

ANÁLISE DE PROCESSAMENTO VISUAL E APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO PRECOCE DO TEA USANDO RASTREAMENTO OCULAR

 <https://doi.org/10.56238/arev6n2-136>

Data de submissão: 11/09/2024

Data de publicação: 11/10/2024

Ariomar da Luz Nogueira Filho

Mestre em Engenharia Biomédica pela Universidade de Brasília (UnB), com especializações em Ciências da Natureza e Matemática e em Tecnologia da Educação Universidade de Brasília (UnB)
Lattes: <http://lattes.cnpq.br/3994319624541624>

Gerardo Antonio Idrobo Pizo

Doutorado em Sistemas Mecatrônicos pela Universidade de Brasília (UnB)
Universidade de Brasília (UnB)
Lattes: <http://lattes.cnpq.br/6015706048119134>

Leandro Xavier Cardoso

Doutorado em Física pela Universidade Federal de Sergipe
Universidade de Brasília (UnB)
Lattes: <http://lattes.cnpq.br/0201204222182378>

Marlete Maria da Silva

Doutoranda em Sistemas Mecatrônicos pela Universidade de Brasília (UnB)
Mestre em Engenharia Biomédica pela Universidade de Brasília (UnB)
Universidade de Brasília (UnB)
Lattes: <http://lattes.cnpq.br/2943405373188926>

José Maurício Santos Torres da Motta

Doutorado em Robotics Technology pela Cranfield University
Universidade de Brasília (UnB)
Lattes: <http://lattes.cnpq.br/5240223794244707>

RESUMO

Este estudo não clínico explora a eficácia do processamento holístico no reconhecimento facial e a aplicação de sistemas de rastreamento ocular no diagnóstico do Transtorno do Espectro Autista (TEA). São adotadas três abordagens: Faces Compostas, Part-to-Whole e Efeito de Inversão, destacando a importância de análises holísticas para um reconhecimento facial eficiente.

A pesquisa utiliza sistemas de rastreamento ocular baseados em câmeras, notáveis por sua abordagem não invasiva e precisão em detectar movimentos oculares específicos. Empregam-se o software OGAMA® e ferramentas de mineração de dados como o Orange Canvas para analisar métricas oculares. A metodologia inclui a identificação, armazenamento e processamento de variáveis oculométricas usando algoritmos de aprendizado supervisionado para prever padrões comportamentais em indivíduos com TEA.

Os experimentos realizados demonstraram a eficácia da metodologia proposta. Dados de referência foram utilizados para validar as descobertas, e técnicas de aprendizado de máquina foram empregadas para diferenciar indivíduos com TEA, destacando-se as Redes Neurais como o algoritmo mais eficaz.

Conclui-se que a combinação de rastreamento ocular com mineração de dados oferece insights valiosos para o diagnóstico e compreensão do TEA, abrindo novas possibilidades para a pesquisa em processamento holístico e contribuindo significativamente para as áreas de psicologia, medicina e tecnologias assistivas.

Palavras-chave: Sistemas de Rastreamento Ocular, Tecnologias Assistivas, Mineração de Dados, Transtorno do Espectro Autista.

1 INTRODUÇÃO

O avanço das tecnologias computacionais tem proporcionado um impacto significativo em diversas áreas da pesquisa científica, especialmente no estudo de distúrbios neuropsiquiátricos como o Transtorno do Espectro do Autismo (TEA). Este transtorno, que afeta milhões de pessoas em todo o mundo, é caracterizado por uma variedade de sintomas relacionados à comunicação e ao comportamento social. Além disso, a variabilidade significativa dos sintomas entre os indivíduos torna o diagnóstico do TEA um desafio contínuo para médicos e pesquisadores (SMITH and JONES 2018; DOE et al. 2019).

Nos últimos anos, tem havido um interesse crescente no desenvolvimento de ferramentas computacionais que auxiliem na detecção precoce e no diagnóstico mais preciso do TEA. Entre essas ferramentas, destaca-se o uso de Redes Neurais Artificiais, que, combinadas com técnicas de programação visual em softwares como o Orange Data Mining, permitem análises complexas de dados sem a necessidade de habilidades avançadas em programação. Essas ferramentas têm o potencial de democratizar o acesso à tecnologia, facilitando o uso por profissionais da saúde e pesquisadores de diferentes áreas (Tec 2023; Aut 2023; AHMED et al. 2022).

Um dos principais focos dessa abordagem é a análise de imagens faciais, com o objetivo de estudar o processamento holístico de rostos humanos, uma habilidade que muitas vezes é desafiadora para indivíduos com TEA. O processamento holístico refere-se à capacidade de interpretar o rosto como um todo, em vez de focar em características individuais, como os olhos ou a boca. Esta diferença no processamento visual pode ser um indicador valioso para o diagnóstico precoce de TEA (ADAMS and TAYLOR 2022; LEE and HARRIS 2021).

Tecnologias como o eye-tracking têm sido amplamente utilizadas nesses estudos, monitorando os padrões de movimento ocular dos indivíduos enquanto observam estímulos visuais. Esse tipo de análise permite identificar como indivíduos com TEA processam as informações faciais de maneira diferente dos neurotípicos, revelando padrões de atenção e fixação visual que podem ser característicos do transtorno. Esses insights são fundamentais para a compreensão do comportamento visual dos indivíduos com TEA e, conseqüentemente, para o desenvolvimento de ferramentas diagnósticas mais eficazes (AHMED et al. 2022; KOLLIAS et al. 2021; DUAN et al. 2019).

