



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
CURSO DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Arthur Gums Willrich

Uma ferramenta para coleta e análise de rastreamento de olhar para auxílio a diagnóstico de transtorno do espectro autista.

Florianópolis
2023

Arthur Gums Willrich

Uma ferramenta para coleta e análise de rastreamento de olhar para auxílio a diagnóstico de transtorno do espectro autista.

Trabalho de Conclusão de Curso do Curso de Graduação em Ciência da Computação do Centro Tecnológico da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Ciência da Computação.
Orientador: Prof. Dr. Jônata Tyska Carvalho

Florianópolis
2023

Arthur Gums Willrich

Uma ferramenta para coleta e análise de rastreamento de olhar para auxílio a diagnóstico de transtorno do espectro autista.

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Ciência da Computação” e aprovado em sua forma final pelo Curso de Graduação em Ciência da Computação.

Florianópolis, 13 de novembro de 2023.

Profa. Dra. Jerusa Marchi
Coordenador do Curso

Banca Examinadora:

Prof. Dr. Jônata Tyska Carvalho
Orientador

Prof. Dr. Renato Fileto
Avaliador
Instituição UFSC

Prof. Dr. Mateus Grellert da Silva
Avaliador
Instituição UFSC

AGRADECIMENTOS

Primeiramente, expresso minha profunda gratidão aos meus pais, Roberto e Ivete, cujo apoio e incentivo desde a minha infância foram fundamentais para me proporcionar as condições necessárias para alcançar o ponto em que me encontro hoje. Cada conselho, aviso e até mesmo broncas foram cruciais para eu chegar até aqui.

Além disso, não posso deixar de estender meu sincero agradecimento a cada colega e amigo que tive o privilégio de conhecer durante minha trajetória na universidade. A presença de cada um uma fonte valiosa de apoio durante todo o meu processo de graduação. Sem o companherismo e o suporte de vocês, essa jornada teria sido não apenas solitária, mas também consideravelmente mais desafiadora. Agradeço por cada momento compartilhado, por cada desafio superado, pois, sem dúvida, a união e colaboração tornaram essa experiência mais rica e menos árdua.

Gostaria de expressar minha profunda gratidão ao meu dedicado orientador, Jonatã, cuja orientação, auxílio, motivação e merecidas broncas foram essenciais para que eu atingisse este tão almejado objetivo.

Aos amigos que se tornaram parte obrigatória das minhas sextas-feiras desde pequeno, compartilhando não apenas sinceras e profundas gargalhadas, mas muito tempo de qualidade, comida gostosa, histórias questionáveis e momentos que irei levar para toda minha vida.

*“Quer você pense
que pode ou não,
você estará certo”
(Henry Ford, 1940)*

RESUMO

O transtorno do espectro autista (TEA) é um distúrbio que acarreta diversas adversidades na vida de quem o porta, as mais frequentes são o déficit no convívio social, as dificuldades no aprendizado, a diminuição da capacidade de processamento cerebral, a necessidade de uma rotina, entre outros. Na esfera familiar, grande parte das complicações se dá primariamente no diagnóstico deste transtorno e futuramente na convivência, devido ao fato das diversas demandas especiais necessárias indiretamente requisitadas pelo diagnosticado. Essas necessidades, caso a família não esteja preparada, causam diversos danos, como a sobrecarga física e emocional diretamente relacionadas ao estorvo da capacidade financeira e atenuação da qualidade de vida. Por não existir nenhum tipo de cura, o principal diferencial na vida dos afetados está no diagnóstico mais cedo possível. Devido à vasta quantidade de dados de sessões de testes e terapias disponíveis sobre TEA e a atual necessidade de uma análise manual dos mesmos por um especialista, foi desenvolvido este projeto. Ele busca a partir de técnicas de análise de dados e mineração de dados, analisar padrões de comportamento do olho para auxiliar no diagnóstico do TEA. Espera-se fornecer um software completo aos especialistas da área para auxiliar na identificação de padrões de atenção (eye-tracking) de interesse dentre os dados, sendo assim, diminuindo o tempo necessário da análise manual por parte de especialistas.

Palavras-chave: TEA. Diagnóstico. Análise de Dados. Monitoramento de movimento dos olhos.

ABSTRACT

Autism Spectrum Disorder (ASD) is a condition that brings various adversities to the lives of those who have it, with the most common being deficits in social interaction, learning difficulties, decreased brain processing capacity, and the need for a routine, among others. Within the family sphere, a significant portion of complications arises primarily during the diagnosis of this disorder and, subsequently, in daily interactions, due to the various special demands indirectly required by the diagnosed individual. These needs, if the family is not prepared, can cause various damages, such as physical and emotional overload directly related to the burden on financial capacity and a decrease in the quality of life. As there is no cure, the main differentiator in the lives of those affected lies in an early diagnosis. Given the vast amount of data from testing and therapy sessions available on ASD and the current need for manual analysis by a specialist, this project has been developed. It aims to use data analysis and data mining techniques to analyze eye behavior patterns to assist in the diagnosis of ASD. The goal is to provide a comprehensive software tool to specialists in the field to aid in identifying patterns of attention (eye-tracking) of interest among the data, thus reducing the time required for manual analysis by experts.

Keywords: ASD. Diagnosis. Data analysis. Eye Tracker.

LISTA DE FIGURAS

Figura 1 – Exemplo de Heatmap(Fonte: rockcontent).	17
Figura 2 – KDD Process Model, Sheikh, Asim & Alnoukari, Mouhib & El Sheikh, Asim. (2012).	19
Figura 3 – Classificação. (Fonte: Google Developers)	20
Figura 4 – Clusterização. (Fonte: Perspectivas do uso de mineração de dados e aprendizado de máquina em saúde e segurança no trabalho)	21
Figura 5 – Algoritmo do K-Means. (Fonte: K-Means Clustering in Python: A Practical Guide)	22
Figura 6 – Algoritmo do K-Means em funcionamento. (Fonte: augustocl.github.io/)	23
Figura 7 – Resultado da Pesquisa. (Fonte: (SASSON et al., 2012))	27
Figura 8 – Resultado da Pesquisa. (Fonte: (SHAW et al., 2021))	28
Figura 9 – Diagrama ilustrativo da Aplicação Fonte: Elaborado pelo autor	31
Figura 10 – Diagrama de Uso do Site Fonte: Elaborado pelo autor	32
Figura 11 – Tela de Login do Site	34
Figura 12 – Tela de Criação de Operador	34
Figura 13 – Tela de Menu de Pacientes	35
Figura 14 – Tela de Edição de Paciente	35
Figura 15 – Tabela de Menu de Registros	36
Figura 16 – Tela de Criação de Registro	36
Figura 17 – Tela de Menu de Coleta de Registro	37
Figura 18 – Tela de Criação de Pacientes	37
Figura 19 – Tela de Calibração do EyeTracker	38
Figura 20 – Vídeo com Heatmap	38
Figura 21 – Exemplo de Página de Visualizar Registro	39
Figura 22 – Visualização Segundo-a-Segundo do Cluster	39
Figura 23 – Visualização simplificada do cluster	40
Figura 24 – Exemplo de um frame fragmentado	40
Figura 25 – Diagrama do Banco de Dados Fonte: Elaborado pelo autor	42
Figura 26 – Exemplo do comportamento esperado para um paciente neuroatípico	45
Figura 27 – Exemplo do comportamento esperado para um paciente neurotípico	45
Figura 28 – Alvo para manter o olhar Fonte: Mauricio Konrath	46
Figura 29 – Demonstração de manter contato visual	48
Figura 30 – Demonstração de deslocamento ao contato visual	48
Figura 31 – Exemplo de Heatmap Paciente Neuroatípico	49
Figura 32 – Exemplo de Heatmap Paciente Neurotípico	49
Figura 33 – Exemplo de Cluster Paciente Neuroatípico	50
Figura 34 – Exemplo de Cluster Paciente Neurotípico	50

- Figura 35 – Teste de precisão do EyeTracker em ambiente com luminosidade adequada 51
- Figura 36 – Teste de precisão do EyeTracker em ambiente sem luminosidade suficiente 52

LISTA DE TABELAS

Tabela 1 – Resumo comparativo dos trabalhos relacionados Fonte: Elaborado pelo autor	29
Tabela 2 – Resultados comparativos acerca do armazenamento necessário entre vídeos categóricos Fonte: Elaborado pelo autor	47
Tabela 3 – Resultados comparativos acerca do tempo de resposta entre vídeos categóricos Fonte: Elaborado pelo autor	47

SUMÁRIO

1	INTRODUÇÃO	12
1.1	JUSTIFICATIVA	13
1.2	OBJETIVOS	14
1.2.1	Objetivo Geral	14
1.2.2	Objetivos Específicos	14
1.3	ESCOPO DO TRABALHO	15
1.4	ORGANIZAÇÃO DO TRABALHO	15
1.5	METODOLOGIA	15
1.5.1	Etapas de Execução	15
2	FUNDAMENTAÇÃO	18
2.1	CIÊNCIA DE DADOS	18
2.1.1	Processo KDD	18
2.2	MACHINE LEARNING	19
2.2.1	Tipos de machine learning	19
2.3	CLUSTERIZAÇÃO	22
2.4	ALGORITMOS DE CLUSTERIZAÇÃO	22
2.4.1	Algoritmo K-means	22
2.4.2	Algoritmo DBSCAN	23
2.4.3	Algoritmo HDBSCAN	23
2.4.4	Algoritmo OPTICS	23
2.5	TRANSTORNO DO ESPÉCTRO AUTISTA	24
2.6	TRABALHOS RELACIONADOS	25
2.6.1	Diferenciais e Inovações: Comparação com trabalhos relacionados	28
3	DESENVOLVIMENTO	30
3.1	REQUISITOS FUNCIONAIS	30
3.2	VISÃO GERAL	30
3.3	SITE	31
3.3.1	Visão Geral	31
3.3.2	Desenvolvimento	32
3.3.3	Requisições HTTP	32
3.3.4	Login	33
3.3.5	EyeTracker	33
3.3.6	Imagens	34
3.4	SERVIDOR	41
3.4.1	Visão geral	41
3.4.2	Autenticação	41
3.4.3	Banco de Dados	41

3.4.4	Técnicas de Ciências de Dados	42
3.4.4.1	Clusterização	42
3.4.4.2	Heatmap	43
3.4.5	Retorno de Mídias	43
4	TESTES E RESULTADOS	44
4.1	TESTES	44
4.1.1	Testes de Mesa	44
4.1.2	Desempenho	45
4.1.3	Calibração e Precisão	45
4.2	RESULTADOS	46
4.2.1	Tempo e Armazenamento	46
4.2.2	Teste de Mesa	48
4.2.3	Calibração e Precisão	51
4.3	DISCUSSÃO SOBRE RESULTADOS	51
5	CONCLUSÃO	53
5.1	TRABALHOS FUTUROS	53
A	CÓDIGOS FONTES	55
B	ARTIGO SBC	56
	BIBLIOGRAFIA	57

1 INTRODUÇÃO

O transtorno do espectro autista (TEA), também conhecido como autismo, é um transtorno que prejudica neurologicamente aqueles que o desenvolvem desde o nascimento ou início da infância, segundo o Manual Diagnóstico e Estatístico de Transtornos Mentais DSM-5. O autismo gera inúmeras adversidades, como padrões restritos e repetitivos de hábitos, como padrões de movimento, interesses inflexíveis e hiper ou hipossensibilidade a estímulos sensoriais, dificuldades de imaginação, além de déficits na comunicação e interação social.

O TEA não possui causas totalmente descobertas, existem evidências de que haja predisposição genética para o autismo, outros fatores possivelmente relacionados são infecções durante a gravidez e fatores ambientais que podem acabar impactando o feto, como a exposição a materiais tóxicos, desequilíbrio metabólico, estresse e complicações na gravidez.

Todavia, é notável que em alguns casos esse transtorno vem seguido de habilidades impressionantes, como a vasta atenção a detalhes e à exatidão, capacidade de memória e atenção em torno de uma determinada área de interesse específica durante um longo período de tempo acima da média e a facilidade no aprendizado de maneira visual.

O nosso cérebro possui a capacidade de se reorganizar, de modificar sua estrutura em resposta aos estímulos que recebe do meio ambiente externo, chamamos essa habilidade de neuroplasticidade. Essa habilidade é acentuada nos primeiros anos de vida. Essa remodelação cerebral permite um vigoroso processo de aquisição de novas competências, como a melhora na cognição, na linguagem socioemocional e em habilidades motoras.

Ao se falar de tratamento, devemos lembrar que o TEA não possui cura, porém o diagnóstico precoce deste transtorno é fundamental para diminuir possíveis adversidades e gerar um impacto positivo na vida da criança, visto que é na infância, onde ocorre o ápice da plasticidade cerebral, além de ser nesta fase em que ocorre o agravamento de padrões de comportamento considerados inadequados e o isolamento da criança. Entretanto, o cérebro humano possui a capacidade de se reorganizar e reestruturar de acordo com estímulos do meio externo, habilidade chamada de neuroplasticidade. Sendo assim, é possível treinar o órgão por meio de terapias o mais cedo possível para melhorar o desempenho dos neurônios responsáveis por atividades de cunho social.

Em relação à coleta de dados, a mesma é feita de maneira simples, apenas utilizando dispositivos como câmera, microfone, entre outros, e através deles é possível gerar uma grande quantidade de dados de testes, formando uma grande oportunidade para realização de pesquisa com base neles. Todavia, esse grande volume de dados também acaba se tornando um empecilho, pois a análise dos mesmos é inteiramente exercida de forma manual, tanto por pesquisadores quanto por terapeutas e especialistas na área, demandando uma grande quantidade de tempo e esforço.

1.1 JUSTIFICATIVA

Com o aumento significativo da incidência do TEA nos últimos anos, uma ferramenta para o auxílio da detecção precoce do mesmo se torna necessária. Dados estatísticos norte-americanos do CDC (Centro de Controle e Prevenção de Doenças) apontam que entre 2000 e 2002 a prevalência do TEA era de 1 a cada 150 crianças. Em 2018, esse número aumentou para 1 a cada 44, um aumento acima de 240%, além de ser quatro vezes mais incidente em meninos do que em meninas.

Desta forma, visto que a identificação de um caso de TEA nos EUA é feita antes dos 3 anos de idade e no Brasil o transtorno é identificado, em média, em crianças com idade entre 5 e 7 anos, cria-se uma necessidade de uma ferramenta para auxiliar os profissionais da área tanto no Brasil quanto em outros países. O diagnóstico tardio acarreta em diversos problemas, tanto para o paciente, que terá seus sintomas mais acentuados, quanto para a família, que muitas vezes não terá conhecimento para lidar da maneira mais adequada com essa situação.

O método de rastreio ocular é particularmente útil ao se trabalhar com crianças, pois com ele é possível acompanhar o desenvolvimento de diversos aspectos emocionais e sociais, que são diretamente afetados pelo transtorno do espectro autista. O aumento dos diagnósticos oftalmológicos ainda não é muito claro, são esperadas altas taxas de ROP (Retinopatia da Prematuridade), pois a idade gestacional mais baixa está associada à maior prevalência do TEA. Além disso, distúrbios como Ambliopia, estrabismo, neuropatia óptica e nistagmo podem ocorrer como consequência de distúrbios neurológicos, porém são casos isolados.

O objetivo deste trabalho é desenvolver uma ferramenta que possa auxiliar profissionais da saúde no diagnóstico precoce do Transtorno do Espectro Autista (TEA), fornecendo informações sobre as semelhanças e diferenças entre pessoas neurotípicas (sem TEA) e neuroatípicas (com TEA).

É importante ressaltar que essa ferramenta deve ser utilizada como um suporte para profissionais da saúde, não substituindo a avaliação e o julgamento clínico. Ela pode fornecer informações valiosas que complementam a expertise do profissional, auxiliando na tomada de decisões mais assertivas e no encaminhamento adequado para intervenções e tratamentos adequados ao TEA.

Dessa forma, o desenvolvimento dessa ferramenta busca contribuir para o diagnóstico precoce do TEA, permitindo um atendimento mais eficaz e intervenções adequadas desde as primeiras fases do desenvolvimento, o que pode ter um impacto significativo na vida das pessoas afetadas pelo transtorno.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

O objetivo principal deste trabalho é desenvolver um software que possa fornecer suporte aos profissionais de saúde na detecção de padrões de olhar em pacientes neurotípicos e neuroatípicos, permitindo que possam tomar decisões mais embasadas em casos de dúvida. O software foi projetado para analisar dados relacionados ao comportamento de fixação visual e padrões de olhar em pacientes. Esses dados são obtidos por meio de técnicas de rastreamento ocular.

