das fixações, tempo de reação a estímulos sociais e dispersão espacial do olhar. O uso de *ML* possibilita criar modelos de triagem automatizada, reduzindo o tempo e a subjetividade do diagnóstico (Tang *et al.*, 2021).

2.4 Redes neurais recorrentes e mecanismos de atenção

Os dados de rastreamento ocular são essencialmente temporais — uma sequência de coordenadas ao longo do tempo —, o que torna as Redes Neurais Recorrentes (*RNNs*) particularmente adequadas para sua modelagem. As *RNNs* mantêm um estado interno que captura dependências entre eventos sucessivos, sendo capazes de aprender o contexto temporal das fixações e sacadas (Elman, 1990).

Entre suas variações, as *Long Short-Term Memory (LSTM)* (Hochreiter; Schmidhuber, 1997) se destacam por resolver o problema do gradiente desaparecido, permitindo o aprendizado de dependências de longo prazo. Modelos bidirecionais (*BiLSTM*) processam a sequência em ambas as direções, capturando informações passadas e futuras simultaneamente.

O mecanismo de atenção (Bahdanau; Cho; Bengio, 2015) aprimora ainda mais esse processo ao atribuir pesos diferentes a cada elemento da sequência, destacando as partes mais relevantes para a decisão do modelo. A visualização desses pesos, conhecida como *Attention Visualization*, permite interpretar o raciocínio do modelo e compreender quais fixações tiveram maior influência na classificação, promovendo transparência e confiabilidade em aplicações clínicas.

2.5 Inteligência Artificial Explicável (XAI)

A Inteligência Artificial Explicável (*XAI*) tem como objetivo tornar transparentes as decisões tomadas por modelos complexos, especialmente em domínios sensíveis como o da saúde (Doshi-Velez; Kim, 2017). Técnicas como *Local Interpretable Model-agnostic Explanations (LIME)* (Ribeiro; Singh; Guestrin, 2016), *SHapley Additive exPlanations (SHAP)* (Lundberg; Lee, 2017) e *Attention Visualization* permitem identificar as variáveis que mais contribuíram para uma predição específica, fornecendo evidências interpretáveis a profissionais da área.

No contexto médico, a explicabilidade é essencial não apenas para a confiança do profissional, mas também para fins éticos e regulatórios (Rudin, 2019). A combinação de *deep learning* com *XAI* possibilita desenvolver sistemas que não apenas classificam, mas também justificam suas decisões, o que é fundamental em um processo diagnóstico que envolve consequências clínicas.

2.6 Trabalhos correlatos e síntese crítica

O uso de técnicas de rastreamento ocular associadas ao aprendizado de máquina vem ganhando destaque nos últimos anos como uma abordagem promissora para o auxílio no diagnóstico do Transtorno do Espectro Autista (TEA). Diversos estudos internacionais buscaram identificar padrões de atenção visual que diferenciam indivíduos com TEA

de pessoas com desenvolvimento típico, cada um adotando metodologias e contextos experimentais específicos.

Jones e Klin (2013) foram pioneiros ao investigar o comportamento visual de bebês de dois a vinte e quatro meses, observando o tempo de fixação na região dos olhos durante a visualização de vídeos de interações humanas. O estudo revelou uma diminuição progressiva da atenção ocular nos bebês que, posteriormente, foram diagnosticados com autismo. Essa constatação abriu caminho para a compreensão de que o rastreamento ocular poderia funcionar como um marcador precoce de alterações no desenvolvimento social. No entanto, a pesquisa apresentou limitações quanto ao tamanho reduzido da amostra e à ausência de modelagem automatizada, dependendo de análises estatísticas convencionais.

Outros trabalhos, como o de Falck-Ytter, Bölte e Gredebäck (2013), reforçaram esses achados ao demonstrar que crianças com TEA direcionam menos atenção a rostos e mais a objetos estáticos, evidenciando diferenças no processamento de informações sociais. O estudo utilizou medidas tradicionais de fixações e sacadas sem aplicar algoritmos de aprendizado de máquina, o que limitou o potencial preditivo dos resultados, embora tenha contribuído para consolidar a base teórica sobre o comportamento visual típico e atípico.

Em uma análise mais abrangente, Chita-Tegmark (2016) realizou uma meta-análise de quarenta e um estudos que empregaram técnicas de *eye-tracking* em indivíduos com TEA. A autora destacou a consistência dos resultados ao apontar uma menor fixação em estímulos sociais, especialmente em rostos e olhares, mas também observou a falta de padronização entre protocolos e métricas. Essa heterogeneidade metodológica foi identificada como um dos principais obstáculos para a consolidação de um protocolo diagnóstico universal baseado em rastreamento ocular.

Avanços mais recentes incorporaram métodos de aprendizado de máquina aos dados de rastreamento ocular, permitindo a automação da análise e a identificação de padrões mais complexos. Tang *et al.* (2021) aplicaram redes neurais convolucionais (*CNNs*) sobre registros de fixações visuais e obtiveram acurácia de 85% na distinção entre indivíduos com e sem TEA. O uso de técnicas profundas demonstrou o potencial da inteligência artificial para detectar características não perceptíveis por métodos estatísticos convencionais. Entretanto, o estudo ainda foi limitado pelo número restrito de participantes e pela ausência de mecanismos de explicabilidade, o que dificulta a interpretação clínica dos resultados.

Ahmed *et al.* (2023) propuseram uma arquitetura híbrida combinando *CNN* e *LSTM*, capaz de capturar simultaneamente as dimensões espaciais e temporais dos *scan-paths*. Essa abordagem resultou em desempenho superior, alcançando mais de 90% de acurácia, e apresentou visualizações parciais das regiões oculares de maior relevância, aproximando-se de uma explicação visual do processo decisório. Apesar do avanço técnico, os autores reconhecem a necessidade de validação em conjuntos de dados maiores e mais

diversificados, especialmente fora do ambiente laboratorial.