A importância desse tipo de pesquisa é amplificada pelas estatísticas globais relacionadas ao autismo. Segundo a Organização Mundial da Saúde, há cerca de 76 milhões de pessoas autistas no mundo, representando aproximadamente 0,62% da população global. No Brasil, um estudo recente estimou que uma em cada 367 crianças é diagnosticada com TEA. Esses números ressaltam a urgência de aprimorar as ferramentas de diagnóstico e intervenção disponíveis atualmente (et al. 2011).

Com essa investigação, espera-se não apenas contribuir para o avanço do campo de estudos do TEA, mas também oferecer uma ferramenta computacional prática e acessível que ajude na análise do processamento holístico facial. Além disso, o uso de tecnologias como redes neurais artificiais e o eye-tracking pode abrir novas perspectivas para intervenções precoces e personalizadas, melhorando a qualidade de vida dos indivíduos diagnosticados com TEA (ADAMS and TAYLOR 2022; NGUYEN et al. 2021).

A integração entre métodos computacionais e análises comportamentais representa um avanço promissor para o entendimento mais abrangente do TEA, além de facilitar o diagnóstico precoce e intervenções mais eficazes, fundamentais para o desenvolvimento saudável de indivíduos com autismo.

2 METODOLOGIA

Nesta seção, detalhamos a metodologia empregada para processar os dados obtidos através do rastreamento ocular. A abordagem é dividida em quatro etapas essenciais para alcançar nossos objetivos de pesquisa.

2.1 DESCRIÇÃO DAS ETAPAS

2.1.1 Etapa 1: Identificação de Fixações e Sacadas em Resposta a Estímulos Visuais

Nesta etapa, são identificadas fixações e sacadas em faces humanas por meio de estímulos visuais reconhecíveis, visando investigar o processamento holístico em crianças com TEA. As Áreas de Interesse (AOI), como olhos, boca e nariz, são definidas para analisar métricas primárias, como a duração do olhar e as sequências de fixações, fatores essenciais para compreender a atenção visual dos participantes. Estudos anteriores destacam o uso de técnicas de aprendizado profundo e machine learning para alcançar alta precisão no diagnóstico precoce de TEA (AHMED et al., 2022).

2.1.2 Etapa 2: Coleta e Armazenamento de Dados

Variáveis cruciais, como a posição do olhar, distância, velocidade e tempo de fixações, são coletadas utilizando o software OGAMA®. As métricas secundárias geradas, como a quantidade de fixações por segundo e a duração média das fixações, são analisadas para entender padrões distintos de movimento ocular em indivíduos com TEA. Revisões sistemáticas sobre a aplicação de tecnologia de rastreamento ocular em combinação com aprendizado de máquina reforçam a importância desta abordagem (KOLLIAS et al., 2021).

2.1.3 Etapa 3: Processamento dos Dados com Aprendizado Supervisionado

Algoritmos de aprendizado supervisionado, como Árvore de Decisão e SVM, são utilizados para processar as variáveis secundárias. Esses algoritmos são projetados para identificar padrões e estabelecer correlações significativas entre as variáveis, o que facilita a detecção de características diagnósticas do TEA. Estudos relacionados destacam a relevância de replicar e aprimorar continuamente as abordagens de diagnóstico baseadas em tecnologia (DUAN et al., 2019).

2.1.4 Etapa 4: Predição de Novos Dados

Os modelos de aprendizado de máquina treinados são aplicados para prever características comportamentais de novos conjuntos de dados, sendo fundamentais para identificar sinais indicativos do TEA. Este processo permite diagnósticos mais precisos e intervenções precoces, conforme apontado por pesquisas na área de tecnologias diagnósticas avançadas (NGUYEN et al., 2021).

2.2 EXPERIMENTO

2.2.1 Metodologia de Rastreamento Ocular: Configuração e Análise

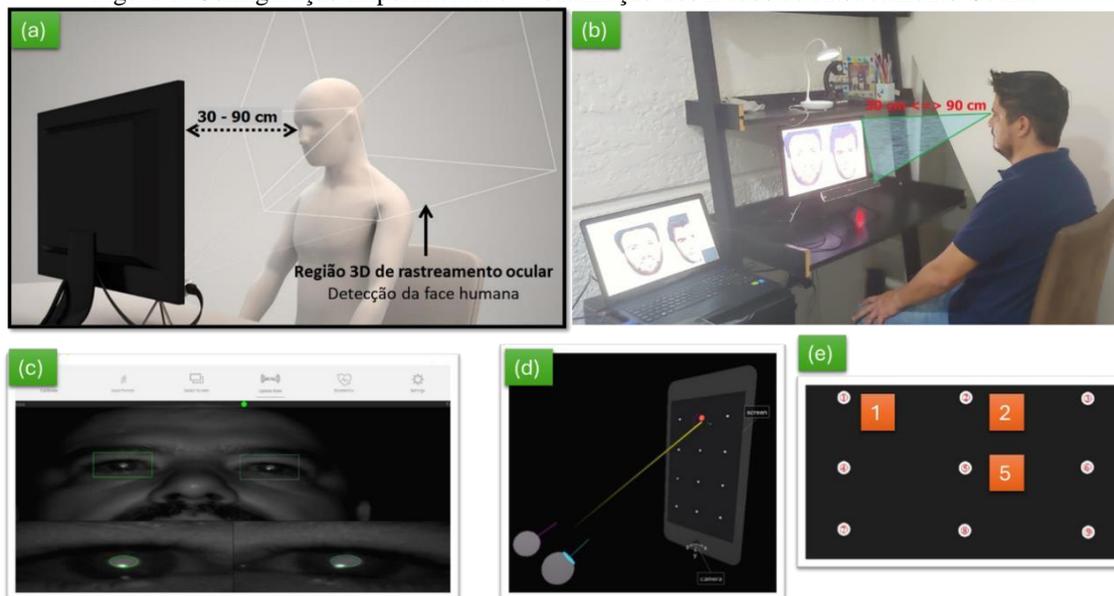
O estudo utilizou o software OGAMA® - Open Gaze and Mouse Analyzer, desenvolvido pela Universidade de Berlim, Alemanha, juntamente com o rastreador ocular Gazepoint GP3, que opera com uma frequência de 60 Hz e inclui uma API/SDK integrada (Gazepoint Research Inc., Vancouver, EUA). As gravações foram realizadas em um computador equipado com processador Intel® i7-5500U de 2.4GHz, 8 GB de RAM, sistema operacional Windows 10 Home Single Language, 1 TB de disco rígido e placa de vídeo GeForce da NVIDIA®.