Ao disponibilizar essa ferramenta aos profissionais de saúde, espera-se que eles possam utilizar as informações fornecidas pelo software como um apoio adicional em seus processos de avaliação e diagnóstico. Por exemplo, em casos de dúvida ou incerteza, o software pode gerar insights sobre os padrões de olhar observados nos pacientes, indicando a probabilidade de um diagnóstico específico ou sugerindo encaminhamentos para avaliações mais detalhadas.

O desenvolvimento desse software busca facilitar e agilizar o processo de detecção de padrões de olhar em pacientes neurotípicos e neuroatípicos, proporcionando um suporte adicional aos profissionais de saúde e contribuindo para uma avaliação mais precisa e eficiente.

1.2.2 Objetivos Específicos

1. Explicar conceitos e elementos relacionados ao TEA e as técnicas utilizadas relacionadas à análise de dados.
2. Estudar e compreender o funcionamento de ciência de dados para estar apto a aplicar os conceitos em torno do TEA.
3. Desenvolver um software que, por algoritmos de ciência de dados, possibilite a detecção de padrões de atenção (eye-tracking).
4. Desenvolver um software utilizando algoritmos de ciência de dados que seja capaz de evidenciar padrões de atenção por meio do rastreamento ocular (eye-tracking) em pacientes neurotípicos e neuroatípicos.
5. Desenvolver uma interface web para minha aplicação.
6. Estabelecer um banco de dados capaz de suportar os dados necessários para minha aplicação.

1.3 ESCOPO DO TRABALHO

Revisão do estado da arte das técnicas de aprendizado de máquina e mineração de dados que combinam abordagens acadêmicas com a aplicação insuficiente dessas técnicas no contexto do TEA. A implementação da ferramenta será realizada com o auxílio do WebGazer.js, uma ferramenta de software aberto. O ambiente de desenvolvimento escolhido será o Visual Studio Code, oferecendo suporte ao desenvolvimento de uma aplicação full stack com front-end em React e o back-end em Node, JavaScript e Python.

1.4 ORGANIZAÇÃO DO TRABALHO

A seguir está descrito como o trabalho estará organizado. O segundo capítulo apresentará diversos conceitos necessários para o entendimento completo do trabalho. No terceiro capítulo, serão apresentados trabalhos relacionados a este estudo. O quarto capítulo apresentará a metodologia proposta. O capítulo cinco trará avaliações e resultados com testes da ferramenta desenvolvida. Por fim, o sexto e último capítulo apresentará sugestões para futuras pesquisas e conclusões finais sobre este trabalho.

1.5 METODOLOGIA

O presente trabalho terá uma forma de abordagem qualitativa e quantitativa, com a realização de uma pesquisa contextual sobre o tema, além de uma coleta de dados e uma coleta de dados, visando um aprofundamento do conhecimento sobre os principais indicadores utilizados para a detecção do TEA, alcançando, então, a possibilidade de início do desenvolvimento do projeto, etapa em que serão colocados em prática os estudos realizados.

Serão aplicadas técnicas de forma exploratória, a fim de identificar tendências e detectar problemas de qualidade nos dados disponíveis.

Depois do algoritmo ser executado será feita uma análise preditiva e interpretação dos resultados gerados e irá ser feita uma avaliação para medir a validade dos resultados obtidos.

1.5.1 Etapas de Execução

O trabalho contará com as seguintes etapas de execução:

1. Estudo e coleta de dados
2. Preparação dos dados
3. Desenvolvimento e aplicações de técnicas de data mining
4. Validação dos modelos

5. Construção de uma ferramenta

A metodologia para realização deste trabalho se assemelha muito com o processo KDD, na **primeira etapa** será feita a coleta de dados, em parceria com uma instituição local voltada em auxiliar no tratamento do TEA, principalmente em crianças, a partir de uma ferramenta que será disponibilizada onde será possível, apenas com uma webcam, reconhecer para onde a criança está olhando ao passar do tempo e exportar, em formato de coordenadas, esses dados.

A partir disto poderá se iniciar a **segunda etapa**, utilizando técnicas muito comuns de exploração de dados, como sumeração estatística e visualização para que seja possível de uma maneira inicial indentificar tendencias nos diferentes tipo de comportamentos.

Posteriormente à coleta de dados e a preparação dos mesmos, serão aplicadas técnicas de data mining, dando início à **terceira etapa**, no intuito de detectar eventos e padrões de interesse para dar o suporte requisitado por pesquisadores e médicos especialistas na área acerca ao TEA.

Com base em critérios de sucessos definidos na etapa inicial, os modelos desenvolvidos e técnicas serão avaliados nesta **quarta etapa** por profissionais especialistas que apoiam este projeto, esta etapa contará também com ajustes, de maneira iterativa, na etapa anterior, a fim de permitir que novos ajustes possam vir a serem feitos para alcançar os critérios de sucesso previamente definidos.

Na **quinta e ultima etapa** será produzida uma ferramenta de software com interace e a mesma será disponibilizada em um repositório público aberto com o intuito de auxiliar na transferência do conhecimento gerado na pesquisa deste trabalho podendo assim trazer benefícios de maneira imediata para a sociedade, além do software, serão produzidos materiais e vídeos para auxiliar na utilização prática deste software, estes serão disponibilizados no repositório junto ao software.

Esta ferramenta terá algumas funcionalidades, entre elas a captura de dados, que ocorrerá da seguinte forma: Com o auxilio de uma webcam e um computador serão amostrados vídeos/imagens e feita a captura, provavelmente a uma taxa de 50Hz, de onde está voltado o olhar do indivíduo, sendo assim poderemos gerar uma vasta quantidade de dados brutos contendo coordenadas de para onde o olhar estava voltado ao longo do tempo, com esses dados poderemos gerar algumas representações, como por exemplo o heatmap.

Além disto, é importante citar que serão necessários tratamentos em cima dos dados, inclusive para tratarmos as "piscadas"do paciente, testes iniciais apontaram que existe um efeito chicote que ocorre quando o indivíduo que está tendo seu olhar rastreado pisca os olhos, as coordenadas salvas durante esse piscar tendem descolar para algum dos cantos do monitor durante alguns milisegundos e após isso retornam ao local esperado correto.

Outra funcionalidade da ferramenta será apontar os indivíduos mais prováveis de

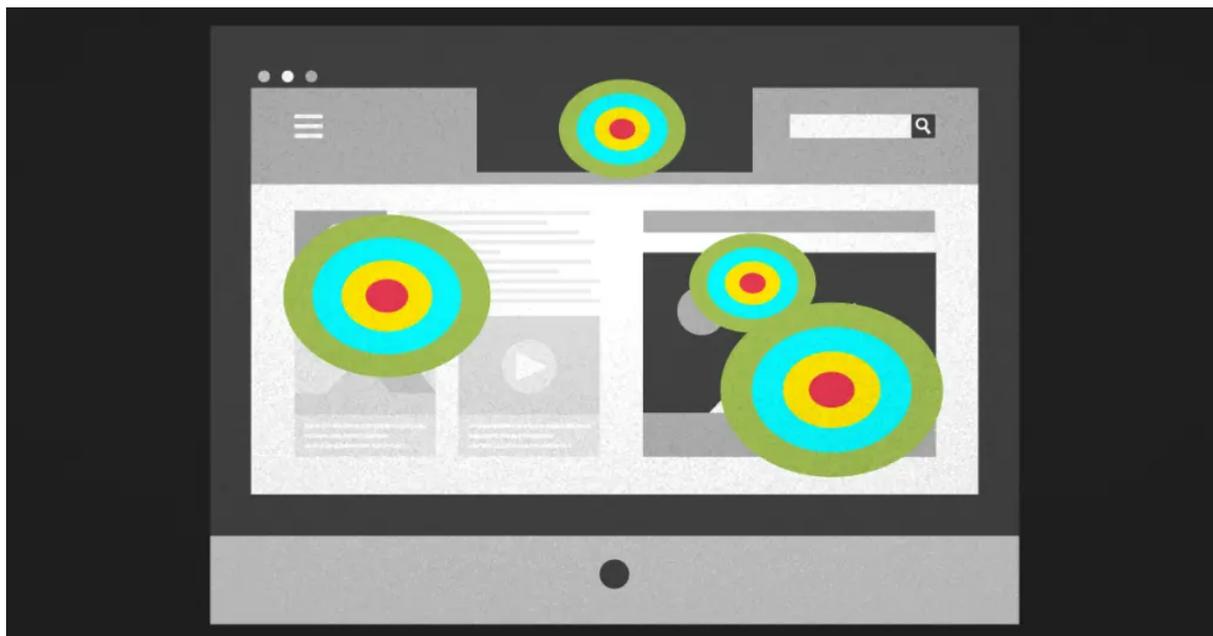


Figura 1 – Exemplo de Heatmap(Fonte: rockcontent).

se encaixar ao espectro autista. A partir de técnicas de machine learning a ferramenta será testada com uma grande base de dados providos por instituições parceiras como é o caso do Instituto Farol, instituto em Florianópolis especializado em TEA. Serão identificados padrões de indivíduos com desenvolvimento típico e atípico e estes utilizados como base para avaliarmos a possibilidade de um novo indivíduo se encaixar em cada um destes grupos.

2 FUNDAMENTAÇÃO

Neste capítulo, serão apresentados alguns conceitos de mineração e tratamento de dados, bem como as tecnologias utilizadas para a realização deste trabalho, com exemplos de código. Além disso, serão explicados e exemplificados os motivos pelos quais esses dados são tratados.

2.1 CIÊNCIA DE DADOS

A ciência de dados é uma área multidisciplinar que se dá a partir da combinação de áreas tanto da ciências da computação, quanto estatística, simplificadamente a ideia por trás desta ciência é estudar e gerar informações a partir de uma grande quantidade de dados para extrair insights que podem ser aplicados tanto em empresas do setor privado quanto do setor público.

Nesta seção, serão apresentadas técnicas e processos relacionados à ciência de dados que foram necessários para o desenvolvimento e execução deste trabalho. Nas subseções subsequentes, serão abordados o KDD, que é o principal processo utilizado na manipulação de dados, outros modelos utilizados para automatização de dados e métodos específicos.

2.1.1 Processo KDD

A descoberta de conhecimento em bancos de dados, Knowledge Discovery in Databases ou simplesmente KDD é um termo cunhado em 1989 vagamente utilizado entre os praticantes de técnicas de Data Science, ele compreende todo o processo de realizar o input de dados, pré-processá-los, realizar a mineração de dados e fazer o pós-processamento para, então, termos a informação desejada. Para FAYYAD (1994): "Descoberta de Conhecimento em Bancos de Dados é o processo não trivial de identificar padrões válidos, novos, potencialmente úteis e compreensíveis em dados"

Utilizando como base o proposto por FAYYAD o processo do KDD é composto por 5 fases, sendo elas:

- **Seleção:** Consiste em fazer a seleção dos dados que serão a ser processados e analisados, fontes destes dados podem ser planilhas, banco de dados, data warehouse, entre outros.
- **Processamento:** A fase de processamento tem a função de avaliar a qualidade dos dados selecionados previamente, nesta fase também serão feitas limpeza, correção, identificação de outliers, verificação de dados ausentes/inexistentes e até remoção desses dados.

- **Transformação:** Nesta etapa são aplicadas algumas técnicas de transformações, com o intuito de normalizar, agregar, criar novos atributos, reduzir ou simplificar os dados.
- **Mineração de dados:** Provavelmente a fase mais famosa dentre todo o processo, na fase de data mining é onde são aplicadas técnicas de data mining ou construção de um modelo para que possamos validar alguma hipótese ou descobrir padrões de forma autônoma, este trabalho utilizará ela para avaliar e detectar padrões comportamentais com base no rastreamento do olhar do paciente.
- **Interpretação e Avaliação:** Nesta etapa é feita a avaliação do sistema e de seu desempenho, aplicando dados que não foram utilizados para o treinamento do sistema, com isso podemos avaliar, com base em diversas formas, sendo elas parâmetros estatísticos ou até mesmo avaliação de algum profissional na área da pesquisa.

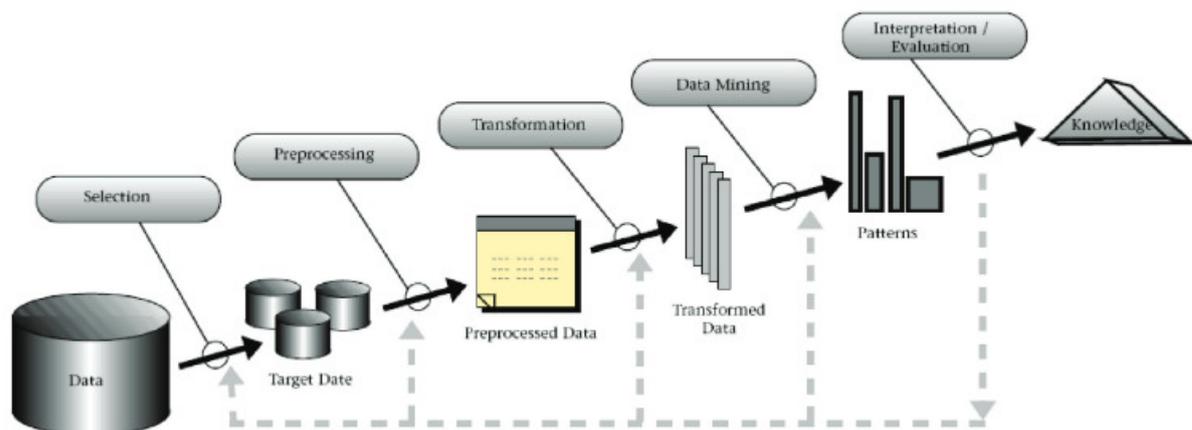


Figura 2 – KDD Process Model, Sheikh, Asim & Alnoukari, Mouhib & El Sheikh, Asim. (2012).

2.2 MACHINE LEARNING

Machine Learning ou Aprendizado de Máquina é um ramo da área de Inteligência Artificial focado em algoritmos que tentam se aproximar da maneira com que seres humanos aprendem, melhorando de maneira gradual, à partir de treinos, a sua precisão.

2.2.1 Tipos de machine learning

Como o deep learning e o machine learning tendem a ser usados de maneira alternada, é importante observar as nuances entre os dois. Machine learning, deep learning e redes neurais são todos subcampos da inteligência artificial. No entanto, o deep learning

é, na verdade, um subcampo do machine learning, e as redes neurais são um subcampo do deep learning.

- **Aprendizado de Máquina Supervisionado:** O aprendizado de máquina supervisionado é aquele que recebe dados rotulados, ou seja, dados que já possuem a "resposta" do que se deseja prever. Fica a encargo do sistema determinar a descrição para cada classe, neste tipo de aprendizado existem os seguintes modelos:
 - **Classificação:** Este modelo é possivelmente o mais popular e importante dentro da área de aprendizado de máquina, de maneira geral ele mapeia as entradas nas saídas corretamente, tentando prever a categoria de uma observação dada. Podemos citar como exemplo um classificador de email que classifica os emails entre spam e não spam, ele utiliza dados observados anteriormente para classificar dados ainda não observados.

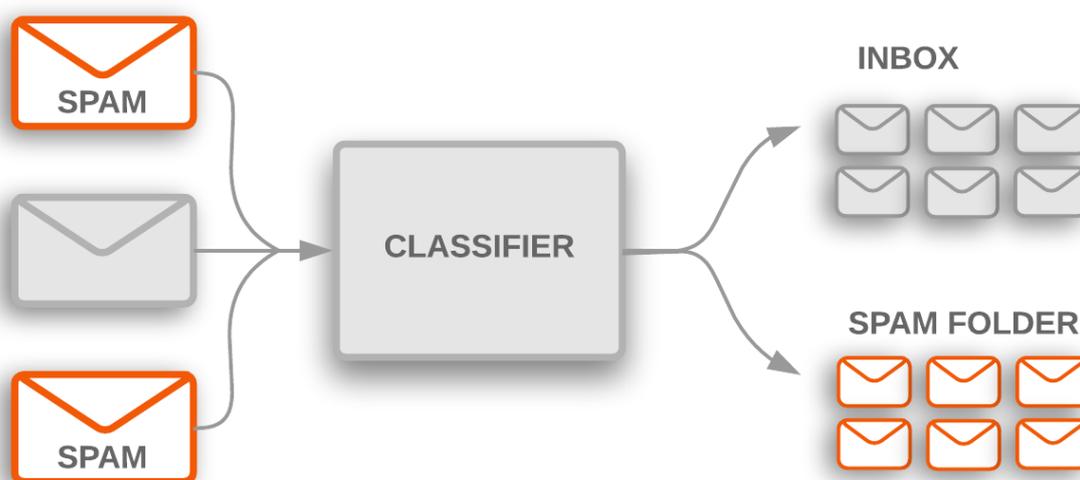


Figura 3 – Classificação. (Fonte: Google Developers)

- **Regressão:** Modelo semelhante à classificação, a grande diferença é que ao invés de classificar, neste modelo é estimado um valor numérico, como por exemplo estimar um modelo que, a partir da renda familiar, local de habitação e grau de escolaridade de indivíduos já observados anteriormente, determine a expectativa de vida de um indivíduo não observado anteriormente.
- **Aprendizado de Máquina Não-Supervisionado:** Este tipo de aprendizado utiliza algoritmos para fazer a análise e o agrupamento de conjunto de dados não rotulados, ou seja, dados sem rotulação que indentificam suas características, propriedades ou classificação. Com esse tipo de algortimo é possível encontrar agrupamentos

ou padrões ocultos, sem nenhum tipo de necessidade de intervenção humana. A capacidade deste tipo de aprendizado de descobrir semelhanças nas informações torna esta solução ideal para realizar uma análise de caráter exploratório dos dados e permite com que possamos reconhecer padrões em imagens e vídeos. Existem dois modelos no aprendizado de máquina não supervisionado, sendo eles:

- Clusterização: modelo de segmentação de dados que compartilham padrões e tendências semelhantes. Neste tipo de estudo não existe nenhuma variável dependente. Técnicas de clusterização buscam diferenças e semelhanças em um determinado conjunto de dados e agrupam os semelhantes em um segmento (cluster) de maneira automática, a partir de métricas ou critérios. Existem diversas técnicas de clusterização, cada uma com benefícios e contras, portanto é necessário o estudo para entender qual o melhor algoritmo de clusterização para cada caso. Não é necessário definir grupos ou atributos que devem ser utilizados para segmentar o conjunto de dados.