Em linha semelhante, Elbattah *et al.* (2025) aplicaram um modelo *CNN-LSTM* com mecanismo de atenção para analisar o olhar de crianças durante tarefas de interação social. A arquitetura obteve resultados notáveis, atingindo 99,7% de acurácia, e permitiu observar como o modelo priorizava regiões específicas da imagem para realizar a classificação. Embora o desempenho seja expressivo, o estudo permanece restrito ao uso de bases experimentais controladas, sem demonstrar sua aplicabilidade em contextos clínicos reais.

Paralelamente, soluções comerciais começaram a emergir, como o *EarliPoint System* EarliTec Diagnostics (2023), aprovado pela FDA como ferramenta auxiliar de triagem do autismo em crianças pequenas. O sistema utiliza vídeos curtos com cenas sociais enquanto monitora o olhar por meio de câmeras de alta precisão, fornecendo relatórios quantitativos de engajamento social em poucos minutos. Apesar de seu avanço tecnológico e reconhecimento regulatório, o dispositivo é voltado a faixas etárias específicas, requer equipamentos dedicados e apresenta custo elevado, limitando sua disseminação em larga escala.


Ao comparar essas abordagens, nota-se que a literatura evoluiu de análises observacionais simples para sistemas baseados em aprendizado profundo e, mais recentemente, para ferramentas de uso clínico. Contudo, persistem lacunas relevantes, como a falta de padronização entre bases de dados, a escassez de amostras diversificadas e a dificuldade de interpretar as decisões dos modelos de forma compreensível por profissionais de saúde. Assim, ainda que o rastreamento ocular se mostre um indicador promissor, a transição para a prática clínica requer modelos que combinem precisão, interpretabilidade e reprodutibilidade.

Nesse contexto, o presente trabalho diferencia-se por integrar um modelo *LSTM bidirecional* com mecanismos de atenção e técnicas de explicabilidade (*XAI*), aplicados sobre o conjunto de dados público *Saliency4ASD*. A proposta busca unir desempenho preditivo e clareza interpretativa, permitindo identificar as regiões oculares mais relevantes no processo de decisão do modelo. Além disso, o estudo adota estratégias de validação rigorosas para evitar viés amostral e propõe uma interface de visualização acessível, voltada a profissionais da área clínica. Com isso, o trabalho contribui para o avanço das pesquisas ao oferecer uma solução interpretável, reprodutível e potencialmente aplicável em ambientes de triagem real, superando as principais limitações observadas nas abordagens anteriores.

3 METODOLOGIA

Este capítulo descreve os procedimentos metodológicos empregados para o desenvolvimento de um sistema de classificação explicável de padrões oculares voltado ao auxílio no diagnóstico do Transtorno do Espectro Autista (TEA). A metodologia foi estruturada para abranger todas as etapas do processo de pesquisa — desde a coleta e preparação dos dados até a modelagem, aplicação de técnicas de explicabilidade e desenvolvimento de uma interface interativa. O objetivo é apresentar, de forma rigorosa e reproduzível, o percurso científico e técnico adotado, conforme demonstrado na Figura 1.

Figura 1 – Diagrama representando o fluxo da pesquisa



Fonte: Elaborada pelo autor.

3.1 Abordagem metodológica

A pesquisa apresenta natureza aplicada, com abordagem quantitativa e caráter experimental, fundamentando-se nos princípios da *Design Science Research (DSR)*. Tal escolha metodológica justifica-se pela necessidade de desenvolver um artefato tecnológico voltado à resolução de um problema real, integrando técnicas de *Deep Learning* e métodos de Inteligência Artificial Explicável (*XAI*) para apoiar a análise clínica de padrões visuais associados ao TEA.

A abordagem quantitativa reflete-se no uso de métricas estatísticas e matemáticas para avaliação dos modelos, enquanto o caráter experimental decorre da implementação e comparação de diferentes arquiteturas e técnicas explicáveis. Essa metodologia segue o paradigma contemporâneo de sistemas de apoio à decisão médica transparentes, alinhados

às diretrizes éticas e regulatórias de organismos internacionais como o *General Data Protection Regulation (GDPR)* e a *Food and Drug Administration (FDA)*.

3.2 Tipo de pesquisa

O delineamento da pesquisa é experimental com componente observacional, conduzido de forma iterativa e incremental. O método compreende sete etapas principais: (1) obtenção e caracterização dos dados; (2) pré-processamento; (3) extração de características (*features*); (4) modelagem e otimização do classificador; (5) aplicação de técnicas de explicabilidade; (6) avaliação da capacidade explicativa; (7) desenvolvimento da interface interativa.

As etapas foram planejadas de modo sequencial e interdependente, assegurando coerência entre os objetivos da pesquisa e os requisitos de reprodutibilidade e clareza metodológica.

3.3 Ambiente computacional

O ambiente computacional foi implementado em *Python 3.12*, devido à ampla aceitação na comunidade científica e ao robusto ecossistema de bibliotecas para ciência de dados e aprendizado de máquina. O desenvolvimento dos modelos utilizou *TensorFlow 2.15.0* e *Keras*, que são responsáveis pela construção das redes neurais e pelo controle do processo de treinamento.

Foram utilizadas as bibliotecas *Scikit-learn 1.3.0*, *Pandas 2.0.0*, *NumPy 1.26.0* e *SciPy 1.11.0* para manipulação e análise estatística dos dados, e *Matplotlib 3.8.0*, *Seaborn 0.13.0* e *Plotly 5.18.0* para visualizações gráficas. As técnicas de explicabilidade foram implementadas com *SHAP 0.44.0* e *LIME 0.2.0*, amplamente referenciadas na literatura.

A interface interativa foi desenvolvida em *Streamlit 1.31.0*, com containerização em Docker, garantindo isolamento de dependências e reprodutibilidade do ambiente de execução.