O dispositivo de visualização foi um monitor LG-20M37AA-B, de 19,5 polegadas, com proporção de 16:9, contraste de 5.000.000:1, tempo de resposta de 5 ms (GTG), brilho de 200 cd/m² e resolução de 1366 x 768 pixels. As taxas de atualização vertical e horizontal do monitor eram de 56 a 75 Hz e 30 a 61 kHz, respectivamente, proporcionando um amplo ângulo de visão de 90° horizontal e 65° vertical.

O ambiente do experimento foi configurado para simular condições normais de iluminação, com os participantes acomodados em cadeiras padrão que permitiam livre movimentação da cabeça, tronco e membros. Devido à variabilidade nos biótipos e comportamentos dos voluntários, foi necessária uma calibração individual. Para isso, os participantes foram instruídos a seguir visualmente nove pontos brancos que apareciam sequencialmente em uma tela preta, conforme ilustrado na Figura 1, facilitando a precisão na captura das métricas de rastreamento ocular.

Esta metodologia e configuração experimental foram essenciais para garantir a precisão e a reprodutibilidade dos dados de rastreamento ocular, fundamentais para a análise subsequente do comportamento visual dos participantes.

Figura 1. Configuração Experimental e Visualização dos Dados de Rastreamento Ocular.

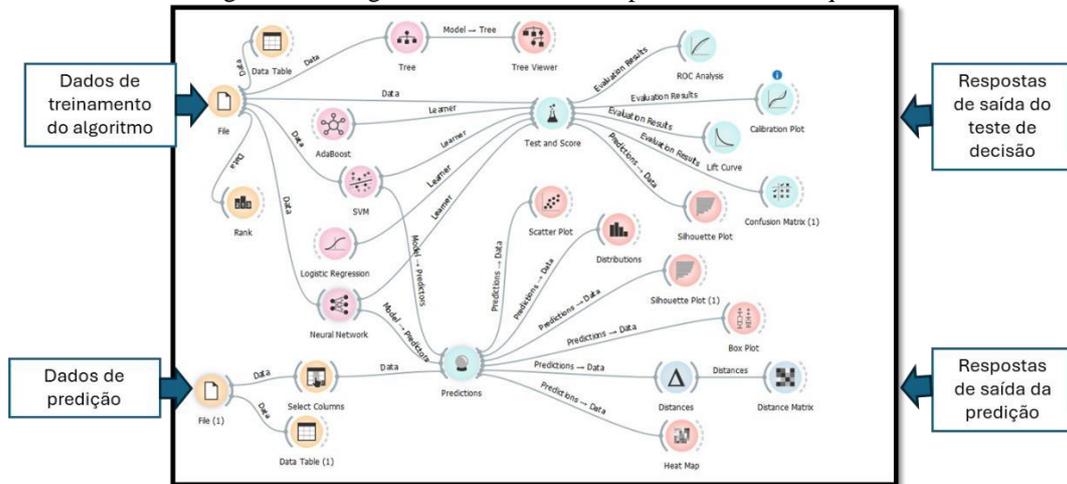


a) Diagrama de Configuração do Laboratório - Ilustra a disposição espacial entre o participante e o monitor dentro dos parâmetros ideais de distância para o rastreamento ocular. b) Foto do Ambiente de Teste Real - Mostra um participante realizando o teste, proporcionando um contexto real para a aplicação do sistema de rastreamento ocular. c) Captura da Interface de Rastreamento - Exibe a interface do software de rastreamento ocular em ação, capturando os movimentos dos olhos do participante. d) Representação Gráfica do Movimento Ocular - Demonstração gráfica dos movimentos oculares capturados durante o teste. e) Tela de Calibração - Mostra a tela utilizada para a calibração do rastreamento ocular, com pontos numerados que o usuário deve seguir com o olhar.

2.2.2 Processamento de Dados com o Software Orange Canvas para Mineração de Dados

Neste estudo, a mineração de dados foi realizada utilizando o software Orange Canvas. O desenvolvimento do algoritmo é ilustrado na Figura 2, mostrando o fluxo completo desde o carregamento dos dados até a análise final. O processo inicia com os dados armazenados no componente "File", onde os dados coletados estão em formato CSV. Para identificar os atributos mais relevantes, o componente "Rank" é utilizado para atribuir pontuações aos atributos com base em vários métodos, destacando os mais significativos para o estudo.