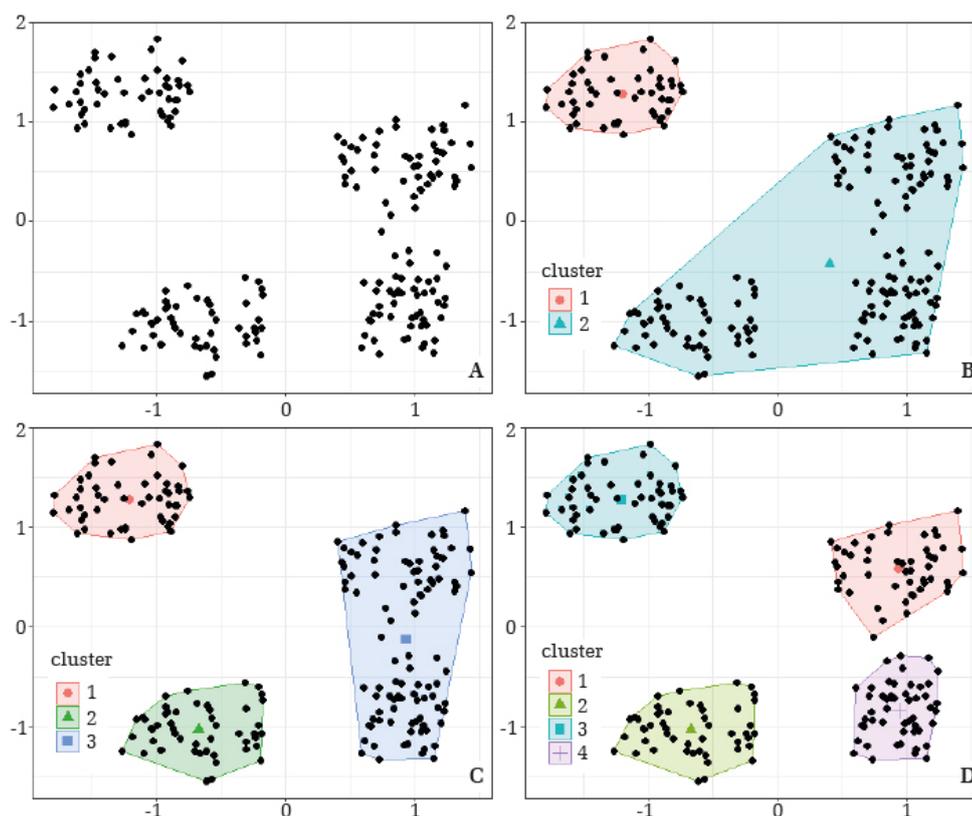


Figura 4 – Clusterização. (Fonte: Perspectivas do uso de mineração de dados e aprendizado de máquina em saúde e segurança no trabalho)

- Associação: Este modelo visa criar associações entre a ocorrência de diferentes classes nos dados, por exemplo, para entendermos quem é o público alvo para determinado anúncio, gerando modelos descritivos que permitem descobrir regras como: "Jovens entre 18 e 24 anos que cursam Ciência da Computação na

UFSC que adquirem um notebook tem 4 vezes mais probabilidade de adquirir um SSD junto, do que aqueles que não cursam"ou ainda: "Quem observa determinado produto tem interesse em ver qual outro produto relacionado?".

2.3 CLUSTERIZAÇÃO

A clusterização é uma técnica de análise de dados usada para agrupar objetos ou pontos de dados semelhantes em conjuntos chamados clusters. É uma abordagem comum em aprendizado de máquina e mineração de dados, onde o objetivo é descobrir estruturas e padrões intrínsecos nos dados. A clusterização permite identificar grupos naturais ou segmentos de dados com características semelhantes, facilitando a compreensão dos dados e a tomada de decisões. Diferentes algoritmos de clusterização podem ser aplicados, como o k-means, DBSCAN, HDBSCAN e OPTICS, cada um com suas próprias vantagens e limitações. A clusterização é amplamente utilizada em diversas áreas, incluindo ciência de dados, bioinformática, marketing e análise de redes sociais.

2.4 ALGORITMOS DE CLUSTERIZAÇÃO

Nesta subseção, serão descritos os algoritmos de clusterização utilizados na aplicação deste trabalho.

2.4.1 Algoritmo K-means

Um dos algoritmos para fazer agrupamentos de pontos ou clusters mais utilizado é o K-means. Cada um dos pontos é associado com uma centróide onde cada instância é atribuída ao cluster (com centróide) mais próximo. Este algoritmo é bastante simples, ele consiste em definir o número de centróides aleatoriamente e entra em loop atribuindo os pontos mais próximos das centróides ao cluster da mesma e recalcula a posição da centróide, este loop acontece até elas não se alterarem mais.

Algorithm 1 *k*-means algorithm

- 1: Specify the number *k* of clusters to assign.
 - 2: Randomly initialize *k* centroids.
 - 3: **repeat**
 - 4: **expectation:** Assign each point to its closest centroid.
 - 5: **maximization:** Compute the new centroid (mean) of each cluster.
 - 6: **until** The centroid positions do not change.
-

Figura 5 – Algoritmo do K-Means. (Fonte: K-Means Clustering in Python: A Practical Guide)

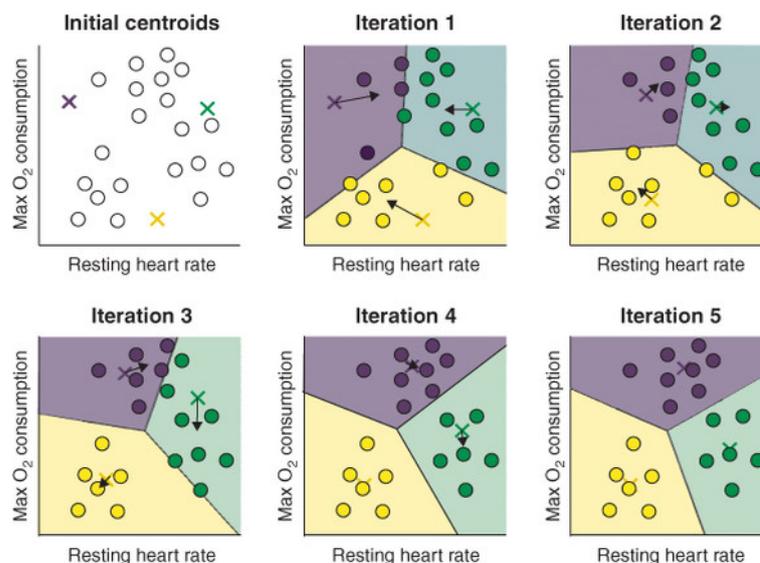


Figura 6 – Algoritmo do K-Means em funcionamento. (Fonte: augustocl.github.io/)

2.4.2 Algoritmo DBSCAN

O DBSCAN é um algoritmo de clusterização amplamente utilizado que se baseia na densidade dos pontos de dados. Ele agrupa os pontos de dados em clusters com base na proximidade espacial e densidade local. O DBSCAN é capaz de identificar clusters de diferentes formas e tamanhos, sem a necessidade de especificar o número de clusters antecipadamente. Além disso, ele também é capaz de identificar pontos de ruído ou outliers que não pertencem a nenhum cluster. O DBSCAN é uma ferramenta valiosa para a análise exploratória de dados e é eficiente em termos de complexidade computacional.

2.4.3 Algoritmo HDBSCAN

O HDBSCAN é um algoritmo de clusterização baseado em densidade que estende o DBSCAN, permitindo a descoberta automática do número de clusters. Ele utiliza uma abordagem hierárquica para identificar estruturas de densidade em diferentes escalas nos dados. O HDBSCAN atribui pontos a clusters com base na densidade local e na conectividade entre os pontos, permitindo a identificação de clusters de diferentes formas e tamanhos.

2.4.4 Algoritmo OPTICS

O OPTICS é um algoritmo de clusterização baseado em densidade que permite a identificação de clusters de forma flexível e automática. Ele calcula uma ordenação dos pontos de dados com base na densidade e na conectividade espacial entre eles. Ao contrário do DBSCAN, o OPTICS não requer a definição prévia do número de clusters. Ele fornece uma representação visual do espaço de dados em forma de gráfico, conhecido

como gráfico OPTICS, que permite a identificação de clusters e a detecção de pontos de ruído. O OPTICS é útil para a análise exploratória de dados e pode ser adaptado a diferentes cenários de clustering.

2.5 TRANSTORNO DO ESPÉCTRO AUTISTA

O transtorno do espectro autista (TEA) é um distúrbio caracterizado por um desenvolvimento atípico que causam uma série de condições como comprometimento na socialização, problemas na linguagem e na comunicação, redução do limiar de interesses e a necessidade de repetição sempre das mesmas atividades.

O termo "Transtorno do Espectro Autista" passou a ser utilizado a partir de 2013, ele se dá por causa da união de quatro tipos de diagnósticos: Autismo Clássico, onde existe uma grande variância no grau de comprometimento, o indivíduo tende a ser voltado apenas para si mesmo, conseguem falar mas não utilizam a fala como forma de comunicação, tem bastante dificuldade em manter o contato visual e aprendem as coisas no sentido literal da palavra; Transtorno Desintegrativo da Infância, também conhecido como síndrome de Heller, neste tipo do transtorno o indivíduo tende a ter uma regressão acentuada no desenvolvimento na infância, onde a criança inicialmente se assemelha bastante com outras crianças sem o transtorno, entretanto, o portador acaba, ao longo do tempo, perdendo a capacidade de realizar algumas ações que o mesmo fazia sem dificuldades anteriormente, além desta redução da capacidade motora a criança ainda apresenta complicações na comunicação social e dificuldade na compreensão de situações figuradas; Transtorno Global do Desenvolvimento Sem Outra Especificação, geralmente mais branda que as outras síndromes dentro do espectro, é um diagnóstico bastante semelhante ao autismo clássico; e Síndrome de Asperger, que interfere diretamente em como os diagnosticados enxergam e interagem com o mundo, eles possuem, assim como em todos os tipos de TEA, dificuldades em interagir com outras pessoas, problemas de coordenação e interesses bastante focado. Todavia indivíduos com Asperger tendem a ter habilidades e talentos muito marcantes, eles são excepcionalmente inteligentes e talentosos em alguma área em específico, como música, arte ou matemática.

O TEA não é uma doença, portanto, ele não possui nenhum tipo de cura, todavia, é possível realizar tratamentos para diminuir os sintomas indesejados. Por ser na infância o momento da vida onde o cérebro mais faz reorganizações cerebrais é esta fase onde o tratamento do transtorno mais faz resultado, então o diagnóstico de maneira precoce se dá de suma importância. Este diagnóstico atualmente é realizado de maneira essencialmente clínico, realizado por meio de observações diretas do comportamento do paciente por um especialista, além de entrevistas com os pais e/ou cuidadores.

No Brasil, o diagnóstico é severamente mais tardio em relação à países mais desenvolvidos, com uma média de atraso de diagnóstico em dois anos à três anos e este atraso gera diversas complicações na vida do indivíduo, frequentemente gerando condi-

ções mórbidas, como epilepsia, depressão, transtorno de déficit de atenção, ansiedade e hiperatividade.

As causas desta diferença na velocidade do diagnóstico se dá devido à alguns fatores, podendo ser a falta de um treinamento específico de profissionais da saúde, que tendem a avaliar normal a falta de habilidades de comunicação social até os 4,5 anos ou até mesmo o Transtorno do déficit de atenção com hiperatividade ser acusado, assim atrasando a detecção do TEA até o aumento das demandas nas escolas, este diagnóstico não está totalmente errôneo pois estima-se que 30 a 40% dos indivíduos com TEA também possuam TDAH, a falta de informação da própria família do indivíduo, que acaba não cogitando a possibilidade da criança ter este transtorno e a alta demanda por médicos especializados na área que não são suficientes para o grande fluxo de dados.

Em outros trabalhos, que serão futuramente apresentados em outro capítulo deste projeto, já foram realizados estudos acerca do peculiar movimento do olhar dos indivíduos com TEA, ao serem disponibilizados vídeos e imagens para os mesmos, eles tendem a ter um padrão em comum que pode ser explorado, utilizando tecnologias como análise de dados e aprendizado de máquina para auxiliar no diagnóstico precoce do transtorno do espectro autista.

2.6 TRABALHOS RELACIONADOS

Nesta seção serão abordados alguns dos trabalhos relacionados a este, contendo resumos e pontos relevantes destes artigos.

Attention to Eyes is Present But in Decline in 2–6 Month-Olds Later Diagnosed with Autism (JONES et al., 2013)

O estudo teve como objetivo investigar a diminuição do contato visual em bebês de 2 a 6 meses como um possível indicativo de Transtorno do Espectro Autista (TEA). Os pesquisadores observaram que, ao longo do tempo, esses bebês gradualmente perdem a fixação do olhar, diferenciando-se da maioria das crianças da mesma faixa etária. O estudo sugere que a diminuição do contato visual pode ser um indicador mais relevante para auxiliar no diagnóstico precoce do TEA em comparação com a ausência completa do contato visual.

Para realizar o estudo, foram observadas 110 crianças em dez momentos diferentes de suas vidas, aos 2, 3, 4, 5, 6, 9, 12, 15, 18 e 24 meses de idade. Dentre essas 110 crianças, 59 apresentavam alto risco para TEA, o que significa que elas tinham fatores de risco associados ao desenvolvimento do transtorno. A confirmação da presença ou ausência do TEA ocorreu aos 36 meses de idade.

Ao acompanhar o desenvolvimento dessas crianças e analisar o padrão de diminuição do contato visual ao longo dos meses, os pesquisadores puderam identificar uma possível relação entre essa diminuição e o desenvolvimento posterior do TEA. Essa descoberta pode ser útil na detecção precoce do transtorno, permitindo intervenções e suporte adequados o mais cedo possível.

The eye-tracking of social stimuli in patients with Rett syndrome and autism spectrum disorders: a pilot study (SCHWARTZMAN et al., 2015)

Durante o estudo, os pesquisadores analisaram a fixação visual em estímulos sociais em pacientes com Síndrome de Rett, Transtorno do Espectro Autista (TEA) e em pessoas com desenvolvimento típico. Foram utilizadas três figuras diferentes, sendo duas com faces humanas e uma com estímulo social e não social. A figura com estímulo social continha um bebê no hemisfério esquerdo da imagem e um relógio no hemisfério direito.

O estudo incluiu 14 pacientes do sexo feminino com Síndrome de Rett, com idades entre 4 e 30 anos, 11 pacientes do sexo masculino com TEA, com idades entre 4 e 20 anos, e 17 crianças do sexo feminino com desenvolvimento típico.

Os participantes foram expostos às três figuras diferentes, sendo cada uma exibida por 8 segundos em um monitor de computador que estava conectado a um equipamento de rastreamento ocular. Através desse equipamento, os pesquisadores puderam analisar a fixação do olhar dos participantes nos estímulos sociais apresentados.

O objetivo desse estudo era comparar a fixação do olhar em estímulos sociais entre os três grupos estudados: pacientes com Síndrome de Rett, pacientes com TEA e indivíduos com desenvolvimento típico. Essa análise pode fornecer insights sobre as diferenças na atenção e no processamento de estímulos sociais entre esses grupos.