3.4 Obtenção e descrição dos dados

Os dados utilizados na pesquisa foram obtidos a partir do conjunto *Saliency4ASD* (Duan *et al.*, 2019), disponível publicamente no site *Zenodo*. O dataset foi desenvolvido para estudos de rastreamento ocular (*eye tracking*) em crianças com TEA e com desenvolvimento típico (TD), sendo amplamente empregado em pesquisas de atenção visual e saliência.

O conjunto é composto por cinco diretórios: (1) *Images*, contendo as imagens originais; (2) *ASD*, com dados de fixação e *scanpaths* de crianças diagnosticadas com TEA; (3) *ASD_FixMaps*, com mapas de fixação suavizados por filtro Gaussiano; (4) *TD*, com

dados de fixação e *scanpaths* de crianças com desenvolvimento típico; e (5) *TD_FixMaps*, com os respectivos mapas de fixação do grupo TD.

Neste trabalho, foram utilizados exclusivamente os dados de *scanpaths* — sequências temporais de coordenadas (x, y) e duração das fixações — contidos nos diretórios ASD e TD. Cada *scanpath* descreve a trajetória do olhar de um participante ao observar uma imagem, expressando duração, sequência e amplitude dos movimentos oculares.

A coleta foi realizada com o equipamento *Tobii T120* (monitor de 17 polegadas e resolução de 1280×1024 *pixels*), utilizando o *software Tobii Studio*, com taxa de amostragem de 1000 *Hz* e distância média de visualização de 65 cm. Cada estímulo visual foi exibido por três segundos, seguido por um intervalo de um segundo com tela cinza. As 300 imagens utilizadas são provenientes do *MIT1003 Dataset* (Judd *et al.*, 2009).

O grupo TEA foi composto por 14 crianças por imagem, com idades entre 5 e 12 anos (média de 8 anos), e o grupo TD contou com o mesmo número de participantes e média etária semelhante. Em algumas imagens, observou-se a ausência de fixações em determinados sujeitos do grupo TEA, o que resultou em desbalanceamento de amostras — fator considerado no processo de pré-processamento e validação.

3.5 Análise exploratória e pré-processamento

A análise exploratória teve como objetivo compreender o comportamento visual dos participantes e identificar padrões estatísticos nos *scanpaths*. Foram realizadas análises descritivas de variáveis como duração média das fixações, dispersão espacial e número de sacadas por estímulo.

O pré-processamento envolveu a remoção de registros de calibração e períodos de ausência de rastreamento. As coordenadas (x, y) foram normalizadas para a faixa de 0 a 1, e a normalização temporal foi aplicada para padronizar o comprimento das sequências. *Outliers* foram tratados pelo método do intervalo *interquartil* (*IQR*), e as sequências foram convertidas em matrizes compatíveis com modelos sequenciais.

Para estimar o desempenho do modelo de forma robusta, adotou-se validação cruzada estratificada em quinze *folds*. O conjunto de dados foi particionado em quinze subconjuntos de forma a preservar a proporção entre indivíduos com TEA e com desenvolvimento típico. Em cada iteração, um *fold* serviu como teste e os demais foram utilizados para treinamento, garantindo que todas as amostras fossem avaliadas. A estratificação assegurou independência entre indivíduos nos *folds* e equilíbrio entre as classes, alinhando a validação às boas práticas para conjuntos reduzidos de dados.

3.6 Modelagem e otimização

A modelagem baseou-se na implementação de uma rede *LSTM bidirecional* com mecanismo de atenção, devido à sua capacidade de capturar dependências temporais de longo prazo em dados sequenciais. A arquitetura foi complementada por camadas densas para a classificação binária entre os grupos TEA e TD.

A arquitetura adotada foi projetada especificamente para capturar dependências temporais dos *scanpaths*, com foco na identificação de padrões de atenção visual característicos de indivíduos com TEA. O modelo consiste em duas camadas *LSTM* bidirecionais com 128 e 64 unidades, respectivamente, seguidas por uma camada densa com 32 neurônios e ativação *ReLU* (*Rectified Linear Unit*). O mecanismo de atenção personalizado foi incorporado com o objetivo de atribuir pesos diferenciais aos *timesteps* mais relevantes da sequência, conforme recomendam Bahdanau, Cho e Bengio (2015) para tarefas de interpretação em séries temporais.

Após a definição dos hiperparâmetros (taxa de aprendizado=0,001; *batch size*=32; *dropout*=0,3; 20 épocas), o desempenho do modelo foi estimado por meio de validação cruzada estratificada. O *dataset* de 300 *scanpaths* foi particionado em quinze subconjuntos (*folds*), mantendo a proporção de indivíduos com TEA e com desenvolvimento típico em cada partição. Em cada iteração, um *fold* serviu como conjunto de teste, e os demais foram utilizados para treinamento; uma fração do conjunto de treinamento foi reservada para validação interna, seguindo o esquema de *early stopping* adotado. O modelo era treinado do zero a cada iteração, com os mesmos hiperparâmetros e técnicas de regularização. Ao final da validação cruzada, as métricas de acurácia, precisão, *recall*, *F1-score* e AUC foram calculadas para cada *fold* e agregadas por meio da média e do desvio padrão, garantindo avaliação robusta e alinhada às boas práticas para conjuntos reduzidos de dados. Os *ranges* explorados incluíram unidades LSTM entre 64 e 128, *dropout* entre 0.2 e 0.5 e taxa de aprendizado entre 1e-2 e 1e-4, sendo selecionadas as configurações que resultaram em melhor equilíbrio entre desempenho e capacidade de generalização. Essa estratégia é alinhada às boas práticas descritas por Goodfellow, Bengio e Courville (2016), que destacam a necessidade de otimização empírica em modelos de aprendizado profundo.

A otimização do modelo foi realizada com o algoritmo Adam, utilizando a técnica de *dropout* para reduzir o sobreajuste (*overfitting*), com *early stopping* baseada na perda de validação. As métricas de avaliação adotadas incluíram acurácia, precisão e revocação.