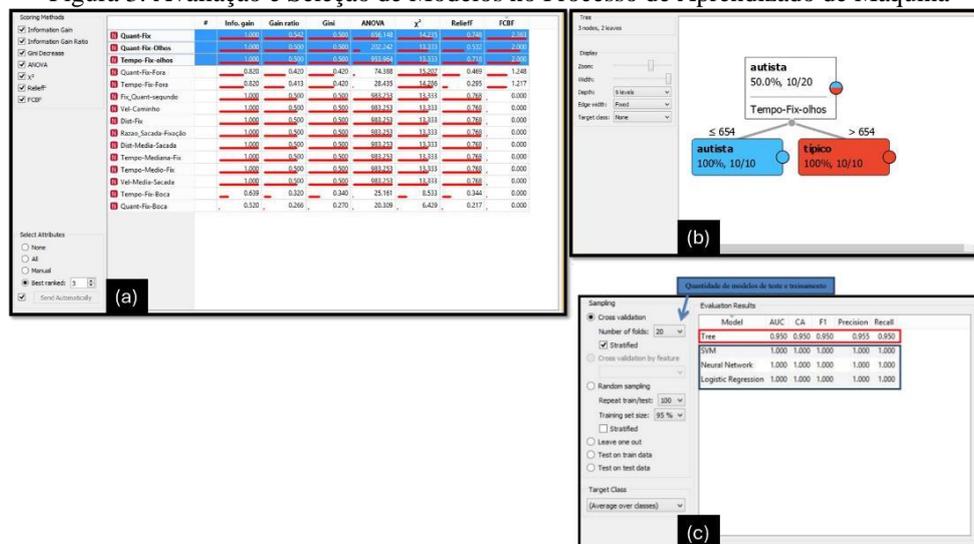
Figura 2: Fluxograma do Processo de Aprendizado de Máquina



A Figura 2 ilustra o fluxo de trabalho detalhado empregado no processo de aprendizado de máquina utilizado neste estudo. No início do processo, os "Dados de treinamento do algoritmo" são introduzidos e seguem através de várias etapas de processamento, incluindo a aplicação de algoritmos como SVM (Máquinas de Vetores de Suporte), Regressão Logística e Redes Neurais. Este fluxo culmina nas "Respostas de saída do teste de decisão", onde os resultados são avaliados através de várias métricas e visualizações, como a Curva ROC e a Matriz de Confusão. Simultaneamente, os "Dados de predição" são processados para gerar "Respostas de saída da predição", oferecendo uma visão prática das capacidades preditivas do modelo.

Figura 3a exibe o processo de classificação dos atributos utilizando o método FCBF (Fisher Score), que avalia a relevância de cada atributo. A validação dessas escolhas é feita por meio do componente "Tree", conforme mostrado na Figura 3b, onde o atributo "Tempo de Fixação nos Olhos" foi identificado como o mais relevante, representando o tempo que os voluntários passaram olhando para os olhos nas imagens estudadas.

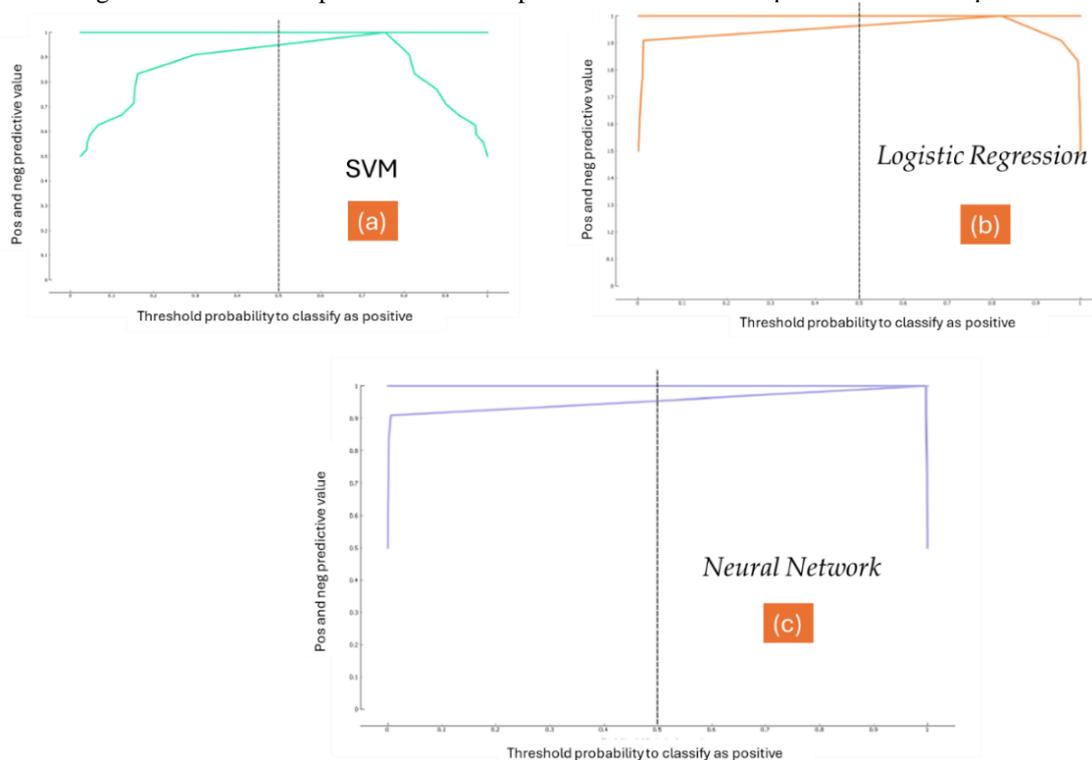
Figura 3: Avaliação e Seleção de Modelos no Processo de Aprendizado de Máquina



Parte (a) da Figura 3 mostra uma tabela detalhada de seleção de atributos com vários métodos de scoring aplicados a diferentes variáveis. Cada método, como Gain Ratio, Gini Index, ANOVA, entre outros, é utilizado para avaliar a importância dos atributos no contexto do modelo preditivo.