Different Eye Tracking Patterns in Autism Spectrum Disorder in Toddler and Preschool Children (KONG et al., 2022)

Neste artigo, foram analisadas as diferenças entre respostas visuais entre crianças com idade entre 1 e 3 anos e crianças com idade entre 3 a 5 anos, em ambos os grupos existiam indivíduos com e sem TEA. Esta análise foi realizada a partir de padrões de olhar das crianças enquanto assistiam vídeos e imagens estáticas e foi possível afirmar que o classificador tinha maior facilidade em discriminar crianças com TEA e desenvolvimento típico (DT), com uma acurácia de 80%, com idades entre 3 e 5 anos, a precisão do outro grupo ficou em 71%. O resultado da pesquisa sugere que crianças mais novas dentro do espectro do TEA possuem um padrão de fixação mais comum em relação às mais crescidas.

Eye Tracking Young Children with Autism (SASSON et al., 2012)

Esta pesquisa teve como objetivo testar os diferentes níveis de exploração em crianças com e sem TEA, foram colocadas imagens com diversas figuras dentro da mesma, estas

foram classificadas como HAI, em português, alto interesse para autistas e LAI, baixo interesse para autistas, podemos perceber na figura abaixo a diferença entre o tempo de exploração de crianças com TEA em uma figura HAI e LAI, em relação a uma criança com desenvolvimento típico, com isto podemos crer que realmente exista uma grande diferença entre padrões de fixação do olhar entre crianças com TEA e DT.

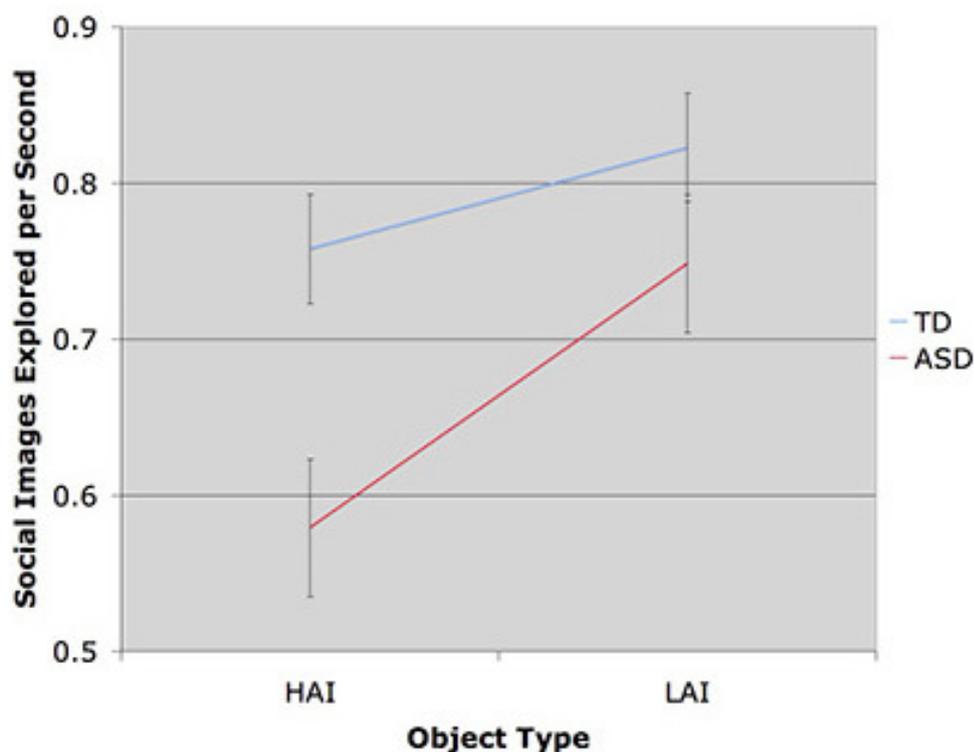


Figura 7 – Resultado da Pesquisa. (Fonte: (SASSON et al., 2012))

Disorder: Autism and Developmental Disabilities Monitoring Network, 2002-2016 (SHAW et al., 2021)

O artigo avaliou as alterações na identificação precoce do Transtorno do Espectro Autista (TEA) ao longo do tempo, bem como a co-ocorrência de deficiência intelectual (DI) e raça/etnia. Para isso, foram coletados dados de crianças de até 8 anos de idade, entre 2002 e 2016, de um programa de vigilância do TEA nos Estados Unidos. A identificação foi definida pelo primeiro diagnóstico de TEA registrado na criança ou pela elegibilidade da criança para a educação especial.

Os resultados mostraram que a identificação de TEA aos 48 meses de idade foi 4 vezes mais provável em 2016 do que em 2002, com maiores aumentos entre crianças sem DI. A idade mediana na identificação do TEA entre as crianças identificadas diminuiu 3 meses ao longo desse período. Crianças de todas as raças/etnias foram mais propensas a serem identificadas ao longo do tempo.

No entanto, foram observadas disparidades raciais estratificadas por DI. Em 2016, crianças negras e hispânicas sem DI tinham menos probabilidade de serem identificadas com TEA em comparação com crianças brancas (razão de risco para ambos os grupos: 0,7; IC 95%: 0,5-0,8). Porém, crianças negras tinham 1,5 vezes mais chances do que crianças brancas de serem identificadas com TEA e DI (IC 95%: 1,3-1,9). Isso indica que crianças brancas eram mais frequentemente identificadas, apesar de crianças negras e hispânicas terem 1,5 vezes mais chances de serem identificadas em comparação com crianças brancas.

Em conclusão, houve um avanço substancial na maior identificação precoce do TEA ao longo do tempo, embora a idade mediana no momento do diagnóstico tenha diminuído apenas em 3 meses. No entanto, ainda existem grandes disparidades na identificação precoce do TEA em relação à raça/etnia e à presença de deficiência intelectual.

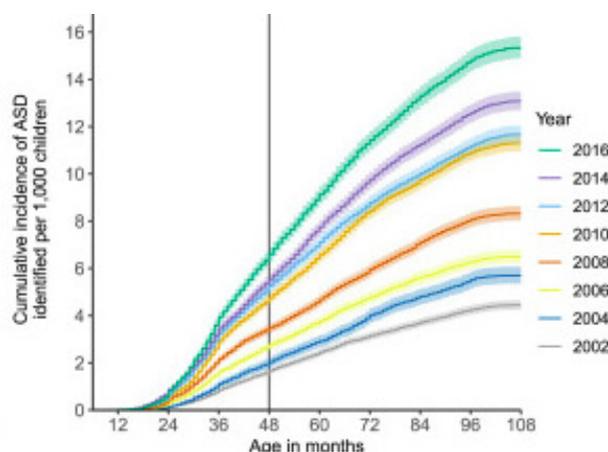


Figura 8 – Resultado da Pesquisa. (Fonte: (SHAW et al., 2021))

Na figura acima é possível observar claramente que o número de crianças diagnosticadas com TEA aos 48 meses aumentou de maneira expressiva entretanto isso também está relacionado com o grande aumento do número de pessoas diagnosticadas com o transtorno.

2.6.1 Diferenciais e Inovações: Comparação com trabalhos relacionados

Este projeto visa o desenvolvimento de uma ferramenta capaz de coletar dados brutos, manipular esses dados e disponibilizar, através de técnicas de ciência de dados, uma forma de especialistas na área da saúde terem auxílio para verificar tendências acerca da neurotipicidade de seus pacientes.

Artigo	Objetivo	Algoritmos	Dados	Resultados
(JONES et al., 2013)	Diminuição do contato visual em bebês de 2 a 6 meses	Análise Funcional dos dados e Análise Principal por Expectativa Condicional	110 crianças em 10 momentos de suas vidas	Comprovou que a fixação do olhar decai ao longo do tempo em pacientes com TEA
(SCHWARZMAN et al., 2015)	Comparação na fixação do olhar em crianças com síndrome de Rett, TEA e DT	Heatmap Análise Estatística	25 indivíduos com TEA/Rett com e 17 crianças com DT	Fixação de indivíduos com Rett é superior ao de crianças com DT/TEA e crianças com TEA se assemelham à DT ao se tratar de objetos não sociais.
(KONG et al., 2022)	Diferença na resposta ao estímulo visual em crianças com 1-3 anos e 3-5 anos	Support vector machine	173 indivíduos sendo eles com TEA ou DT	Maior facilidade na detecção de TEA em indivíduos de 3-5 anos em relação aos mais novos.
(SASSON et al., 2012)	Comparação utilizando figuras com classificação de alto ou baixo interesse para TEA	Fixation Density Maps Fixation analyses	O artigo não explicita o número de indivíduos utilizados para os testes	É possível classificar objetos como de alto ou baixo interesse para o portador de TEA e sua fixação de olhar possui alta variância entre eles
(SHAW et al., 2021)	Avaliar alterações no diagnóstico precoce ao longo do tempo	Cálculos de medianas em cima de dados específicos	Dados de crianças em um programa bial de EJA entre os anos de 2002-2016	Vasto aumento no número de diagnósticos precoces porém a mediana em meses não teve uma redução tão acentuada
Este Projeto	Criar uma ferramenta capaz de coletar e avaliar dados acerca do rastreo de olhar para realizar o diagnóstico de TEA	Heatmap Clusterização KMeans Clusterização HDBSCAN Clusterização Optics	Indivíduos com e sem TEA	É esperado a disponibilização de uma ferramenta capaz de distinguir, a partir de dados acerca do rastreo de olhar, a presença ou não do TEA com uma precisão satisfatória.

Tabela 1 – Resumo comparativo dos trabalhos relacionados Fonte: Elaborado pelo autor

3 DESENVOLVIMENTO

Neste capítulo, será feita a descrição do funcionamento da plataforma desenvolvida. Na Seção 3.2, serão apresentados de forma abrangente tanto o emprego do site quanto a integração deste com o servidor.

3.1 REQUISITOS FUNCIONAIS

A aplicação desenvolvida apresenta uma série de requisitos funcionais acordados em parceria com um Centro de Excelência e Inovação em Autismo, localizado em Florianópolis, para atender às necessidades dos usuários. Esses requisitos abrangem várias áreas, desde a criação e edição de operadores e pacientes até a visualização e análise detalhada de dados.

No âmbito da administração de usuários, nossa aplicação permite a criação e edição de operadores e pacientes, o primeiro é responsável pelo cadastro e a preparação da coleta de registros do segundo.

Uma das características centrais da aplicação é a área de visualização de vídeo com gaze tracker, que desempenha um papel crucial na captura de registros. Esta funcionalidade permite que os pacientes colem coordenadas observadas em um vídeo utilizando o EyeTracking. Essas coordenadas são armazenadas como registros, fornecendo informações valiosas para análise.

Além disso, a aplicação permite o upload de vídeos, tornando o processo de inserção de novos conteúdos simples e eficiente. Essa funcionalidade é essencial para encontrar vídeos que apontam de maneira mais efetiva a diferença em padrões do olhar.

A visualização de registros é uma parte essencial da aplicação. Isso inclui a exibição de um vídeo com um heatmap do registro, fornecendo uma representação visual das áreas de foco. Além disso, há a opção de visualizar um heatmap fixo como referência para comparação, clusters do atual registro sendo visualizado e a possibilidade de comparação do mesmo com outros registrados anteriormente, esses separados entre neurotípicos e neuroatípicos. Os clusters tem seus parâmetros padrões porém também com uma janela de edição de parâmetros com a possibilidade de fazer o download das imagens para melhor análise do profissional acerca das coordenadas observadas.

A aplicação também permite a mudança da neurotipicidade do paciente sendo visualizado, assim que um possível padrão seja observado e o diagnóstico confirmado.

3.2 VISÃO GERAL

De maneira abrangente, a aplicação é dividida em duas partes: o Servidor e o Site. No Site, temos a criação, exclusão e edição de operadores estes podem fazer upload de vídeos, criar, editar e excluir pacientes, estes por sua vez realizam a coleta dos dados, ou

seja, de registros de coordenadas observadas em um vídeo utilizando o EyeTracking. O operador é capaz de visualizar determinado registros específico e fazer uma análise em relação aos pacientes neurotípicos e neuroatípicos. O Servidor tem a função de realizar o processamento dos dados capturados pelo Site, gerando imagens e vídeos para auxiliar na detecção de padrões de olhar e retornando essas mídias para o Site. O servidor é conectado à um banco de dados para realizar o armazenamento dos dados.

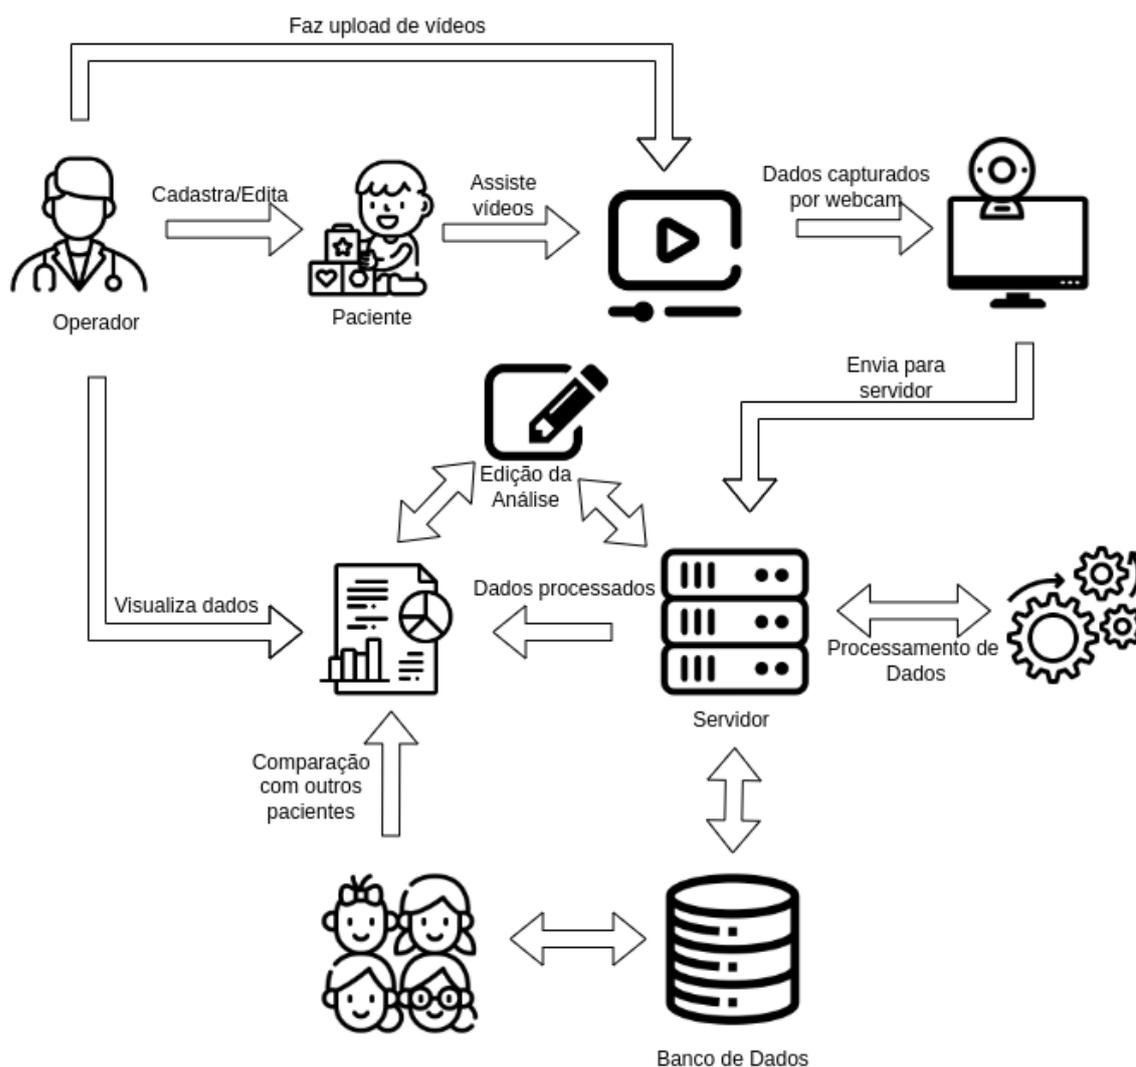


Figura 9 – Diagrama ilustrativo da Aplicação Fonte: Elaborado pelo autor

3.3 SITE

3.3.1 Visão Geral

O site tem o intuito final de realizar a coleta de registros de pacientes com neurotipicidade definida ou não. Após essa coleta ele é responsável por demonstrar o resultado através de clusters e heatmaps para auxiliar o operador do mesmo na detecção de padrões

do paciente assim auxiliando profissionais de saúde no diagnóstico dos pacientes. Ele também é capaz de permitir com que os operadores realizem uploads de vídeos base para os registros. Operadores podem personalizar clusters caso desejado.