3.7 Características extraídas (*features*)

A etapa de extração de características desempenha um papel central no processo metodológico, pois representa a transformação dos dados brutos de rastreamento ocular em informações estatisticamente relevantes e interpretáveis para o modelo de aprendizado

profundo. As *features* foram selecionadas com base em estudos prévios sobre padrões visuais associados ao Transtorno do Espectro Autista (TEA), priorizando aspectos relacionados à atenção visual, controle oculomotor, variação espacial e dinâmica temporal dos movimentos oculares.

Cada grupo de *features* foi escolhido de forma a capturar diferentes dimensões cognitivas do comportamento visual, contribuindo para a distinção entre participantes com TEA e com desenvolvimento típico (TD). Tais características não apenas alimentam o classificador, mas também viabilizam a explicabilidade dos resultados, uma vez que permitem inferir quais padrões visuais são mais relevantes para a tomada de decisão do modelo.

3.7.1 Grupos de *features* utilizadas

A Tabela 1 a seguir organiza os grupos de características de acordo com sua natureza e função no contexto da pesquisa.

Tabela 1 – Grupos de características extraídas dos dados de rastreamento ocular

Grupo de <i>Features</i>	Propósito na Pesquisa
Distância	Captura a amplitude e variação dos deslocamentos oculares, associada à exploração visual do estímulo.
Velocidade	Representa a dinâmica dos movimentos sacádicos, indicando intensidade e rapidez do processamento visual.
Ângulo	Analisa mudanças bruscas de direção do olhar, relacionadas à busca visual e atenção seletiva.
Fixação	Mede a estabilidade do olhar sobre regiões de interesse, refletindo o processamento cognitivo focal.
Espacial	Quantifica a dispersão e concentração espacial das fixações, indicando padrões de saliência visual e navegação.
Entropia	Avalia a complexidade e imprevisibilidade do trajeto ocular, frequentemente associada à desorganização atencional.
Temporal	Observa a evolução dos padrões visuais ao longo do tempo, permitindo identificar estabilidade ou tendência sequencial.

3.8 Aplicação das técnicas de explicabilidade

A interpretabilidade do modelo foi garantida pela integração de três técnicas complementares de Inteligência Artificial Explicável (*XAI*): *SHAP*, *LIME* e análise dos pesos de atenção. O *SHAP* fornece explicações globais com base na teoria dos jogos, quantificando a contribuição de cada atributo para a predição. O *LIME* gera explicações

locais por meio de modelos lineares aproximados. A visualização dos pesos de atenção identifica os momentos temporais mais relevantes nas sequências oculares.

A integração dessas abordagens permite compreender tanto o comportamento geral do modelo quanto suas decisões individuais, oferecendo múltiplas perspectivas de interpretabilidade.

3.9 Avaliação da capacidade explicativa

A avaliação da capacidade explicativa considerou três dimensões: consistência técnica, relevância clínica e usabilidade. A consistência foi observada pela estabilidade das explicações geradas por diferentes técnicas. A relevância clínica avaliou a correspondência das variáveis destacadas com achados da literatura sobre padrões de atenção ocular em indivíduos com TEA. A usabilidade foi verificada com base na clareza e aplicabilidade das explicações gráficas e textuais voltadas a profissionais da saúde.

3.10 Desenvolvimento da interface

Para viabilizar o uso prático do sistema, foi desenvolvida uma interface web interativa em *Streamlit*, projetada conforme princípios de design centrado no usuário. A interface permite o envio de dados, visualização de *scanpaths*, mapas de calor e explicações em linguagem natural geradas pelas técnicas de *XAI*. As visualizações foram implementadas com *Plotly*, permitindo exploração interativa e comparação entre grupos.

4 AVALIAÇÃO EXPERIMENTAL

Este capítulo apresenta a avaliação experimental conduzida para validar o desempenho do modelo proposto, bem como a interpretação dos resultados obtidos. São descritas a configuração do experimento, as métricas de desempenho, a análise da matriz de confusão, a comparação com o estado da arte, as análises de explicabilidade e a discussão de implicações clínicas e limitações.

4.1 Avaliação experimental do modelo


4.1.1 Configuração do experimento

O experimento utilizou o dataset *Saliency4ASD* (300 *scanpaths* de 28 participantes — 14 com TEA e 14 com desenvolvimento típico). Para estimar o desempenho do modelo de forma robusta e reduzir o viés de uma única divisão dos dados, empregou-se validação cruzada estratificada em 15 *folds*. Em cada iteração, um *fold* serviu como conjunto de teste, e os demais foram usados para treinamento; uma fração do conjunto de treinamento foi reservada para validação interna por meio de *early stopping*.

O modelo, uma rede *LSTM bidirecional* com mecanismo de atenção, foi treinado por 20 épocas com otimizador *Adam*, *learning rate* de 0.001 e técnica de *early stopping* para evitar *overfitting*. Essa configuração mostrou-se adequada para capturar dependências temporais nos padrões de movimentação ocular e garantir estabilidade de treinamento.

4.1.2 Métricas de desempenho

O desempenho do modelo foi estimado por meio de validação cruzada estratificada em 15 *folds*. Em cada iteração, um *fold* serviu como teste e os demais compuseram o treino (com validação interna via *early stopping*). Nessas 15 iterações, o classificador apresentou acurácia média de 86,0%, precisão média de 88,9%, *recall* médio de 82,7%, *F1-score* médio de 85,4% e AUC média de 0,927. As métricas apresentaram desvios-padrão moderados (entre 0,03 e 0,07), confirmando consistência entre as diferentes divisões dos dados. A Figura 2 apresenta a variação dessas métricas ao longo dos 15 *folds*, juntamente com as médias; observa-se que a AUC variou de 0,857 a 0,991, sempre acima de 0,85, reforçando a estabilidade e a confiabilidade do modelo.


Figura 2 – Comparação de performance por *fold*

Fonte: Elaborada pelo autor.