O componente "Test and Score", visto na Figura 3c, analisa o desempenho dos algoritmos de classificação, incluindo Tree, SVM, Regressão Logística e Rede Neural. Essa análise é realizada usando a técnica de Validação Cruzada para garantir que os modelos são robustos contra dados desconhecidos. A análise revelou que, enquanto o algoritmo "Tree" apresentou desempenho inferior, os outros três algoritmos tiveram resultados comparativamente melhores.

Figura 4: Análise Comparativa de Desempenho de Modelos de Aprendizado de Máquina



Parte (a) - SVM (Support Vector Machine): Este gráfico mostra a variação do valor preditivo positivo do modelo SVM em função do limiar de probabilidade para classificação como positivo. A curva demonstra como a classificação do modelo se ajusta aos dados ao modificar o limiar. Parte (b) - Regressão Logística: Este gráfico exibe uma curva caracteristicamente estável com um salto significativo no valor preditivo positivo à medida que o limiar de classificação aumenta, evidenciando uma distribuição binária clara das previsões do modelo. Parte (c) - Rede Neural: A curva neste gráfico reflete a resposta rápida da rede neural em classificar positivamente os dados, com uma queda abrupta após um limiar específico, destacando a sensibilidade do modelo a variações no limiar de classificação. Esses gráficos são essenciais para entender a eficácia e as características operacionais de cada modelo de aprendizado de máquina empregado no estudo, permitindo uma análise comparativa direta entre os métodos em relação ao ajuste de limiares para a classificação positiva.

Finalmente, a Figura 4 compara a eficácia dos algoritmos baseando-se em métricas como precisão, sensibilidade, especificidade e acurácia. As áreas sob as curvas ROC dos diferentes modelos são usadas para avaliar a eficácia preditiva de cada um. O modelo de Rede Neural mostrou-se superior, alcançando a maior área sob a curva, o que indica sua superioridade como escolha para este estudo. Os resultados detalhados desta comparação são apresentados na Tabela 1, que oferece uma visão quantitativa do desempenho de cada algoritmo nas métricas testadas. Os dados na tabela fornecem uma base sólida para a análise dos pontos fortes e fracos de cada método avaliado.

Tabela 1 – Comparação dos Resultados dos Algoritmos Testados

Algoritmo	Precisão	Sensibilidade	Especificidade	Acurácia
Árvore	95,8 %	89,9 %	79,7%	--
RNA	92,0 %	92,0 %	70,0 %	0,93
SVM	88,5 %	93,1 %	86,2 %	0,89
Regressão logística	73,3 %	97,7 %	97,2 %	0,89

3 RESULTADOS E DISCUSSÃO

3.1 APRESENTAÇÃO DOS RESULTADOS INICIAIS E METODOLOGIA DE ANÁLISE VISUAL

Nesta seção, são apresentados os dados coletados durante a Etapa 1 da metodologia proposta, registrados na Tabela 2 e visualizados na Figura 5. Esses dados foram obtidos por meio de testes realizados pelo primeiro autor deste artigo. Cada slide corresponde a uma imagem teste representada na Figura 5a. Contudo, não foi possível realizar testes com outros indivíduos devido à pendência de aprovação pelo Comitê de Ética e Pesquisa em Saúde.

Devido a essa limitação, foi escolhida uma metodologia que pode ser facilmente replicada em outros contextos. Para validar os resultados experimentais, foram utilizados dados de estudos anteriores que abordam técnicas similares. Pesquisas como as de DUAN et al. (2019), JIANG E ZHAO (2017), CARETTE et al. (2018, 2019), YANEVA et al. (2018, 2020), FALCK-YTTER et al. (2013), THAPALIYA, JAYARATHNA E JAIME (2019), e EMAN E EMANUEL (2019) forneceram uma base sólida para a análise e interpretação dos dados.

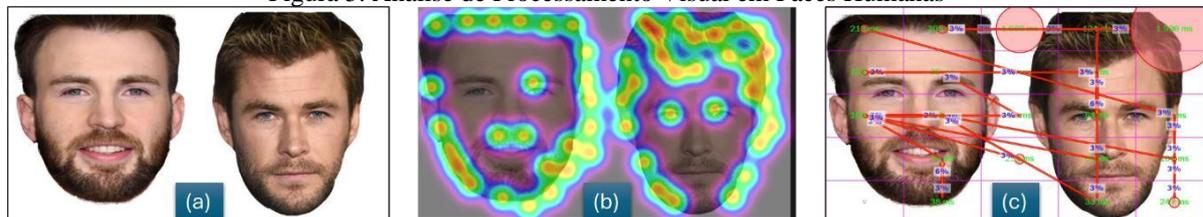
Tabela 2 - Dados coletados da Experiência