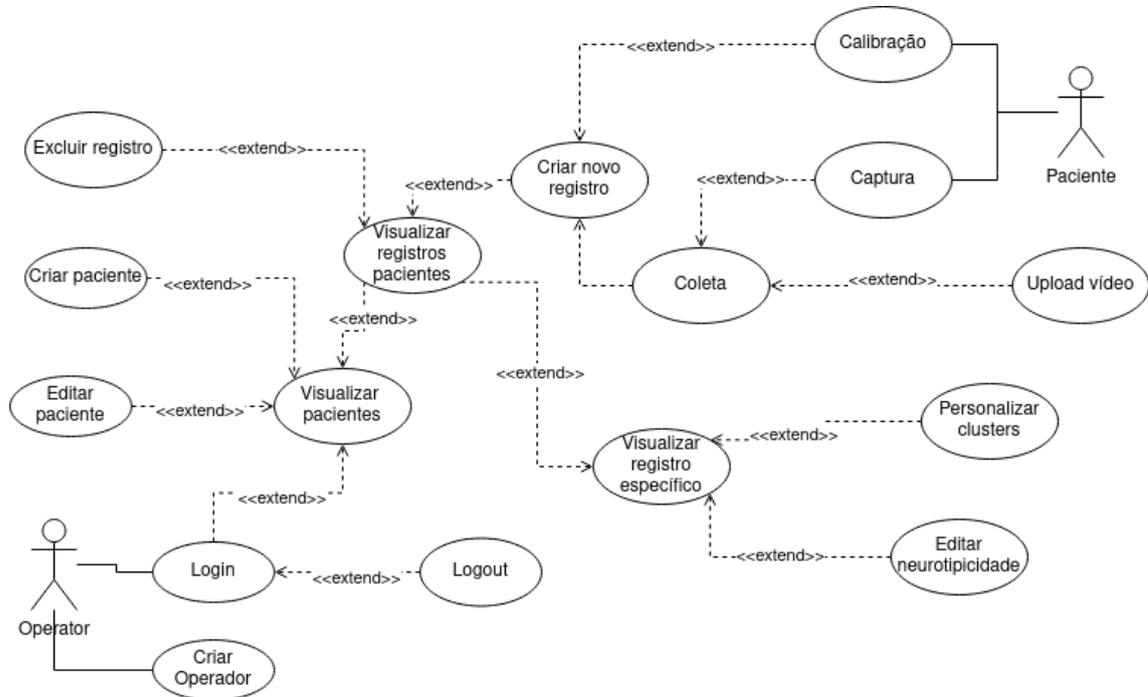


Figura 10 – Diagrama de Uso do Site Fonte: Elaborado pelo autor

3.3.2 Desenvolvimento

Para o desenvolvimento do Site, foi utilizada a biblioteca ReactJS, que é uma biblioteca JavaScript de código aberto para construir interfaces interativas. O ReactJS possui uma abordagem declarativa para a criação de componentes reutilizáveis e o gerenciamento do estado da interface do usuário. Isso permite a criação de interfaces de usuário eficientes, responsivas e de fácil manutenção.

O ReactJS também é altamente extensível, permitindo a continuação do desenvolvimento desta ferramenta e a aplicação de outras técnicas, como ciência de dados ou qualquer outra necessária.

3.3.3 Requisições HTTP

Para fazer as requisições HTTP foi utilizada o Axios, uma biblioteca JavaScript que oferece uma solução facilitada para realizar requisições HTTP a servidores. Amplamente utilizado no desenvolvimento web e em aplicações baseadas em JavaScript, como aplicações de página única (SPA) e aplicativos móveis, o Axios simplifica a comunicação assíncrona com endpoints de APIs e servidores. Essa biblioteca oferece uma interface intuitiva e de fácil utilização, permitindo o envio de dados por meio de diversos métodos HTTP,

como GET, POST, PUT e DELETE. Além disso, o Axios oferece recursos adicionais, incluindo interceptação de requisições e respostas, manipulação de cabeçalhos e controle de tempo limite. Para adicionar autenticação em token, o Axios permite a inclusão do token de autenticação no cabeçalho da requisição. Isso pode ser feito através da propriedade 'headers', onde é possível passar o token no formato Bearer.

3.3.4 Login

O processo de login no projeto começa quando o usuário preenche o formulário de login na página LoginPage. Ao clicar no botão "Entrar", o evento handleSubmit é acionado. Nesse evento, é chamada a função login fornecida pelo contexto AuthContext. O contexto fornece acesso a informações e funcionalidades relacionadas à autenticação.

Dentro da função login do contexto, ocorre uma chamada assíncrona para a função createSession do arquivo api.js. Essa função envia uma solicitação para o endpoint /sessions no backend, passando o email e a senha fornecidos pelo usuário. O backend verifica as credenciais e, se forem válidas, retorna um objeto de resposta contendo o usuário logado e um token de autenticação.

O objeto de resposta é então processado na função login. O usuário logado é armazenado no estado local do componente AuthProvider por meio da função setUser, que atualiza o estado user. Além disso, o token é armazenado no armazenamento local (local storage) do navegador usando localStorage.setItem. O token é definido nos cabeçalhos de autenticação da instância api criada em api.js, para que todas as solicitações subsequentes sejam feitas com o token de autenticação.

Após a atualização do estado e armazenamento do token, a função navigate do pacote react-router-dom é usada para redirecionar o usuário para a página "/patientMenu".

3.3.5 EyeTracker

Para coleta de coordenadas com base no rastreamento do olhar foi utilizada a biblioteca WebGazer, uma biblioteca desenvolvida por uma equipe da Brown University, Rhode Island, EUA. O WebGazer é uma biblioteca JavaScript de código aberto que permite o rastreamento de movimento ocular em navegadores da web utilizando apenas uma webcam. Essa biblioteca é uma maneira acessível e fácil de adicionar funcionalidades de eye tracking a projetos web, sem a necessidade de hardware especializado.

Embora o WebGazer.js seja uma ferramenta poderosa, ele tem algumas limitações. O rastreamento ocular pode ser menos preciso do que os sistemas de rastreamento ocular dedicados, e a precisão pode ser afetada pela qualidade da webcam, pelas condições de iluminação e por outros fatores.

3.3.6 Imagens

A seguir serão apresentadas imagens das telas de maior importância na parte do Site.



A imagem mostra a interface de login do sistema. No topo, o título "Login do Sistema" é exibido em uma fonte grande e preta. Abaixo do título, há dois campos de entrada de texto: o primeiro é rotulado "Email" e o segundo "Senha". Na base da interface, há três botões de ação: "ENTRAR", "CRIAR OPERADOR" e "SAIR", todos em caixa alta e com uma borda sutil.

Figura 11 – Tela de Login do Site

A tela de login é responsável por permitir a autenticação do operador, para garantir que quem está fazendo o gerenciamento de pacientes tem autorização para esta função. Quando um usuário faz login, é feita uma solicitação ao backend para criar uma sessão e receber um token de acesso. Esse token também é adicionado aos cabeçalhos das solicitações feitas pelo cliente HTTP para autenticar as solicitações no backend. Ela também permite a navegação para a tela de criação do operador.



A imagem mostra a interface de criação de um novo operador. O título "Criar Operador" está no topo em uma fonte grande e preta. Abaixo, há dois campos de entrada de texto: "Email" e "Senha". Na base, há dois botões de ação: "CRIAR" e "SAIR", ambos em caixa alta e com uma borda sutil.

Figura 12 – Tela de Criação de Operador

A tela de criação de operador é responsável pela criação do operador, este deve cadastrar um email e uma senha, após isso o sistema verifica que não existe esse operador cadastrado no banco de dados e, em caso de sucesso, faz a inserção do mesmo no banco. Em caso de falhas um erro é retornado apontando que o email já está em uso.

Nome	CPF	Neurotipicidade	Ações
Jorge	1	Atípico	<input type="button" value="VISUALIZAR DADOS"/> <input type="button" value="EDITAR PACIENTE"/> <input type="button" value="DELETAR PACIENTE"/>
Pedro	2	Típico	<input type="button" value="VISUALIZAR DADOS"/> <input type="button" value="EDITAR PACIENTE"/> <input type="button" value="DELETAR PACIENTE"/>
Lucas	999	Atípico	<input type="button" value="VISUALIZAR DADOS"/> <input type="button" value="EDITAR PACIENTE"/> <input type="button" value="DELETAR PACIENTE"/>
Eduardo	10	Típico	<input type="button" value="VISUALIZAR DADOS"/> <input type="button" value="EDITAR PACIENTE"/> <input type="button" value="DELETAR PACIENTE"/>
Arthur	11122233345	Não Definido	<input type="button" value="VISUALIZAR DADOS"/> <input type="button" value="EDITAR PACIENTE"/> <input type="button" value="DELETAR PACIENTE"/>

Figura 13 – Tela de Menu de Pacientes

A tela de menu de pacientes é a tela inicial da aplicação, responsável por exibir todos os pacientes registrados no banco de dados junto com o CPF do responsável e sua neurotipicidade. Ela permite a criação, edição e deleção de pacientes, além da visualização de registros de um paciente específico.

Editar Dados do Paciente

Nome
Arthur

CPF do responsável
11122233345

Neurotipicidade
Não definido

Figura 14 – Tela de Edição de Paciente

A tela de edição de paciente permite a alteração do nome do paciente e sua neurotipicidade, o CPF do responsável é um campo que não permite atualizações. Essas atualizações são commitadas no banco de dados.

Registros do paciente: Arthur

Data	Nome	Vídeo	Ações
2023-09-13T12:05:25.391Z	TestandoHeatmap	Toy Story in 30 Seconds.mp4	VISUALIZAR REGISTRO EXCLUIR REGISTRO
2023-09-18T11:42:00.869Z	novoyou	Toy Story in 30 Seconds.mp4	VISUALIZAR REGISTRO EXCLUIR REGISTRO
2023-10-22T18:51:07.821Z	NovaColeta	Toy Story in 30 Seconds.mp4	VISUALIZAR REGISTRO EXCLUIR REGISTRO
2023-10-22T19:00:40.854Z	NovaColeta2	Toy Story in 30 Seconds.mp4	VISUALIZAR REGISTRO EXCLUIR REGISTRO

[VOLTAR](#)

Figura 15 – Tabela de Menu de Registros

A tela de tabela de menu de registros é responsável pela exibição dos registros de um paciente específico no banco de dados, contendo a data, nome e vídeo do registro. Ela permite a criação, visualização e a exclusão de registros.

Novo Registro

Paciente: Arthur

[Retornar ao Menu](#) [Realizar Calibração](#) [Realizar Coleta](#)

Figura 16 – Tela de Criação de Registro

Esta tela permite a criação de registro permite a calibração, que tem seu funcionamento descrito na seção sobre calibração, ela é um pré requisito não obrigatório. Além disto outra opção fornecida é a coleta de registro que irá abrir o menu de coleta de registro.

Selecione um Vídeo

Figura 17 – Tela de Menu de Coleta de Registro

Esta tela precede a coleta do novo registro, ela permite o envio de vídeos para o servidor, que irá salvar o vídeo para utilizá-lo em coletas futuras. Nesta tela deve ser selecionado o vídeo que será utilizado na coleta e um nome para a mesma. Ao final da coleta o registro é salvo no banco de dados.

Criação de Paciente

Figura 18 – Tela de Criação de Pacientes

A tela de criação de pacientes é responsável pela criação de pacientes, deve ser cadastrado pelo operador logado, os dados requeridos do paciente são nome, neurotipicidade (neurotípico, neuroatípico ou não definido) e CPF do responsável, visto que o grupo alvo de pacientes são crianças e nem toda criança possui seu próprio CPF. Os pacientes são salvos no banco de dados.



Figura 19 – Tela de Calibração do EyeTracker

A tela de calibração do webgazer é responsável por aprimorar a calibração da ferramenta de coleta de coordenadas, são dispostos 5 pontos fixos na tela. O paciente deve acompanhar o cursor com o olhar e pressionar em cada um dos pontos 4 vezes, para que a ferramenta possa ajustar parâmetros do próprio EyeTracker. Após completa a calibração o paciente já está apto a realizar uma coleta.



Figura 20 – Vídeo com Heatmap

A ferramenta gera mapas de calor sobre o vídeo para melhor visualização de áreas observadas pelo paciente, onde as áreas mais quentes correspondem aos locais onde o paciente manteve seu foco de visão.

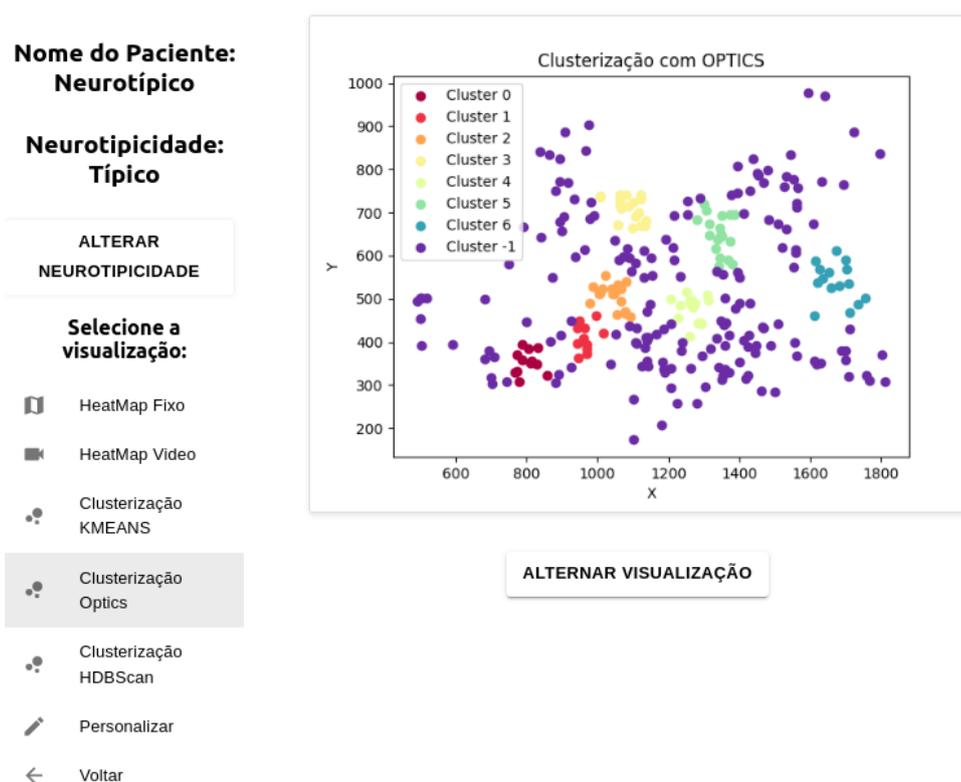


Figura 21 – Exemplo de Página de Visualizar Registro

Esta é a página ao visualizarmos um registro, ela possui as seguintes opções: Alterar Neurotipicidade, HeatMap Fixo, HeatMap Vídeo, Clusterização KMEANS, Clusterização Optics e Clusterização HDBScan. Ao entrar nessa página o servidor envia arrays de strings das imagens codificadas em Base64 e o site faz a decodificação e exibe ao operador o requisitado. Além disso as opções de Clusterização possuem o botão de alterar visualização que altera o modo de exibição de segundo-a-segundo e completa.

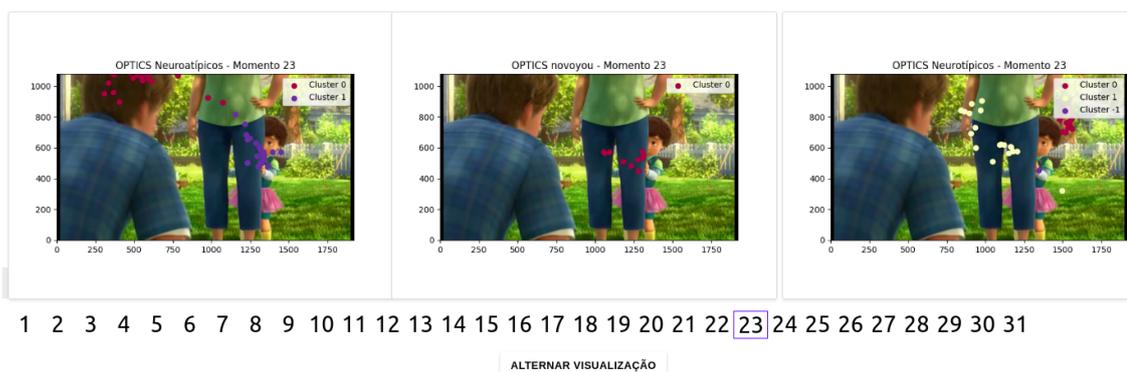


Figura 22 – Visualização Segundo-a-Segundo do Cluster

A visualização no modo segundo-a-segundo dos clusters de neurotípicos e neuroatípicos ao longo do tempo é responsável por permitir a visualização de maneira segmentada no intervalo fixo de um segundo, permitindo a comparação específica para um mesmo intervalo de tempo entre o registro atual e registros de pacientes neurotípicos e neuroatípicos.