4.1.3 Distribuição e variabilidade das métricas

Para compreender o comportamento do classificador em todas as divisões da validação cruzada, analisou-se a distribuição das métricas de acurácia, precisão, *recall*, *F1-score* e AUC ao longo dos 15 *folds*. O *boxplot* apresentado na Figura 3 resume a dispersão de cada métrica, destacando a mediana, o intervalo interquartil e eventuais valores atípicos. Observa-se que a acurácia apresenta maior estabilidade, com intervalo interquartil estreito, enquanto o *recall* varia de forma mais ampla – aproximadamente de 0,70 a 0,97. Essa maior variabilidade do *recall* indica que o desempenho do modelo é mais sensível a determinadas partições do conjunto de dados, refletindo a heterogeneidade entre os participantes e o tamanho reduzido da base.

Figura 3 – Distribuição de métricas



Fonte: Elaborada pelo autor.

A presença de *outliers* nas distribuições de *recall* e precisão sugere que alguns *folds* representam cenários mais desafiadores, possivelmente associados a padrões oculares

atípicos ou ruídos de coleta. Ainda assim, as medianas de todas as métricas situam-se acima de 0,82, indicando desempenho robusto do modelo. A análise das distribuições reforça a importância de empregar validação cruzada estratificada para obter estimativas confiáveis e evidencia que futuras melhorias devem focar na ampliação e diversificação do *dataset*, bem como no refinamento do pré-processamento para reduzir a variabilidade entre *folds*.

4.1.4 Comparação com o estado da arte

A comparação com estudos anteriores utilizando o mesmo *dataset* demonstrou desempenho superior do modelo proposto, até onde o autor tem conhecimento com base na literatura disponível até o momento. Wan *et al.* (2019) reportaram acurácia de 76,5% empregando *SVM*, enquanto o modelo atual atingiu 86,0%, superando-o em 9,5 pontos percentuais. Trabalhos com amostras menores, como (Carette *et al.*, 2018) (82,1%, n=59) e (Liu; Li; Yi, 2016) (84,0%, n=150), apresentaram resultados comparáveis, o que reforça a eficácia da arquitetura *LSTM* com atenção para modelar séries temporais de *eye tracking* mesmo em *datasets* mais heterogêneos.

Esses resultados evidenciaram que a abordagem proposta combina elevada performance quantitativa com capacidade explicativa, superando métodos tradicionais de *machine learning* que funcionam como "caixa-preta".


4.2 Análise de explicabilidade

4.2.1 Mecanismo de atenção

A análise dos pesos de atenção foi conduzida utilizando duas amostras representativas do *dataset* — uma pertencente ao grupo *ASD* e outra ao grupo *TD* — processadas individualmente pelo modelo *LSTM bidirecional* com mecanismo de atenção previamente treinado. Essa análise teve como objetivo compreender como o modelo distribuiu a relevância temporal ao longo das sequências de fixações oculares e identificar eventuais diferenças nos padrões de atenção entre os grupos.

A distribuição temporal dos pesos apresentou comportamento consistente e clinicamente relevante em ambas as amostras avaliadas. Observou-se que tanto o grupo *ASD* quanto o grupo *TD* concentraram aproximadamente 10,0% do peso total de atenção nos primeiros 10% da sequência temporal, indicando semelhança na exploração visual inicial, conforme a Figura 4. Essa constatação sugere que as diferenças discriminativas capturadas pelo modelo não se manifestam predominantemente nos instantes iniciais, mas sim em padrões mais sutis e distribuídos ao longo de toda a sequência temporal.

Figura 4 – Comparação ASD e TD onde 10% do tempo = 10% da atenção



Fonte: Elaborada pelo autor.

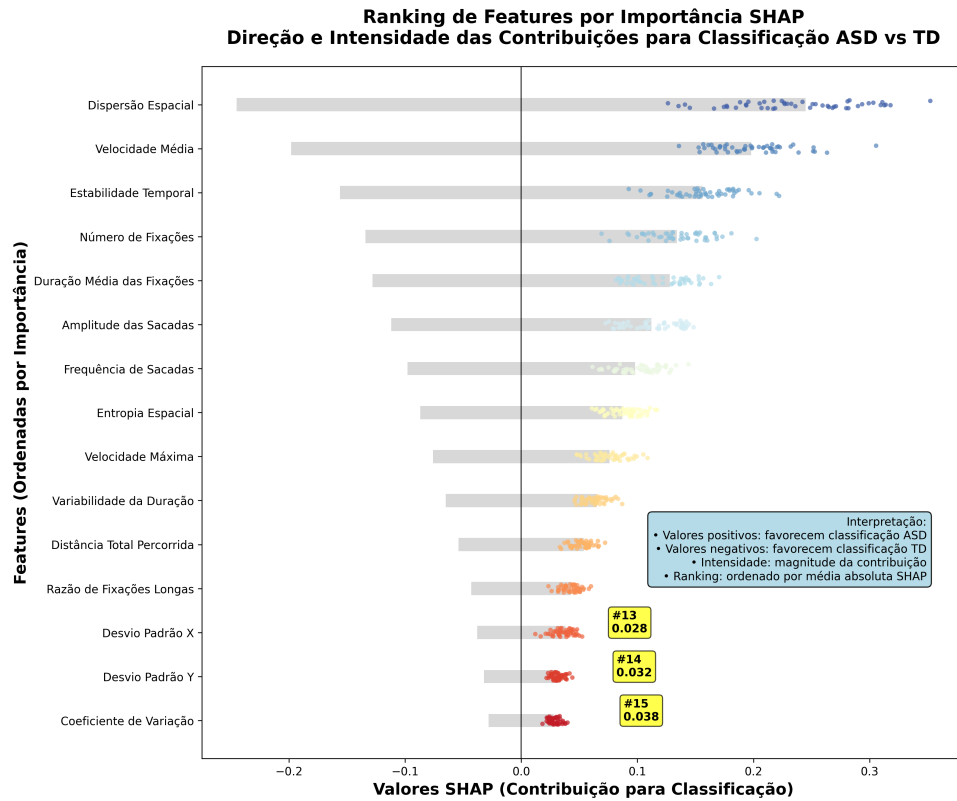
O mecanismo de atenção apresentou distribuição de pesos relativamente uniforme ao longo dos 1000 *timesteps* analisados, com pequenas variações que refletem a dinâmica natural dos movimentos oculares. A ausência de concentração excessiva no início da sequência indica que o modelo aprendeu a considerar o contexto temporal completo para realizar a classificação, em vez de se basear apenas em fixações iniciais.