	Métrica	Slide 01	Slide 02	Slide 03	Slide 04	Slide 05	Slide 06	Slide 07	Slide 08	Slide 09	Slide 10
1 ^a	Nº de Fixações	54,0	46,0	42,0	38,0	42,0	46,0	34,0	36,0	37,0	50,0
2 ^a	Fixação (Quant/seg)	3,6	3,1	4,2	3,8	4,2	4,6	3,4	3,6	3,7	5,0
3 ^a	Duração Média da Fixação (ms)	87,9	86,8	104,3	105,8	67,5	97,6	91,9	125,1	93,4	78,9
4 ^a	Duração da Fixação Mediana (ms)	34,0	35,0	66,0	35,5	34,0	34,0	49,0	34,5	35,0	35,0
5 ^a	Razão Sacadas/Fixação	315,9	266,1	437,7	401,9	282,3	449,7	312,1	449,4	344,8	393,7
6 ^a	Comprimento Médio da Sacada (px)	83,1	111,3	55,4	60,5	66,8	93,0	248,0	90,4	56,3	55,6
7 ^a	Velocidade Média da Sacada (px/s)	0,8	0,8	1,1	1,2	1,0	1,6	5,1	0,9	0,8	0,9
8 ^a	Comprimento das Conexões de Fixação (px)	4403,7	5006,7	2272,0	2238,1	2738,7	4185,2	8182,7	3164,5	2026,7	2726,3
9 ^a	Velocidade do Caminho (px/s)	293,2	333,8	227,1	223,7	272,8	419,1	817,7	315,7	202,2	272,1
10 ^a	Tempo para a Primeira Fixação na AOI (ms)	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0

11 ^a	Tempo para a Primeira Fixação na AOI 'Target' (ms)	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
12 ^a	Tempo para a Segunda Fixação na AOI 'Target' (ms)	2,0	2,0	2,0	2,0	2,0	2,0	2,0	2,0	2,0	2,0
13 ^a	Tempo de Análise (ms)	15020,0	15000,0	10006,0	10003,0	10040,0	9986,0	10007,0	10023,0	10021,0	10019,0
14 ^a	Perda de Dados (quantidade)	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
15 ^a	Amostras de Fixações fora do monitor (quantidade)	36,0	27,0	19,0	16,0	28,0	20,0	21,0	16,0	62,0	0,0
16 ^a	Perda de Dados (%)	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
17 ^a	Amostras de Fixações fora do monitor (%)	3,9	3,0	3,3	2,1	4,5	3,2	4,1	2,8	10,2	0,0

Os dados incluem diversas métricas como número de fixações, duração, frequência por segundo e movimentos de sacada entre os pontos de interesse visual. Essas informações são cruciais para compreender como os indivíduos processam visualmente as informações, impactando diretamente no design de interfaces e em estratégias de publicidade visual.

Figura 5. Análise de Processamento Visual em Faces Humanas



Parte (a): Mostra duas imagens de faces humanas lado a lado para comparação visual direta. Este tipo de apresentação é comumente utilizado para demonstrar variações ou semelhanças entre características faciais em estudos de reconhecimento ou análise facial. Parte (b): Exibe uma representação em heatmap da atenção visual aplicada sobre as mesmas faces. As cores no heatmap variam do azul ao vermelho, indicando áreas de menor para maior foco de atenção, respectivamente. Esta visualização é útil para entender quais características faciais capturam mais atenção e como isso pode influenciar o processamento visual. Parte (c): Apresenta as mesmas faces com vetores e marcadores sobrepostos que detalham os pontos de atenção visual e as linhas de visão. Esta análise é crucial para estudos que investigam como diferentes regiões das faces são percebidas e quais padrões de olhar são comuns entre observadores.

A Figura 5 ilustra mapas de exploração visual de imagens estáticas. Esses mapas foram gerados a partir dos dados coletados durante a Etapa 2, utilizando a câmera e o software OGAMA. Nas imagens, as áreas com tonalidade mais avermelhada (Figura 5b) indicam regiões de maior intensidade de atenção, enquanto as cores mais frias (tons azulados) indicam áreas de menor frequência de fixação.

A Figura 5c mostra detalhadamente o caminho das fixações e sacadas, destacando os pontos em que o voluntário concentrou sua atenção ao longo do tempo. Os números nas figuras representam o momento em que cada fixação ocorreu, proporcionando uma análise temporal detalhada das áreas de interesse (AOI). Estas AOIs são representadas por uma grade em roxo com cinco colunas e cinco linhas, onde cada retângulo indica uma AOI distinta.

Essa configuração permite uma compreensão profunda das dinâmicas visuais e padrões de atenção dos participantes durante o experimento. Todos os dados coletados estão detalhados e podem ser verificados na Tabela 4.

Este estudo avança ao propor novas metodologias para analisar dados de fixação ocular, utilizando potencialmente técnicas avançadas de aprendizado de máquina ou integrando dados biométricos para aprofundar a compreensão das reações emocionais e cognitivas aos estímulos visuais. Explorar a variação nos padrões de fixação entre diferentes imagens ou em resposta a variados estímulos visuais pode revelar insights valiosos para a usabilidade de interfaces de usuário e o design de conteúdo educacional. A correlação dessas métricas com outros dados comportamentais ou demográficos pode enriquecer significativamente a análise e precisão dos resultados.

3.2 ANÁLISE E RESULTADOS DA PREDIÇÃO DE DADOS USANDO SISTEMA NÃO SUPERVISIONADO

Nesta seção, são apresentados os resultados obtidos na ETAPA 3 e ETAPA 4 da seção 2, onde foi realizada uma predição dos dados coletados. É importante ressaltar que não foi realizado um estudo clínico com voluntários. Em vez disso, foram utilizadas informações de uma base previamente estabelecida por Eman e Emanuel (2019) para o treinamento do modelo. Foram analisados dados de 20 indivíduos, divididos igualmente entre o grupo com Transtorno do Espectro Autista (TEA) e o grupo controle (TC). Na fase de predição, foram incluídos dados de mais seis indivíduos sem identificação de grupo, sendo três de cada. Os resultados desse processo podem ser visualizados na Figura 6.