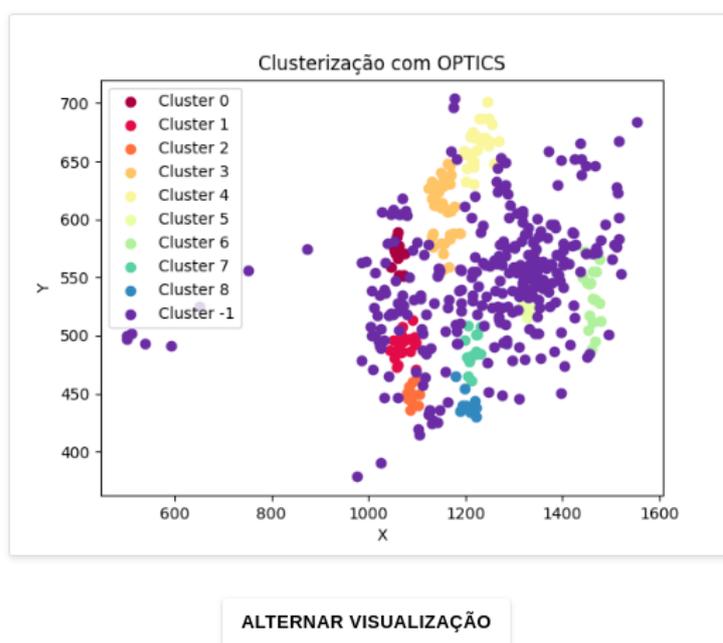


Figura 23 – Visualização simplificada do cluster

O modo de visualização simplificada exibe a clusterização das coordenadas observadas do vídeo por inteiro, para um entendimento da visualização de maneira veloz e abrangente.



Figura 24 – Exemplo de um frame fragmentado

3.4 SERVIDOR

3.4.1 Visão geral

No processo de desenvolvimento do Servidor, foi utilizado o Node.js, que oferece um ambiente de execução altamente escalável, sendo fundamental para lidar com uma carga de trabalho cada vez maior. Sua arquitetura baseada em eventos e assincronismo permite que o servidor atenda a várias solicitações simultaneamente, garantindo maior capacidade de processamento e melhor tempo de resposta.

Além disso, para utilizar as técnicas de ciência de dados no servidor, foi utilizada a linguagem de programação Python, devido à vasta quantidade de bibliotecas disponíveis, sua flexibilidade e escalabilidade, além da integração com o servidor em JavaScript.

3.4.2 Autenticação

No backend, o middleware de autenticação é responsável por verificar a autenticidade e validade dos tokens de acesso. Ele recebe o token enviado pelo frontend no cabeçalho de autenticação, decodifica o token e verifica sua assinatura. Se o token for válido, o middleware extrai o identificador do usuário e o adiciona ao objeto de solicitação. Isso permite que o backend identifique e autorize o usuário nas rotas protegidas. Cada token possui uma validade de 3 dias.

3.4.3 Banco de Dados

Para o SGDB, foi utilizado o MongoDB, que é um banco de dados NoSQL orientado a documentos, oferecendo alta flexibilidade e escalabilidade. Ele armazena os dados em formato JSON-like chamado BSON (Binary JSON), permitindo uma fácil integração com aplicativos JavaScript e Node.js.

Para garantir a segurança e a integridade dos dados, utilizamos o MongoDB Atlas como parte integrante de nosso sistema. O MongoDB Atlas é um serviço de banco de dados na nuvem que fornece recursos avançados de gerenciamento e segurança. Ele permite que salvemos nossos dados com confiabilidade e, ao mesmo tempo, oferece escalabilidade para atender às nossas necessidades crescentes.

O banco de dados em MongoDB possui as entidades Coords, Patient e User. A entidade Coords representa coordenadas e informações relacionadas a um vídeo e paciente. A entidade Patient contém informações sobre um paciente, como nome, CPF do responsável e um valor relacionado à neurodiversidade. A entidade User armazena informações dos usuários do sistema, como email e senha. Cada entidade é representada por uma tabela separada no banco de dados, permitindo um gerenciamento eficiente e estruturado dos dados.

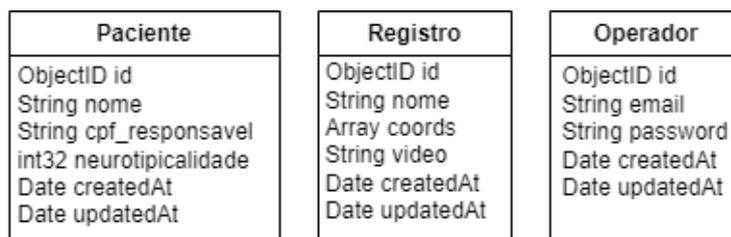


Figura 25 – Diagrama do Banco de Dados Fonte: Elaborado pelo autor

3.4.4 Técnicas de Ciências de Dados

Na implementação das técnicas de Ciência de Dados, Python foi a linguagem de programação escolhida devido à sua extensa variedade de bibliotecas e integração simplificada com o servidor em NodeJS. A biblioteca python-shell foi empregada para facilitar essa integração de ambientes distintos.

3.4.4.1 Clusterização

Para a execução das clusterizações K-Means, OPTICS e HDBScan, bem como para a criação do heatmap estático, foram empregadas as principais bibliotecas: numpy, matplotlib e sklearn. No contexto da geração do heatmap sobre vídeos, as bibliotecas OpenCV e numpy foram essenciais.

Para a realização da clusterização de dados bidimensionais, o código recebe dados de entrada no formato JSON contendo coordenadas (x, y) de pontos a serem clusterizado eles são convertidos em um array, onde cada elemento representa um ponto no espaço bidimensional. Em seguida, o algoritmo é aplicado aos dados.

Após a execução do algoritmo, são obtidos rótulos de cluster para cada ponto e informações sobre as distâncias de alcance. Os pontos são então visualizados no plano XY, sendo atribuídas cores diferentes a cada cluster identificado. O fundo da figura é uma mescla dos pontos definidos pelo algoritmo com o frame de tempo médio do intervalo definido. A figura resultante é salva em um buffer de memória como um arquivo PNG.

A customização dos parâmetros para a geração dos clusters é uma opção disponível na aplicação, assim que um novo registro é capturado, os endpoints são acionados, invocando automaticamente os métodos de clusterização com valores padrão, que são pré processados e então salvos automaticamente. Essa abordagem foi adotada para agilizar a visualização, garantindo eficiência na análise de dados em tempo real. Essa estratégia não apenas simplifica o processo, mas também permite uma adaptação dinâmica às características específicas dos dados coletados, promovendo uma abordagem flexível e adaptativa.

3.4.4.2 Heatmap

Para a geração do mapa de calor em vídeo, onde a intensidade do calor é determinada pelas coordenadas capturadas presentes no JSON de entrada, o código carrega o vídeo especificado usando a biblioteca OpenCV e define a resolução desejada para o vídeo de saída. Depois é calculada a escala para redimensionar o vídeo original, mantendo a proporção, em seguida, são calculadas as dimensões finais do vídeo e as dimensões das barras pretas para preencher as áreas restantes e manter a resolução desejada.

É inicializado o mapa de calor com a mesma resolução do vídeo final e definidas algumas variáveis, como a taxa de esfriamento da área e a taxa de adição de calor. O código entra em um loop onde cada quadro do vídeo é lido, redimensionado para as dimensões finais e o mapa de calor é atualizado. Adiciona calor à área próxima ao ponto especificado no arquivo JSON. O algoritmo escala o mapa de calor para o intervalo $[0, 255]$, aplicando uma paleta de cores e mescla o mapa de calor à imagem do vídeo. O ponto de aquecimento é movido gradualmente em direção às coordenadas fornecidas no arquivo JSON, e o quadrado resultante é gravado no vídeo de saída,

O loop continua até o final do vídeo original. O vídeo resultante é salvo no diretório especificado.

3.4.5 Retorno de Mídias

As mídias geradas pelo servidor são geradas a partir do momento em que o paciente faz o upload de um registro. Nesse momento, o servidor utiliza seus parâmetros padrões para gerar as imagens e as salva localmente, isso é feito para evitar um tempo maior de resposta quando essas mídias são requisitadas. Para o envio das mídias da camada do servidor para a de aplicação as mesmas são codificadas em Base64 e postas em um array para que a aplicação possa facilmente descodificá-las e prontamente já estarem disponíveis de maneira ordenada.

4 TESTES E RESULTADOS

Para coleta de dados em pacientes reais seria necessária uma aprovação ainda não requerida, então, os dados para teste e obtenção de resultados neste presente projeto foram coletados artificialmente e buscam demonstrar que, com o auxílio da ferramenta, profissionais da saúde poderão visualizar diferentes tipos de padrões de direcionamento do olhar de seus pacientes.

4.1 TESTES

Com o intuito de validar a usabilidade e desempenho do aplicativo, foram conduzidos testes relacionados à calibração, desempenho e simulação de cenários. Todos os dados de capturas dos testes foram obtidos de maneira artificial, de maneira apenas a evidenciar a funcionalidade da ferramenta para que, com ela, seja possível estudarmos a existência de padrões em pacientes reais.

4.1.1 Testes de Mesa

Com o intuito de destacar a eficácia dos requisitos funcionais, foram empregados vídeos animados para a realização de coletas que simulam distintos padrões de olhares, abrangendo tanto o comportamento de crianças neurotípicas quanto de crianças neuroatípicas. Para representar o enfoque de crianças neurotípicas, observou-se um prolongado contato visual com objetos humanos, focalizando determinadas regiões do vídeo. Em contrapartida, para simular os padrões de crianças neuroatípicas, foram evitados contatos visuais com figuras representando rostos, direcionando o olhar para outras áreas da tela.

Para comprovação da eficácia de diferenciação de padrões da ferramenta foi proposto simular o comportamento para o mesmo trecho de vídeo da seguinte forma: pacientes neuroatípicos assim que tivessem contato com o rosto da criança desviariam o olhar para a parte de trás da cabeça do homem, como apontado na figura 26, já pacientes neurotípicos manteriam o olhar voltado para a criança em todo o trecho, como na figura 27.

Outro teste seria acerca da área observado ao vídeo inteiro, onde seria testado a capacidade de diferenciar padrões caso pacientes neuroatípicos materem seu olhar voltado para a parte inferior esquerda do vídeo, já pacientes neurotípicos manteriam seu olhar mais voltado para a fatia centro direita da tela durante todo o vídeo.

Essas divergências, uma vez identificadas e apresentadas por meio de clusters e heatmaps, possibilitarão uma análise mais aprofundada das tendências observadas nos comportamentos visuais das crianças.

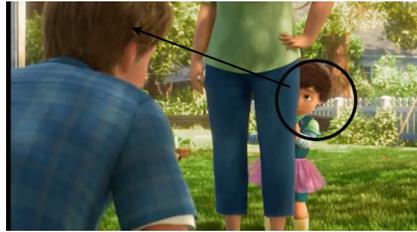


Figura 26 – Exemplo do comportamento esperado para um paciente neuroatípico



Figura 27 – Exemplo do comportamento esperado para um paciente neurotípico

4.1.2 Desempenho

Visando calcular o desempenho da aplicação, foram testes que se concentraram na variação velocidade de resposta e no armazenamento. A variedade de vídeos utilizados nesses testes, abrangendo diferentes durações, proporcionou uma análise mais detalhada.

Inicialmente, exploramos a capacidade da aplicação em lidar com vídeos curtos (10 segundos), seguido por vídeos pequenos (30 segundos), médios (1 minuto) e longos (3 minutos). Com essa variedade de vídeo são esperados insights sobre sua eficiência em termos de tempo de processamento e espaço em disco requerido.

Considerando a eficiência do tempo de resposta, os testes foram conduzidos com foco nas requisições que envolvem um período considerável de espera. Estas incluem o processamento da visualização completa, segundo a segundo, dos três algoritmos de clusterização: Optics, HDBSCAN e K-means.

Para mensurar o espaço em disco necessário por cada um dos registros é necessário considerarmos dois fatores: os arquivos produzidos por um registro específico e os arquivos contendo as imagens médias para pacientes neurotípicos e neuroatípicos geradas a partir de registros de pacientes neurotípicos e neuroatípicos no mesmo vídeo.

Esses testes são cruciais para avaliar o desempenho da aplicação em cenários do mundo real, fornecendo dados fundamentais para a otimização contínua e aprimoramento da experiência do usuário.

4.1.3 Calibração e Precisão

O teste para avaliar a qualidade de precisão e calibração do EyeTracker foi conduzido por meio da realização de capturas de registros em ambientes especialmente propícios,

considerando a luminosidade disponível e em ambientes com baixa quantidade de luz ofertada. Para a condução desses testes, optou-se por utilizar um vídeo que apresentava um alvo específico, designado para ser seguido com o olhar.

No decorrer do experimento, em todos os testes, a direção do olhar, a distância entre o dispositivo de captura de vídeo e paciente, a qualidade do dispositivo de vídeo e outros demais fatores correram de maneira similar, visando a única diferença entre eles ser a luminosidade disponível, buscando minimizar possíveis interferências externas que pudessem afetar a acurácia dos resultados.

Além disso, é importante destacar que o processo de calibração do EyeTracker foi realizado antes do início de cada teste, ambos com a mesma qualidade de iluminação, assegurando a adequada sincronização entre o dispositivo de captura de vídeo e o olhar.

Ao adotar essa abordagem, procurou-se estabelecer um ambiente experimental controlado, permitindo uma análise aprofundada da qualidade do EyeTracker em condições de iluminação adequada ou não. Os resultados desses testes são fundamentais para definir a necessidade de um ambiente com mais rigor para a coleta de registros.

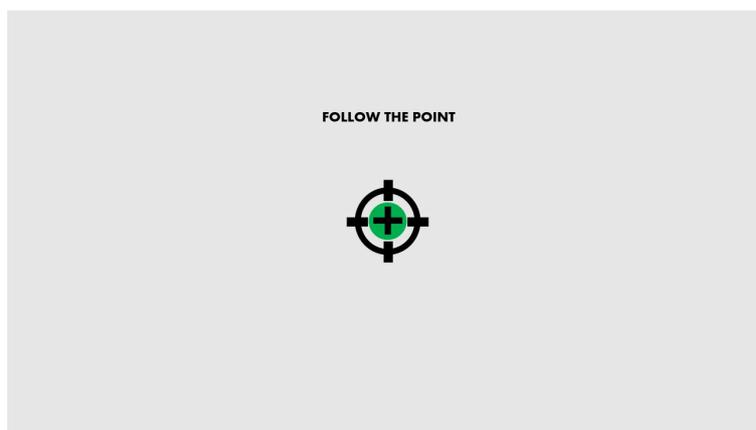


Figura 28 – Alvo para manter o olhar Fonte: Mauricio Konrath

4.2 RESULTADOS

Nesta seção, serão apresentados os resultados obtidos a partir da aplicação em dados forjados de pacientes neurotípicos e neuroatípicos. Os experimentos foram conduzidos com o objetivo de demonstrar que a ferramenta é capaz de mostrar a diferença do comportamento visual e sua capacidade de tempo de resposta e armazenamento de acordo com testes propostos na seção de testes.

4.2.1 Tempo e Armazenamento

As tabelas nesta subseção exibem os resultados referentes ao armazenamento para diferentes categorias de vídeos: curtos, pequenos, médios e longos, conforme especificado na

seção de testes. Além disso, são apresentados os tempos de resposta da geração de clusters para cada tipo de cluster, utilizando os algoritmos HDBSCAN, K-means e OPTICS.

No contexto do armazenamento, existe um diretório com clusters para comparação contendo dados de pacientes neurotípicos e neuroatípicos. Este diretório, denominado diretório comparativo, será tratado como ponto de referência. Cada registro adicional ocupará uma quantidade adicional de espaço.

Categoria de Vídeo	Diretório Comparativo	Adicional por registro
Curto	10,6 MB	3,4 MB
Pequeno	34,0 MB	16,2 MB
Médio	75,6 MB	56,4 MB
Longo	225,0 MB	149,8 MB

Tabela 2 – Resultados comparativos acerca do armazenamento necessário entre vídeos categóricos Fonte: Elobarado pelo autor

Esses resultados são considerados satisfatórios devido à quantidade de imagens e vídeos fornecidos.

Categoria de Vídeo	HDBSCAN	K-Means	OPTICS
Curto	11.12 segundos	9.71 segundos	11.27 segundos
Pequeno	25.98 segundos	19.00 segundos	33.68 segundos
Médio	1.2 minutos	37.62 minutos	1.2 minutos
Longo	2.2 minutos	2.5 minutos	2.2 minutos

Tabela 3 – Resultados comparativos acerca do tempo de resposta entre vídeos categóricos Fonte: Elobarado pelo autor

Devido à natureza assíncrona do servidor, onde as respostas não dependem umas das outras, o tempo de disponibilização de cada registro corresponde à requisição com o maior tempo de resposta.