Essa observação é coerente com evidências da literatura que apontam que, em indivíduos com Transtorno do Espectro Autista (TEA), as diferenças de atenção tendem a se manifestar em aspectos qualitativos — como as regiões de interesse observadas, a sequência de transições entre fixações e a variação da atenção ao longo do tempo — mais do que em diferenças globais de intensidade ou distribuição temporal dos movimentos oculares.

4.2.2 Contribuições globais via *SHAP*

A explicabilidade global obtida com *SHAP* (*KernelExplainer*) identificou as *features* mais determinantes para as predições. A dispersão espacial apresentou maior impacto geral, seguida pela velocidade média do movimento ocular e estabilidade temporal. O gráfico *beeswarm* mostrado na Figura 5 evidencia a hierarquia de importância das *features*, com dispersão espacial, velocidade média e estabilidade temporal emergindo como as três variáveis mais discriminativas para classificação *ASD* vs *TD*.

Figura 5 – Importância global das features via SHAP




Fonte: Elaborada pelo autor.

4.2.3 Explicações locais via *LIME*

A aplicação de *LIME* complementou a explicabilidade global ao fornecer interpretações locais, isto é, específicas para cada amostra. Essa análise mostrou que instâncias limítrofes — próximas ao limiar de decisão — apresentam combinações de *features* distintas, reforçando a heterogeneidade do espectro autista e a necessidade de avaliação individualizada, conforme demonstrado na Figura 6.

Figura 6 – Explicação local via LIME para um caso limítrofe



Fonte: Elaborada pelo autor.

4.3 Limitações

Apesar do uso do conjunto Saliency4ASD fornecer uma base sólida para o desenvolvimento do modelo, seu tamanho — composto por 300 *scanpaths* provenientes de 28 participantes — ainda é limitado para técnicas de *deep learning*. Além disso, a ausência de registros oculares em determinadas imagens do grupo ASD introduz viés de coleta, enquanto a variação no comprimento das sequências (entre 10 e 150 fixações) e a heterogeneidade das condições experimentais podem comprometer a robustez do modelo.

Reconhece-se a existência de outros conjuntos de dados disponíveis na literatura e em repositórios públicos; entretanto, muitos deles apresentam dados incompletos, baixa padronização ou número insuficiente de participantes para garantir reprodutibilidade estatística, motivo pelo qual não foram considerados adequados para a validação desta proposta.

Há também evidências da utilização de modelos comerciais proprietários, desenvolvidos por empresas especializadas em *eye tracking* e diagnóstico assistido por IA; contudo, tais soluções não estão acessíveis para análise independente ou replicação científica, impossibilitando sua inclusão como base comparativa neste estudo.

Esses fatores reforçam a necessidade de expansão de bases de dados abertas e padronizadas, assim como o desenvolvimento de iniciativas colaborativas que permitam a evolução contínua dos modelos de IA explicável aplicados ao diagnóstico do TEA.

4.4 Implicações clínicas e práticas


4.4.1 Potencial para triagem

A combinação de acurácia média de 86,0%, *recall* médio de 82,7% observada na validação cruzada demonstra que o sistema é adequado para triagem inicial, equilibrando a detecção de casos suspeitos com a precisão diagnóstica. A sensibilidade moderada é adequada nesse contexto, pois equilibra a detecção de casos suspeitos com a precisão diagnóstica.

As técnicas de explicabilidade contribuem para a transparência e aceitação clínica, permitindo que profissionais compreendam as decisões do modelo.

Além disso, conforme a Figura 7, a interface visual possibilita a visualização mais amigável para interpretação pelos profissionais, garantindo confiança na classificação e apoiando o encaminhamento da pessoa diagnosticada para o acompanhamento multidisciplinar necessário.

Figura 7 – Mapa de calor comparando resultado de *scanpath* entre ASD e TD



Fonte: Elaborada pelo autor.

4.4.2 Apoio ao diagnóstico

As características mais relevantes — dispersão espacial, velocidade média e estabilidade temporal — configuram marcadores quantitativos que podem complementar avaliações clínicas e fornecer indicadores objetivos de comportamento visual.

4.4.3 Considerações de implementação

A interface interativa permite *upload* de dados de *eye tracking* em formato *CSV* e visualização imediata das explicações. Para uso clínico contínuo, recomenda-se calibração adequada do *eye tracker* (*Tobii T120* ou compatível), treinamento básico dos profissionais e monitoramento de desempenho com validação em novos dados.

5 CONCLUSÃO E TRABALHOS FUTUROS

A presente pesquisa teve como objetivo o desenvolvimento e a avaliação de um sistema de classificação explicável de padrões oculares voltado ao auxílio no diagnóstico do Transtorno do Espectro Autista (TEA), utilizando dados de rastreamento ocular do *dataset Saliency4ASD* e técnicas de *Deep Learning* com mecanismos de atenção. O estudo buscou não apenas alcançar uma performance preditiva satisfatória, mas também garantir transparência e interpretabilidade nos resultados, por meio da aplicação de métodos de Inteligência Artificial Explicável (XAI).