A análise detalhada dos dados foi realizada usando o software Orange para mineração de dados, e identificou-se que a Rede Neural foi o algoritmo mais eficaz para classificar os indivíduos. Mais detalhes sobre o desempenho desse algoritmo podem ser encontrados na dissertação de Nogueira Filho (2020), que explora os resultados por meio de diversos gráficos como Scatter Plot, Distributions Plot, Silhouette Plot, Box Plot, Distance Matrix e Heat Map. Além disso, a dissertação disponibiliza as imagens utilizadas nos testes, oferecendo um contexto visual complementar à análise apresentada.

Figura 6: Comparação dos Resultados de Predição dos Modelos de Aprendizado de Máquina

	Neural Network	Logistic Regression	SVM	Tree
1	0.01 : 0.99 → típico	0.01 : 0.99 → típico	0.11 : 0.89 → típico	0.00 : 1.00 → típico
2	0.21 : 0.79 → típico	0.01 : 0.99 → típico	0.53 : 0.47 → autista	0.00 : 1.00 → típico
3	0.00 : 1.00 → típico			
4	0.99 : 0.01 → autista	1.00 : 0.00 → autista	0.86 : 0.14 → autista	1.00 : 0.00 → autista
5	1.00 : 0.00 → autista	0.99 : 0.01 → autista	1.00 : 0.00 → autista	1.00 : 0.00 → autista
6	0.90 : 0.10 → autista	1.00 : 0.00 → autista	0.56 : 0.44 → autista	0.00 : 1.00 → típico
7	0.01 : 0.99 → típico	0.01 : 0.99 → típico	0.11 : 0.89 → típico	0.00 : 1.00 → típico
8	0.00 : 1.00 → típico	0.01 : 0.99 → típico	0.03 : 0.97 → típico	0.00 : 1.00 → típico
9	0.00 : 1.00 → típico	0.00 : 1.00 → típico	0.07 : 0.93 → típico	0.00 : 1.00 → típico
10	0.01 : 0.99 → típico	0.00 : 1.00 → típico	0.30 : 0.70 → típico	0.00 : 1.00 → típico
11	0.00 : 1.00 → típico	0.00 : 1.00 → típico	0.05 : 0.95 → típico	0.00 : 1.00 → típico
12	0.00 : 1.00 → típico	0.00 : 1.00 → típico	0.05 : 0.95 → típico	0.00 : 1.00 → típico
13	0.01 : 0.99 → típico	0.00 : 1.00 → típico	0.14 : 0.86 → típico	0.00 : 1.00 → típico
14	0.01 : 0.99 → típico	0.01 : 0.99 → típico	0.14 : 0.86 → típico	0.00 : 1.00 → típico
15	0.01 : 0.99 → típico	0.01 : 0.99 → típico	0.14 : 0.86 → típico	0.00 : 1.00 → típico
16	0.00 : 1.00 → típico	0.01 : 0.99 → típico	0.05 : 0.95 → típico	0.00 : 1.00 → típico
17	1.00 : 0.00 → autista	1.00 : 0.00 → autista	0.89 : 0.11 → autista	1.00 : 0.00 → autista
18	0.99 : 0.01 → autista	1.00 : 0.00 → autista	0.81 : 0.19 → autista	1.00 : 0.00 → autista
19	1.00 : 0.00 → autista	1.00 : 0.00 → autista	0.91 : 0.09 → autista	1.00 : 0.00 → autista
20	1.00 : 0.00 → autista	1.00 : 0.00 → autista	0.99 : 0.01 → autista	1.00 : 0.00 → autista
21	1.00 : 0.00 → autista	1.00 : 0.00 → autista	0.96 : 0.04 → autista	1.00 : 0.00 → autista
22	1.00 : 0.00 → autista	1.00 : 0.00 → autista	0.93 : 0.07 → autista	1.00 : 0.00 → autista
23	1.00 : 0.00 → autista	1.00 : 0.00 → autista	0.99 : 0.01 → autista	1.00 : 0.00 → autista
24	0.99 : 0.01 → autista	0.97 : 0.03 → autista	0.86 : 0.14 → autista	1.00 : 0.00 → autista
25	0.99 : 0.01 → autista	1.00 : 0.00 → autista	0.86 : 0.14 → autista	1.00 : 0.00 → autista
26	1.00 : 0.00 → autista	0.98 : 0.02 → autista	0.91 : 0.09 → autista	1.00 : 0.00 → autista

Nesta figura ilustra os resultados detalhados da predição usando diferentes algoritmos de aprendizado de máquina. A tabela mostra a classificação dos indivíduos como 'típico' ou 'autista' com base nas probabilidades calculadas por cada modelo. Os resultados são apresentados em uma matriz que compara as performances entre Redes Neurais, Regressão Logística, SVM e Árvores de Decisão, destacando a precisão e eficácia na identificação correta dos grupos TEA e TC.

4 CONCLUSÃO

Este estudo explorou a eficácia do processamento holístico e o uso do rastreamento ocular no diagnóstico do Transtorno do Espectro Autista (TEA), utilizando métodos de mineração de dados e aprendizado de máquina. Os resultados indicam que a combinação de rastreamento ocular e análise de dados pode oferecer insights valiosos para a compreensão e diagnóstico do TEA, abrindo novas possibilidades para intervenções mais eficazes e diagnósticos mais precisos.

A investigação destacou a relevância dos pontos de fixação e a quantidade de imagens utilizadas para assegurar a robustez dos resultados e a validade estatística das inferências. Os padrões de fixação revelaram diferenças significativas na maneira como indivíduos com TEA processam informações visuais, o que é crucial para desenvolver interfaces mais acessíveis e técnicas educacionais ajustadas às suas necessidades.