Em relação ao upload de vídeos para o servidor, o tempo de envio está completamente associado ao upload de provedor de internet, porém em testes realizados este apresentou tempos quase que irrelevantes.

Em relação aos tempos de resposta da geração de cluster com parâmetros personalizados pelo operador, esses tendem a se manter próximos aos tempos encontrados com os valores default descritos nesta subseção.

4.2.2 Teste de Mesa

A figura 29 e a figura 30 demonstram o resultado dos testes que buscavam apontar as diferenças entre manter o olhar voltado à criança em pacientes neurotípicos, representado na Figura 29, e pacientes neuroatípicos, que tendem a observar a criança e desviar o olhar, demonstrado na Figura 30.

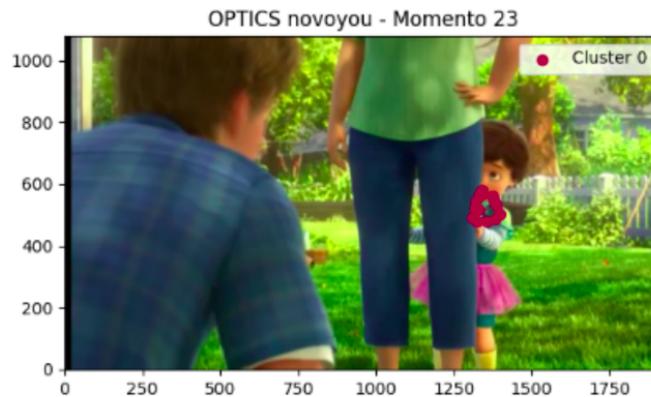


Figura 29 – Demonstração de manter contato visual

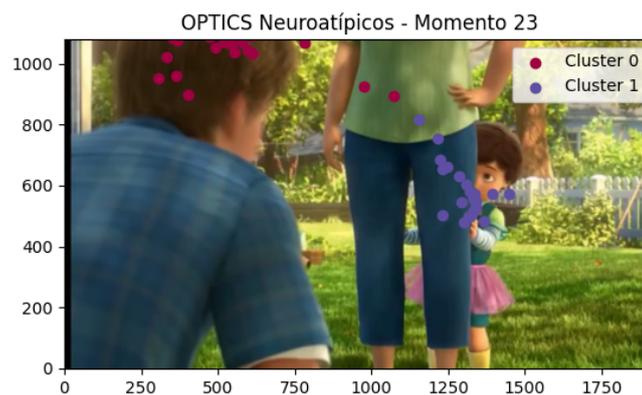


Figura 30 – Demonstração de deslocamento ao contato visual

Nas Figuras 31 e 32, podemos conferir o heatmap acerca das coordenadas capturadas pela ferramenta de rastreamento ocular em pacientes típicos e atípicos observando o mesmo vídeo. Como propunha o teste, os pacientes neuroatípicos (figura 31) tendem a observar a parte inferior esquerda do vídeo, já pacientes neurotípicos (figura 32) tendem a manter

seu olhar mais central direita da tela. Podemos também conferir os clusters gerados por estes registros respectivamente figura 33 e figura 34

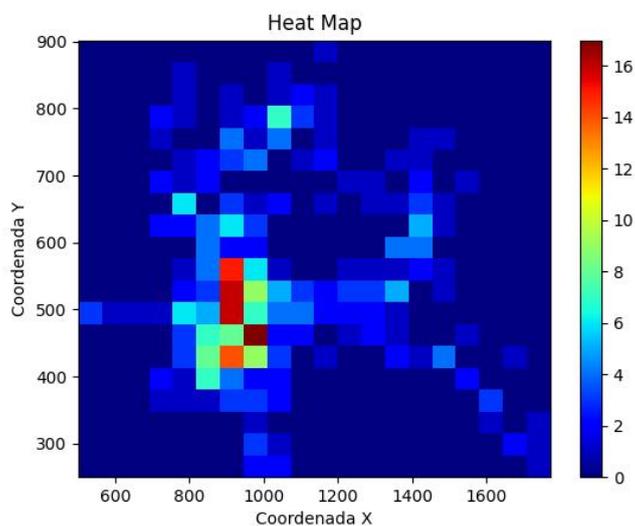


Figura 31 – Exemplo de Heatmap Paciente Neuroatípico

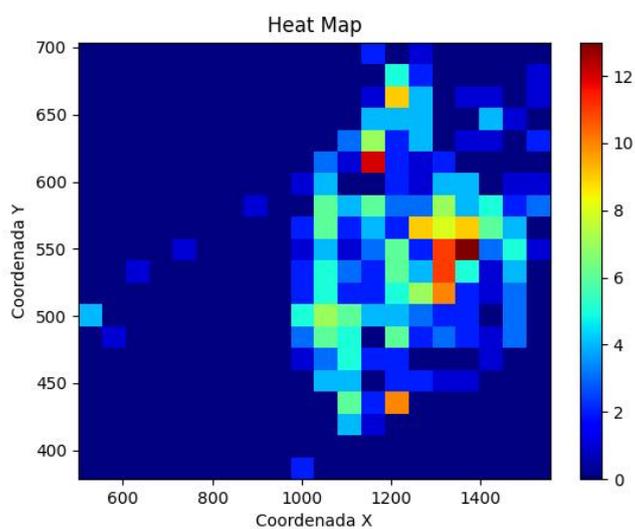


Figura 32 – Exemplo de Heatmap Paciente Neurotípico

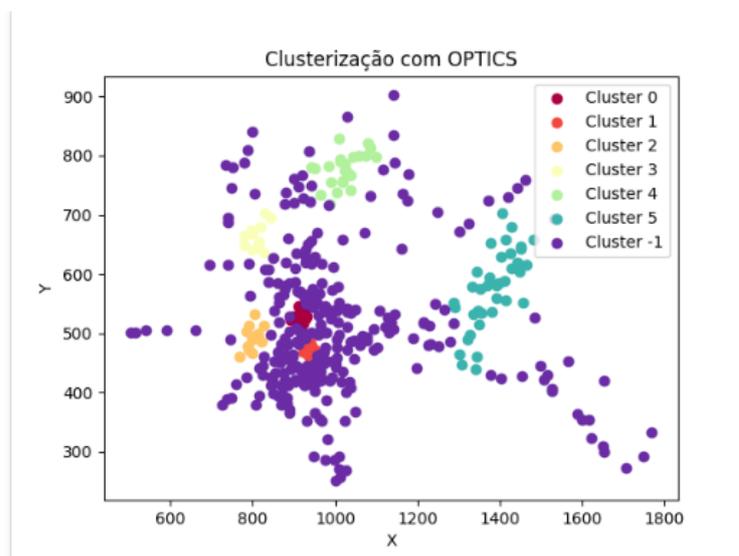


Figura 33 – Exemplo de Cluster Paciente Neuroatípico

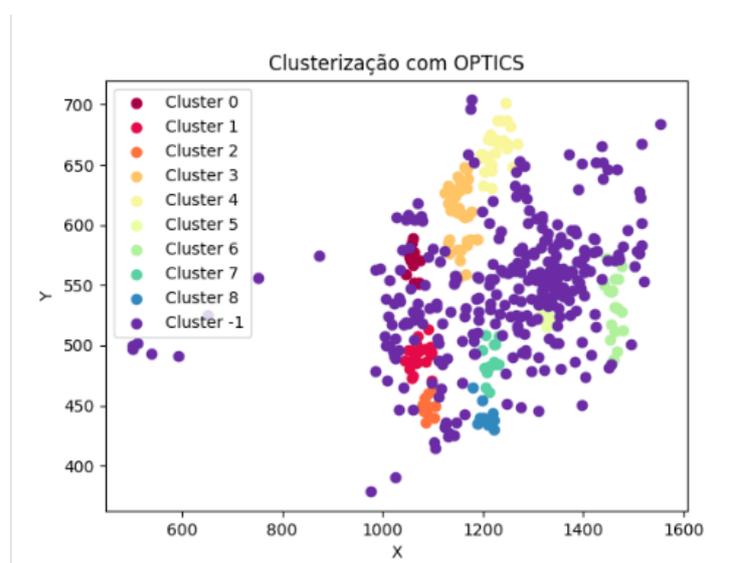


Figura 34 – Exemplo de Cluster Paciente Neurotípico

4.2.3 Calibração e Precisão

As Figuras 35 e 36 ilustram os resultados dos testes de precisão detalhados na seção anterior. Estes testes destacam a importância crucial da iluminação adequada durante a captura, mesmo após uma calibração cuidadosa que considera vários fatores, incluindo iluminação. A ausência de iluminação apropriada no momento da captura pode comprometer o desempenho do EyeTracker, resultando em dados imprecisos sobre a posição visual. Essa condição comprometerá não apenas a visualização do registro individual, mas também pode interferir na identificação de padrões em outras coletas, uma vez que dados incorretos servem como base de comparação para futuras capturas. Isso é especialmente crítico ao classificar pacientes com dados mal coletados como neurotípicos ou neuroatípicos, impactando negativamente na busca por padrões confiáveis.

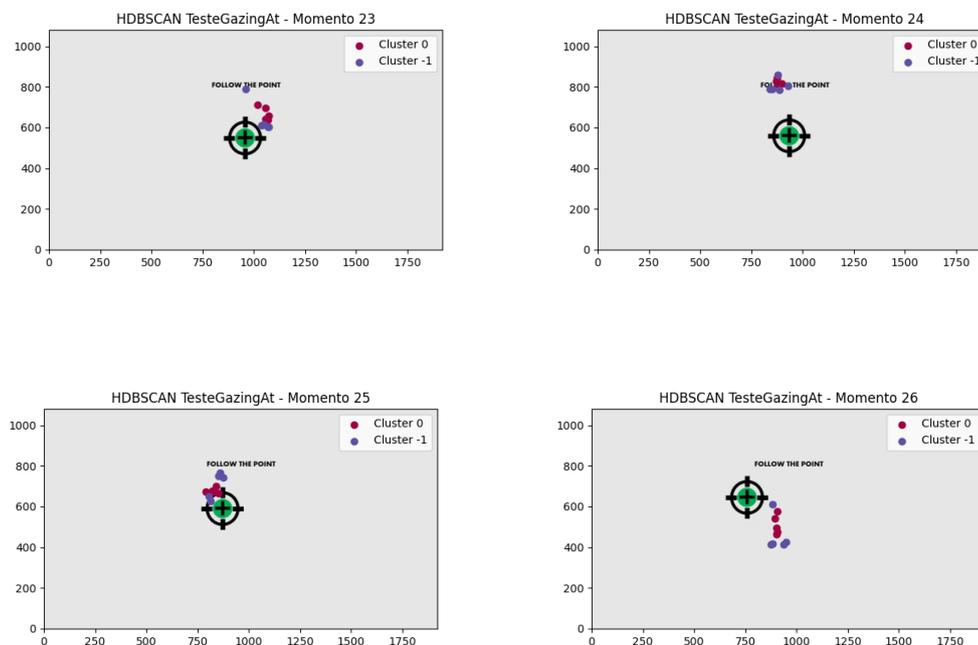


Figura 35 – Teste de precisão do EyeTracker em ambiente com luminosidade adequada

4.3 DISCUSSÃO SOBRE RESULTADOS

De maneira geral, os resultados obtidos pela aplicação estão em conformidade com as expectativas em termos de funcionalidade. A aplicação demonstra habilidade notável em identificar padrões de tendências no olhar do usuário, abrangendo tanto aspectos geoespaciais da tela quanto detalhes relacionados ao conteúdo exibido no vídeo.

No que diz respeito ao desempenho, é observado que a aplicação entrega resultados satisfatórios para vídeos curtos, pequenos e médios. Contudo, para vídeos mais extensos,

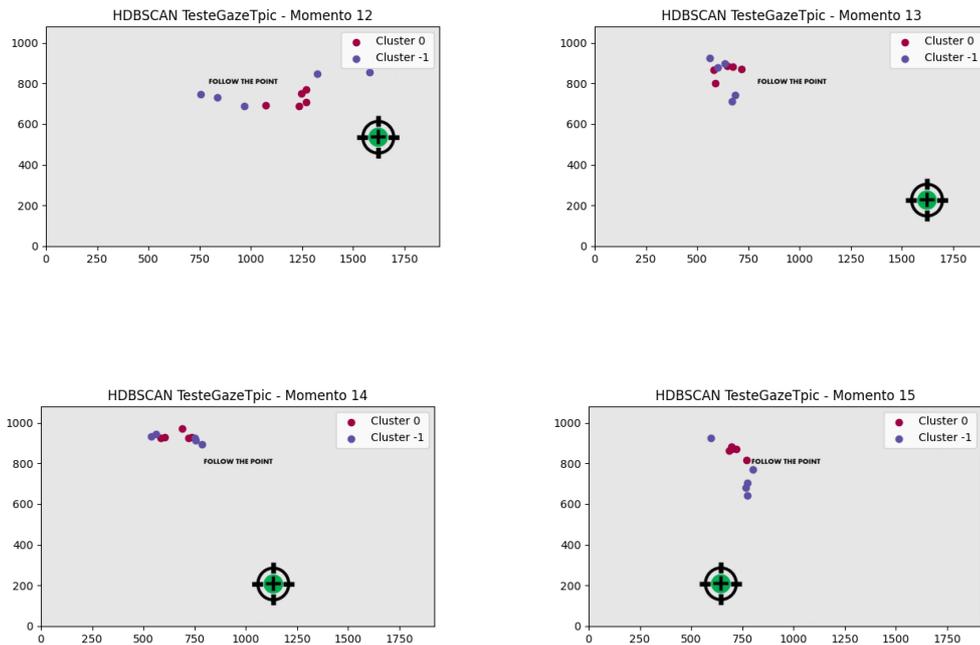


Figura 36 – Teste de precisão do EyeTracker em ambiente sem luminosidade suficiente

a usabilidade para o usuário pode ser comprometida. A cada nova captura, o operador é obrigado a aguardar por mais de dois minutos para obter seus resultados, o que pode impactar a experiência do usuário.

Quanto à precisão do EyeTracker, destaca-se seu bom desempenho em ambientes bem iluminados, proporcionando resultados satisfatórios nessas condições ideais. No entanto, essa precisão pode ser comprometida em ambientes nos quais a iluminação não atende aos pré-requisitos necessários, evidenciando a sensibilidade do sistema a esse fator ambiental específico.

5 CONCLUSÃO

O transtorno do espectro autista (TEA) é um desafio complexo que afeta não apenas os indivíduos diagnosticados, mas também suas famílias. Este artigo enfocou a importância do diagnóstico precoce do TEA e a necessidade de fornecer suporte apropriado às famílias afetadas. O diagnóstico precoce é fundamental para garantir que as intervenções e terapias adequadas sejam implementadas o mais cedo possível, melhorando as perspectivas de desenvolvimento das crianças afetadas.

Neste trabalho, foi desenvolvido um software que possibilita a análise e observação de diversos padrões de olhar com base na observação de vídeos. Constatamos que a capacidade de registrar e interpretar os movimentos oculares através da ferramenta, para entender o comportamento humano no contexto de explorar diferenças em pessoas com neurotipicidade típica e atípica, ao se tratar no transtorno do espectro autista.

Para abordar esse desafio, desenvolvemos um projeto que permite realizar a captura e visualização de dados com o intuito de analisar padrões de comportamento ocular (eye-tracking) em indivíduos com e sem TEA. O objetivo é fornecer uma ferramenta de software que auxilie os especialistas na identificação acelerada de padrões de atenção, reduzindo o tempo necessário para análise manual. Acredita-se que essa abordagem pode ajudar a acelerar o processo de diagnóstico e melhorar a precisão das avaliações.

Ao automatizar parte do processo de análise, busca-se aliviar a carga de trabalho dos profissionais da área, possibilitando um diagnóstico mais rápido e eficaz. Isso pode contribuir para melhorar a qualidade de vida das crianças afetadas e suas famílias, ao garantir que elas recebam o suporte necessário o mais cedo possível.

Em última análise, este projeto representa um passo importante em direção a uma abordagem mais eficiente e precisa no diagnóstico do TEA, fornecendo um valioso recurso para os especialistas da área. No entanto, é importante ressaltar que o diagnóstico e o tratamento do TEA são desafios contínuos que exigem esforços multidisciplinares e um compromisso contínuo com a pesquisa e o desenvolvimento de novas ferramentas e terapias. Este trabalho visa contribuir para o progresso nessa área e ajude a melhorar a vida das pessoas afetadas pelo TEA.

5.1 TRABALHOS FUTUROS

Recomenda-se fortemente a introdução de técnicas de aprendizado de máquina, que pode ser um caminho promissor para a detecção automatizada de padrões de olhar em pessoas com TEA. É possível explorar o desenvolvimento de algoritmos de machine learning que possam analisar e classificar automaticamente os padrões de olhar a partir dos dados coletados.