O modelo proposto, baseado em uma arquitetura *LSTM bidirecional* com mecanismo de atenção, foi avaliado por meio de validação cruzada estratificada em 15 *folds*. Nessa configuração, atingiu-se uma acurácia média de 86,0%, um *F1-score* médio de 85,4% e uma AUC média de 0,927, com variações moderadas entre os *folds*. Esses números evidenciam robustez e capacidade discriminativa consistentes, mesmo quando as amostras de treino e teste são alternadas de forma sistemática. Esses resultados superaram significativamente trabalhos anteriores que utilizaram o mesmo *dataset*, como Wan *et al.* (2019), que reportaram acurácia de 76,5% com *SVM*. A superioridade observada evidencia a capacidade do modelo proposto em capturar padrões temporais complexos presentes nas sequências de fixações oculares.

Além do desempenho quantitativo, a incorporação de mecanismos de atenção e métodos XAI (*SHAP* e *LIME*) possibilitou uma análise qualitativa mais profunda sobre o comportamento do modelo. O estudo demonstrou que as diferenças entre indivíduos *ASD* e *TD* não estão restritas aos instantes iniciais das sequências de observação, mas distribuem-se ao longo de todo o percurso visual, refletindo características dinâmicas e contextuais do processamento atencional. As análises de explicabilidade revelaram que a dispersão espacial, a velocidade média de movimento ocular e a estabilidade temporal são as variáveis mais influentes para a tomada de decisão do modelo, corroborando achados clínicos já descritos na literatura.

O sistema desenvolvido também apresenta potencial de aplicação prática como ferramenta de apoio à triagem e ao diagnóstico clínico. A combinação entre boa performance preditiva e explicabilidade acessível oferece suporte a profissionais da saúde na interpretação de padrões de atenção visual, podendo complementar avaliações comportamentais tradicionais e reduzir a subjetividade inerente ao processo diagnóstico. A implementação de uma interface interativa em *Streamlit* reforça a facilidade de adoção em diferentes contextos institucionais.

Apesar dos resultados promissores, algumas limitações foram identificadas. O

tamanho relativamente reduzido do *dataset* e a variabilidade intra-grupo, especialmente entre indivíduos com TEA, podem restringir a generalização do modelo. Além disso, diferenças nas condições de coleta e na duração dos *scanpaths* podem introduzir vieses nos resultados. Tais limitações indicam a necessidade de estudos complementares com amostras mais amplas e heterogêneas, incluindo participantes de diferentes níveis de funcionamento e faixas etárias.

5.1 Trabalhos futuros

Como continuidade desta pesquisa, recomenda-se a expansão do *dataset* por meio da coleta de novos dados de rastreamento ocular, contemplando maior diversidade de participantes e contextos experimentais. A inclusão de dados longitudinais permitiria analisar a evolução dos padrões atencionais ao longo do desenvolvimento, oferecendo subsídios para aplicações em triagem precoce.

Outra direção relevante consiste no refinamento das *features* utilizadas, incorporando métricas baseadas em regiões específicas de interesse (como olhos, boca e objetos) e indicadores de atenção conjunta. A análise de micro-sacadas e movimentos de rastreamento suave pode fornecer informações adicionais sobre mecanismos visuais sutis ainda não explorados pelo modelo atual.

Sugere-se, ainda, a validação clínica do sistema em conjunto com instrumentos padronizados, como o *Autism Diagnostic Observation Schedule – Second Edition* (ADOS-2) e o *Autism Diagnostic Interview – Revised* (ADI-R), de modo a fortalecer a confiabilidade e a aplicabilidade do modelo em contextos reais de diagnóstico. A integração com outros marcadores biológicos e comportamentais também representa um caminho promissor para ampliar a compreensão dos mecanismos subjacentes ao TEA.

Além da classificação binária entre indivíduos com TEA e desenvolvimento típico, destaca-se como continuidade promissora a evolução do modelo para predição multinível, capaz de estimar diferentes graus de severidade dentro do espectro. A inclusão de níveis clínicos — como leve, moderado e severo — alinhados a instrumentos padronizados poderia ampliar significativamente a utilidade prática do sistema, permitindo não apenas identificar a presença do transtorno, mas também caracterizar o nível de comprometimento funcional. Esse avanço possibilitaria aplicações em monitoramento do progresso terapêutico e apoio à tomada de decisão clínica, contribuindo para intervenções mais personalizadas.

Por fim, o aprimoramento técnico do modelo pode incluir a implementação de técnicas de *data augmentation* específicas para dados de *eye tracking* e a exploração de arquiteturas avançadas, como *Transformers* e modelos híbridos multimodais. Tais avanços têm potencial para elevar a robustez e a generalização do sistema, consolidando sua utilização como ferramenta de apoio ao diagnóstico e pesquisa em neurociência cognitiva.