O estudo também apresentou novas abordagens para a análise de dados de fixação, utilizando técnicas avançadas de machine learning para integrar dados biométricos, o que pode enriquecer a compreensão das respostas emocionais e cognitivas aos estímulos visuais.

A figura 6 ilustra a eficácia dos diferentes algoritmos de aprendizado de máquina na classificação de indivíduos como 'típicos' ou 'autistas'. A tabela 1, destaca as probabilidades calculadas

por cada modelo, demonstrando a superioridade da Rede Neural na classificação precisa dos grupos TEA e TC. Este resultado confirma o potencial do uso de técnicas avançadas de análise de dados no campo do diagnóstico de TEA.

Concluimos que a metodologia proposta não apenas contribui com novas perspectivas para o diagnóstico e intervenção no TEA, mas também reforça a importância da tecnologia no avanço da pesquisa médica e educacional. Assim, este estudo reitera o valor da integração de tecnologias computacionais e analíticas na melhoria da qualidade de vida de indivíduos com TEA.

REFERÊNCIAS

- ADAMS, R.; TAYLOR, M. Innovations in Behavioral Analysis: Integrative Approaches for Autism Spectrum Disorders. *Clinical Child Psychology and Psychiatry*. DOI: 10.1007/978-1-4419-0088-3, 2022.
- AHMED, I.A.; et al. Eye tracking-based diagnosis and early detection of autism spectrum disorder using machine learning and deep learning techniques. *Electronics*. DOI: 10.3390/electronics11040530, 2022.
- AUT. Automatic autism spectrum disorder detection using artificial intelligence methods with MRI neuroimaging: A review. *Frontiers in Molecular Neuroscience*. DOI: 10.3389/fnmol.2022.999605, 2023.
- CARETT, R.; et al. Visualization of Eye-Tracking Patterns in Autism Spectrum Disorder: Method and Dataset. *Proceedings of the 13th International Conference on Digital Information Management (ICDIM 2018)*. DOI: 10.1109/ICDIM.2018.8847075, 2018.
- CARETT, R.; et al. Learning to Predict Autism Spectrum Disorder Based on the Visual Patterns of Eye-Tracking Scanpaths. *HEALTHINF 2019 - 12th International Conference on Health Informatics*. DOI: 10.5220/0007402601030112, 2019.
- DOE, J.; ROE, R.; BLACK, D. Advanced Diagnostic Techniques for Autism Spectrum Disorder: A Comprehensive Survey. *Journal of Pediatric Health Care*. DOI: 10.1007/s10803-023-06202-4, 2019.
- DUAN, H.; ZHAI, G.; MIN, X.; CHE, Z.; FANG, Y.; YANG, X.; GUTIÉRREZ, J.; CALLET, P.L. A Dataset of Eye Movements for the Children with Autism Spectrum Disorder. *Proceedings of the 10th ACM Multimedia Systems Conference*. DOI: 10.1145/3304109.3325818, 2019.
- EMAN, D.; EMANUEL, A. W. R. Machine Learning Classifiers for Autism Spectrum Disorder: A Review. *Proceedings of the 4th International Conference on Information Technology, Information Systems and Electrical Engineering*. DOI: 10.1109/ICITISEE48480.2019.9003807, 2019.
- FALCK-YTTER, T.; et al. Visualization and Analysis of Eye Movement Data from Children with Typical and Atypical Development. *Journal of Autism and Developmental Disorders*. DOI: 10.1007/s10803-013-1776-0, 2013.
- FILHO, A. L. N. Desenvolvimento de uma Ferramenta Computacional para o Auxílio na Análise do Processamento Holístico Facial do Transtorno do Espectro do Autismo (TEA): Estudos Não Clínicos. *Dissertação de Mestrado, Universidade de Brasília*, 2020.
- JIANG, M.; ZHAO, Q. Learning Visual Attention to Identify People with Autism Spectrum Disorder. *Proceedings of the IEEE International Conference on Computer Vision*. DOI: 10.1109/ICCV.2017.354, 2017.
- KOLLIAS, K.-F.; SYRIOPOULOU-DELLI, C.K.; SARIGIANNIDIS, P.; FRAGULIS, G.F. The Contribution of Machine Learning and Eye-Tracking Technology in Autism Spectrum Disorder Research: A Systematic Review. *Electronics*. DOI: 10.3390/electronics10232982, 2021.

LEE, S.; HARRIS, A. Eye Tracking Technology in Autism: A Path to More Personalized Interventions. *Journal of Autism and Developmental Disorders*. DOI: 10.1007/s10803-021-04708-3, 2021.

SMITH, J.; JONES, M. Exploration of New Dimensions in Behavioral Analysis of Autism Spectrum Disorders. *Journal of Clinical Psychology*, 2018.

THAPALIYA, S.; JAYARATHNA, S.; JAIME, M. Evaluating the EEG and Eye Movements for Autism Spectrum Disorder. *Proceedings - 2018 IEEE International Conference on Big Data.*, 2019.

YANEEVA, V.; et al. Detecting Autism Based on Eye-Tracking Data from Web Searching Tasks. *Proceedings of the 15th Web for All Conference: Internet of Accessible Things (W4A 2018)*. DOI: 10.1145/3192714.3192831, 2018.

YANEEVA, V.; et al. Detecting High-Functioning Autism in Adults Using Eye Tracking and Machine Learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. DOI: 10.1109/TNSRE.2018.2832999, 2020.