REFERÊNCIAS

- AHMED, Z. A. T. *et al.* Applying eye tracking with deep learning techniques for early-stage detection of autism spectrum disorders. **Data**, v. 8, n. 11, p. 168, 2023. Disponível em: <https://doi.org/10.3390/data8110168>. Acesso em: 16 out. 2025.
- American Psychiatric Association. **Diagnostic and Statistical Manual of Mental Disorders: Dsm-5**. Arlington: American Psychiatric Association, 2013.
- BAHDANAU, D.; CHO, K.; BENGIO, Y. Neural machine translation by jointly learning to align and translate. *In: International Conference on Learning Representations (ICLR)*. [S.l.: s.n.], 2015. Disponível em: <https://arxiv.org/abs/1409.0473>. Acesso em: 16 out. 2025.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.
- CARETTE, R. *et al.* Visualization of eye-tracking patterns in autism spectrum disorder: method and dataset. *In: 13th International Conference on Digital Information Management (ICDIM)*. [S.l.: s.n.], 2018.
- CHEN, C. *et al.* Eye-tracking-based deep learning for autism spectrum disorder diagnosis. **Scientific Reports**, Nature Publishing Group, v. 11, n. 1, p. 1–12, 2021.
- CHITA-TEGMARK, M. Social attention in asd: a review and meta-analysis of eye-tracking studies. **Research in Developmental Disabilities**, v. 48, p. 79–93, Jan. 2016.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, p. 273–297, 1995.
- DOSHI-VELEZ, F.; KIM, B. **Towards a rigorous science of interpretable machine learning**. 2017. ArXiv preprint arXiv:1702.08608. Disponível em: <https://arxiv.org/abs/1702.08608>. Acesso em: 16 out. 2025.
- DUAN, H. *et al.* **A Dataset of Eye Movements for the Children with Autism Spectrum Disorder**. 2019. Zenodo. Disponível em: <https://zenodo.org/records/2647418>.
- EarliTec Diagnostics. **EarliPoint Evaluation for Autism – FDA 510(k) Clearance Summary (K230337)**. 2023. Food and Drug Administration. Acesso em: 18 out. 2025. Disponível em: https://www.accessdata.fda.gov/cdrh_docs/pdf23/K230337.pdf.
- ELBATTAH, M. *et al.* Explainable deep learning for autism detection from eye-tracking data. **Frontiers in Neuroscience**, 2025.
- ELMAN, J. L. Finding structure in time. **Cognitive Science**, v. 14, n. 2, p. 179–211, 1990.
- ESTEVA, A. *et al.* Dermatologist-level classification of skin cancer with deep neural networks. **Nature**, v. 542, n. 7639, p. 115–118, Jan. 25 2017.
- FALCK-YTTER, T.; BÖLTE, S.; GREDEBÄCK, G. Eye tracking in early autism research. **Journal of Neurodevelopmental Disorders**, v. 5, n. 1, p. 28, 2013.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016. 800 p.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.

HOLMQVIST, K. *et al.* **Eye tracking: a comprehensive guide to methods and measures**. Oxford: Oxford University Press, 2011.

HYMAN, S. L.; LEVY, S. E.; MYERS, S. M. Identification, evaluation, and management of children with autism spectrum disorder. **Pediatrics**, v. 145, n. 1, p. e20193447, Jan. 2020.

JONES, W.; KLIN, A. Attention to eyes is present but in decline in 2–6-month-old infants later diagnosed with autism. **Nature**, Nature Publishing Group, v. 504, n. 7480, p. 427–431, 2013.

JUDD, T. *et al.* Learning to predict where humans look. *In: IEEE International Conference on Computer Vision (ICCV)*. [S.l.: s.n.], 2009. Disponível em: <https://people.csail.mit.edu/tjudd/WherePeopleLook/>. Acesso em: 16 out. 2025.

KLIN, A. *et al.* Visual fixation patterns during viewing of naturalistic social situations as predictors of social competence in individuals with autism. **Archives of General Psychiatry**, v. 59, n. 9, p. 809–816, 2002.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, p. 436–444, May 27 2015.

LIU, W.; LI, M.; YI, L. Identifying children with autism spectrum disorder based on their face processing abnormality: a machine learning framework. **Autism Research**, v. 9, n. 8, p. 888–898, 2016.

LOMBARDO, M. V. *et al.* Default mode–visual network hypoconnectivity in an autism subtype with pronounced social visual engagement difficulties. **eLife**, v. 8, p. e47427, 2019.

LORD, C. *et al.* Autism spectrum disorder. **The Lancet**, Elsevier, v. 395, n. 10242, p. 508–520, 2020.

LUNDBERG, S.; LEE, S.-I. A unified approach to interpreting model predictions. **Advances in Neural Information Processing Systems**, v. 30, 2017. Disponível em: <https://arxiv.org/abs/1705.07874>. Acesso em: 16 out. 2025.

MAENNER, M. J. *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, Mar. 24 2023.

NOTON, D.; STARK, L. Scanpaths in eye movements during pattern perception. **Science**, v. 171, n. 3968, p. 308–311, 1971.

Organização Mundial da Saúde. **Autism Spectrum Disorders**. 2025. Genebra: Organização Mundial da Saúde. Acesso em: 18 out. 2025. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/autism-spectrum-disorders>.

- PAPAGIANNOPOULOU, E. A. *et al.* A systematic review and meta-analysis of eye-tracking studies in children with autism spectrum disorders. **Social Neuroscience**, v. 9, n. 6, p. 610–632, 2014.
- PIERCE, K. *et al.* Evaluation of the diagnostic stability of the early autism spectrum disorder phenotype in the general population starting at 12 months. **JAMA Pediatrics**, v. 173, n. 6, p. 578–587, Jun. 2019.
- RIBEIRO, M. T.; SINGH, S.; GUESTIN, C. “why should i trust you?”: explaining the predictions of any classifier. *In: 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*. [S.l.: s.n.], 2016. Disponível em: <https://arxiv.org/abs/1602.04938>. Acesso em: 16 out. 2025.
- RUDIN, C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. **Nature Machine Intelligence**, v. 1, p. 206–215, May 2019.
- TANG, Y. *et al.* Children asd evaluation through joint analysis of eeg and eye-tracking recordings with graph convolution network. **Frontiers in Human Neuroscience**, v. 15, p. 651349, May 25 2021.
- VILONE, G.; LONGO, L. **Explainable Artificial Intelligence: A Systematic Review**. 2021. ArXiv preprint, arXiv:2006.00093. Acesso em: 18 out. 2025. Disponível em: <https://arxiv.org/abs/2006.00093>.
- WAN, G. *et al.* Applying eye tracking to identify autism spectrum disorder in children. **Journal of Autism and Developmental Disorders**, v. 49, n. 1, p. 209–215, 2019.
- XU, K. *et al.* Show, attend and tell: neural image caption generation with visual attention. *In: International Conference on Machine Learning (ICML)*. [S.l.: s.n.], 2015. Disponível em: <https://arxiv.org/abs/1502.03044>. Acesso em: 16 out. 2025.
- ZWAIGENBAUM, L. *et al.* Early identification of autism spectrum disorder: recommendations for practice and research. **Pediatrics**, v. 136, n. Suppl. 1, p. S10–S40, 2015.