Além do Transtorno do Espectro Autista, existem fortes indícios de que outros transtornos também podem ter como um dos sintomas comportamentos de olhar atípicos,

como é o caso do Transtorno do déficit de atenção com hiperatividade (TDAH) ou a Síndrome de Rett.

Considerar o desenvolvimento de versões acessíveis e aplicativos para dispositivos móveis que permitam a coleta de dados de padrões de olhar em ambientes do dia a dia. Isso pode facilitar a coleta de dados em um ambiente familiar e ampliar a aplicabilidade da ferramenta.

Considera-se a possibilidade de aplicar a ferramenta de análise de padrões de olhar em diferentes faixas etárias, desde crianças até adultos. Isso pode ajudar a entender como os padrões de olhar evoluem ao longo do tempo e se há variações significativas em diferentes grupos etários.

A CÓDIGOS FONTES

Nesta seção, vamos fornecer o acesso para os repositórios do Site e do Servidor.

- Servidor: <https://github.com/arthurwillrich/tcc-backend>
- Site: <https://github.com/arthurwillrich/tcc-app>

B ARTIGO SBC

Uma ferramenta para coleta e análise de rastreamento de olhar para auxílio a diagnóstico de transtorno do espectro autista.

Arthur Gums Willrich¹

¹Departamento de Informática e Estatística (INE) Universidade Federal de Santa Catarina (UFSC)
CEP: 88040-370 – Florianópolis – SC – Brasil

arthur.willrich@gmail.com

Abstract. *Autism Spectrum Disorder (ASD) is a condition that brings various adversities to the lives of those who have it, with the most common being deficits in social interaction, learning difficulties, decreased brain processing capacity, and the need for a routine, among others. Within the family sphere, a significant portion of complications arises primarily during the diagnosis of this disorder and, subsequently, in daily interactions, due to the various special demands indirectly required by the diagnosed individual. These needs, if the family is not prepared, can cause various damages, such as physical and emotional overload directly related to the burden on financial capacity and a decrease in the quality of life. As there is no cure, the main differentiator in the lives of those affected lies in an early diagnosis. Given the vast amount of data from testing and therapy sessions available on ASD and the current need for manual analysis by a specialist, this project has been developed. It aims to use data analysis and data mining techniques to analyze eye behavior patterns to assist in the diagnosis of ASD. The goal is to provide a comprehensive software tool to specialists in the field to aid in identifying patterns of attention (eye-tracking) of interest among the data, thus reducing the time required for manual analysis by experts.*

Resumo. *O transtorno do espectro autista (TEA) é um distúrbio que acarreta diversas adversidades na vida de quem o porta, as mais frequentes são o déficit no convívio social, as dificuldades no aprendizado, a diminuição da capacidade de processamento cerebral, a necessidade de uma rotina, entre outros. Na esfera familiar, grande parte das complicações se dá primariamente no diagnóstico deste transtorno e futuramente na convivência, devido ao fato das diversas demandas especiais necessárias indiretamente requisitadas pelo diagnosticado. Essas necessidades, caso a família não esteja preparada, causam diversos danos, como a sobrecarga física e emocional diretamente relacionadas ao estorvo da capacidade financeira e atenuação da qualidade de vida. Por não existir nenhum tipo de cura, o principal diferencial na vida dos afetados está no diagnóstico mais cedo possível. Devido à vasta quantidade de dados de sessões de testes e terapias disponíveis sobre TEA e a atual necessidade de uma análise manual dos mesmos por um especialista, foi desenvolvido este projeto. Ele busca a partir de técnicas de análise de dados e mineração de dados, analisar padrões de comportamento do olho para auxiliar no diagnóstico do TEA. Espera-se fornecer um software completo aos especialistas da área para auxiliar na identificação de padrões de atenção (eye-tracking) de interesse dentre*

os dados, sendo assim, diminuindo o tempo necessário da análise manual por parte de especialistas.

1. Introdução

O transtorno do espectro autista (TEA), também conhecido como autismo, é um transtorno que prejudica neurologicamente aqueles que o desenvolvem desde o nascimento ou início da infância, segundo o Manual Diagnóstico e Estatístico de Transtornos Mentais DSM-5. O autismo gera inúmeras adversidades, como padrões restritos e repetitivos de hábitos, como padrões de movimento, interesses inflexíveis e hiper ou hipossensibilidade a estímulos sensoriais, dificuldades de imaginação, além de déficits na comunicação e interação social.

O nosso cérebro possui a capacidade de se reorganizar, de modificar sua estrutura em resposta aos estímulos que recebe do meio ambiente externo, chamamos essa habilidade de neuroplasticidade. Essa habilidade é acentuada nos primeiros anos de vida. Essa remodelação cerebral permite um vigoroso processo de aquisição de novas competências, como a melhora na cognição, na linguagem socioemocional e em habilidades motoras.

Ao se falar de tratamento, devemos relembrar que o TEA não possui cura, porém o diagnóstico precoce deste transtorno é fundamental para diminuir possíveis adversidades e gerar um impacto positivo na vida da criança, visto que é na infância, onde ocorre o ápice da plasticidade cerebral, além de ser nesta fase em que ocorre o agravamento de padrões de comportamento considerados inadequados e o isolamento da criança. Entretanto, o cérebro humano possui a capacidade de se reorganizar e reestruturar de acordo com estímulos do meio externo, habilidade chamada de neuroplasticidade. Sendo assim, é possível treinar o órgão por meio de terapias o mais cedo possível para melhorar o desempenho dos neurônios responsáveis por atividades de cunho social.

Dentro da área de ciência de dados, existem diversas pesquisas promissoras envolvendo a utilização de aprendizado de máquina para aplicação no contexto do transtorno do espectro autista. Além disso, nessa área, a aplicação de técnicas é comumente utilizada para o tratamento e diagnóstico de problemas onde são envolvidas uma quantidade massiva de dados, visando detectar padrões, extrair conhecimentos ou até mesmo localizar possíveis soluções para determinado problema.

2. Trabalhos Relacionados e Fundamentação Teórica

2.1. Trabalhos Relacionados

Nesta seção serão descritos trabalhos com relacionados a teste, apontando os fatores de maior relevância.

2.1.1. Attention to Eyes is Present But in Decline in 2–6 Month-Olds Later Diagnosed with Autism (JONES et al., 2013)

O estudo teve como objetivo investigar a diminuição do contato visual em bebês de 2 a 6 meses como um possível indicativo de Transtorno do Espectro Autista (TEA). Os pesquisadores observaram que, ao longo do tempo, esses bebês gradualmente perdem a fixação do olhar, diferenciando-se da maioria das crianças da mesma faixa etária. O

estudo sugere que a diminuição do contato visual pode ser um indicador mais relevante para auxiliar no diagnóstico precoce do TEA em comparação com a ausência completa do contato visual.

Para realizar o estudo, foram observadas 110 crianças em dez momentos diferentes de suas vidas, aos 2, 3, 4, 5, 6, 9, 12, 15, 18 e 24 meses de idade. Dentre essas 110 crianças, 59 apresentavam alto risco para TEA, o que significa que elas tinham fatores de risco associados ao desenvolvimento do transtorno. A confirmação da presença ou ausência do TEA ocorreu aos 36 meses de idade.

Ao acompanhar o desenvolvimento dessas crianças e analisar o padrão de diminuição do contato visual ao longo dos meses, os pesquisadores puderam identificar uma possível relação entre essa diminuição e o desenvolvimento posterior do TEA. Essa descoberta pode ser útil na detecção precoce do transtorno, permitindo intervenções e suporte adequados o mais cedo possível.

2.1.2. The eye-tracking of social stimuli in patients with Rett syndrome and autism spectrum disorders: a pilot study (SCHWARTZMAN et al., 2015)

Durante o estudo, os pesquisadores analisaram a fixação visual em estímulos sociais em pacientes com Síndrome de Rett, Transtorno do Espectro Autista (TEA) e em pessoas com desenvolvimento típico. Foram utilizadas três figuras diferentes, sendo duas com faces humanas e uma com estímulo social e não social. A figura com estímulo social continha um bebê no hemisfério esquerdo da imagem e um relógio no hemisfério direito.

O estudo incluiu 14 pacientes do sexo feminino com Síndrome de Rett, com idades entre 4 e 30 anos, 11 pacientes do sexo masculino com TEA, com idades entre 4 e 20 anos, e 17 crianças do sexo feminino com desenvolvimento típico.

Os participantes foram expostos às três figuras diferentes, sendo cada uma exibida por 8 segundos em um monitor de computador que estava conectado a um equipamento de rastreamento ocular. Através desse equipamento, os pesquisadores puderam analisar a fixação do olhar dos participantes nos estímulos sociais apresentados.

O objetivo desse estudo era comparar a fixação do olhar em estímulos sociais entre os três grupos estudados: pacientes com Síndrome de Rett, pacientes com TEA e indivíduos com desenvolvimento típico. Essa análise pode fornecer insights sobre as diferenças na atenção e no processamento de estímulos sociais entre esses grupos.

2.1.3. Different Eye Tracking Patterns in Autism Spectrum Disorder in Toddler and Preschool Children (KONG et al., 2022)

Neste artigo, foram analisadas as diferenças entre respostas visuais entre crianças com idade entre 1 e 3 anos e crianças com idade entre 3 e 5 anos, em ambos os grupos existiam indivíduos com e sem TEA. Esta análise foi realizada a partir de padrões de olhar das crianças enquanto assistiam vídeos e imagens estáticas e foi possível afirmar que o classificador tinha maior facilidade em discriminar crianças com TEA e desenvolvimento típico (DT), com uma acurácia de 80%, com idades entre 3 e 5 anos, a precisão do outro

grupo ficou em 71%. O resultado da pesquisa sugere que crianças mais novas dentro do espectro do TEA possuem um padrão de fixação mais comum em relação às mais crescidas.

2.1.4. Eye Tracking Young Children with Autism (SASSON et al., 2012)

Esta pesquisa teve como objetivo testar os diferentes níveis de exploração em crianças com e sem TEA, foram colocadas imagens com diversas figuras dentro da mesma, estas foram classificadas como HAI, em português, alto interesse para autistas e LAI, baixo interesse para autistas, podemos perceber na figura abaixo a diferença entre o tempo de exploração de crianças com TEA em uma figura HAI e LAI, em relação a uma criança com desenvolvimento típico, com isto podemos crer que realmente exista uma grande diferença entre padrões de fixação do olhar entre crianças com TEA e DT.

2.2. Fundamentação Teórica

Nesta seção serão descritos os principais conceitos, estes de suma importância para o completo entendimento sobre o trabalho.

2.2.1. WebGazerJS

Uma ferramenta de Eye Tracker é um sistema que utiliza tecnologia de rastreamento ocular para monitorar e registrar os movimentos dos olhos de um usuário enquanto ele interage com uma interface digital, neste presente trabalho, em um navegador web. O Webgazer.js, ferramenta desenvolvida por pesquisadores da Brown University, é uma biblioteca JavaScript que emprega algoritmos de visão computacional para estimar a posição do olhar do usuário em relação à tela do dispositivo. Através destas estimativas, podemos juntar dados acerca destas posições para realizar uma análise afim de reconhecer diferentes tipos de tendências de fixação do olhar.

2.2.2. Clusterização

A clusterização é uma técnica de análise de dados usada para agrupar objetos ou pontos de dados semelhantes em conjuntos chamados clusters. É uma abordagem comum em aprendizado de máquina e mineração de dados, onde o objetivo é descobrir estruturas e padrões intrínsecos nos dados. A clusterização permite identificar grupos naturais ou segmentos de dados com características semelhantes, facilitando a compreensão dos dados e a tomada de decisões. Diferentes algoritmos de clusterização podem ser aplicados, como o k-means, DBSCAN, HDBSCAN e OPTICS, cada um com suas próprias vantagens e limitações. A clusterização é amplamente utilizada em diversas áreas, incluindo ciência de dados, bioinformática, marketing e análise de redes sociais.

2.2.3. Algoritmo K-means

Um dos algoritmos para fazer agrupamentos de pontos ou clusters mais utilizado é o K-means. Cada um dos pontos é associado com uma centróide onde cada instância é

atribuída ao cluster (com centróide) mais próximo. Este algoritmo é bastante simples, ele consiste em definir o número de centróides aleatoriamente e entra em loop atribuindo os pontos mais próximos das centróides ao cluster da mesma e recalcula a posição da centróide, este loop acontece até elas não se alterarem mais.

2.2.4. Algoritmo HDBSCAN

O HDBSCAN é um algoritmo de clusterização baseado em densidade que estende o DBSCAN, permitindo a descoberta automática do número de clusters. Ele utiliza uma abordagem hierárquica para identificar estruturas de densidade em diferentes escalas nos dados. O HDBSCAN atribui pontos a clusters com base na densidade local e na conectividade entre os pontos, permitindo a identificação de clusters de diferentes formas e tamanhos.

2.2.5. Algoritmo OPTICS

O OPTICS é um algoritmo de clusterização baseado em densidade que permite a identificação de clusters de forma flexível e automática. Ele calcula uma ordenação dos pontos de dados com base na densidade e na conectividade espacial entre eles. Ao contrário do DBSCAN, o OPTICS não requer a definição prévia do número de clusters. Ele fornece uma representação visual do espaço de dados em forma de gráfico, conhecido como gráfico OPTICS, que permite a identificação de clusters e a detecção de pontos de ruído. O OPTICS é útil para a análise exploratória de dados e pode ser adaptado a diferentes cenários de clustering.

3. Metodologia

A metodologia para o desenvolvimento deste trabalho se assemelha muito com o processo KDD, na **primeira etapa** será feita a coleta de dados, em parceria com uma instituição local voltada em auxiliar no tratamento do TEA, principalmente em crianças, a partir de uma ferramenta que será disponibilizada onde será possível, apenas com uma webcam, reconhecer para onde a criança está olhando ao passar do tempo e exportar, em formato de coordenadas, esses dados.

A partir disto poderá se iniciar a **segunda etapa**, utilizando técnicas muito comuns de exploração de dados, como sumeração estatística e visualização para que seja possível de uma maneira inicial indentificar tendencias nos diferentes tipo de comportamentos.

Posteriormente à coleta de dados e a preparação dos mesmos, serão aplicadas técnicas de data mining, dando início à **terceira etapa**, no intuito de detectar eventos e padrões de interesse para dar o suporte requisitado por pesquisadores e médicos especialistas na área acerca ao TEA.

Com base em critérios de sucessos definidos na etapa inicial, os modelos desenvolvidos e técnicas serão avaliados nesta **quarta etapa** por profissionais especialistas que apoiam este projeto, esta etapa contará também com ajustes, de maneira iterativa, na etapa anterior, a fim de permitir que novos ajustes possam vir a serem feitos para alcançar os critérios de sucesso previamente definidos.

Na **quinta e última etapa** será produzida uma ferramenta de software com interface e a mesma será disponibilizada em um repositório público aberto com o intuito de auxiliar na transferência do conhecimento gerado na pesquisa deste trabalho podendo assim trazer benefícios de maneira imediata para a sociedade, além do software, serão produzidos materiais e vídeos para auxiliar na utilização prática deste software, estes serão disponibilizados no repositório junto ao software.

Esta ferramenta terá algumas funcionalidades, entre elas a captura de dados, que ocorrerá da seguinte forma: Com o auxílio de uma webcam e um computador serão amostrados vídeos/imagens e feita a captura, provavelmente a uma taxa de 50Hz, de onde está voltado o olhar do indivíduo, sendo assim poderemos gerar uma vasta quantidade de dados brutos contendo coordenadas de para onde o olhar estava voltado ao longo do tempo, com esses dados poderemos gerar algumas representações, como por exemplo o heatmap.

Além disto, é importante citar que serão necessários tratamentos em cima dos dados, inclusive para tratarmos as "piscadas" do paciente, testes iniciais apontaram que existe um efeito chicote que ocorre quando o indivíduo que está tendo seu olhar rastreado pisca os olhos, as coordenadas salvas durante esse piscar tendem descolar para algum dos cantos do monitor durante alguns milissegundos e após isso retornam ao local esperado correto.

4. Desenvolvimento

Neste capítulo, será feita a descrição do funcionamento da plataforma desenvolvida. Serão apresentados de forma abrangente tanto o emprego do site quanto a integração deste com o servidor.

4.1. Site

Para o desenvolvimento do Site, foi utilizada a biblioteca ReactJS, que é uma biblioteca JavaScript de código aberto para construir interfaces interativas. O ReactJS possui uma abordagem declarativa para a criação de componentes reutilizáveis e o gerenciamento do estado da interface do usuário. Isso permite a criação de interfaces de usuário eficientes, responsivas e de fácil manutenção. O ReactJS também é altamente extensível, permitindo a continuação do desenvolvimento desta ferramenta e a aplicação de outras técnicas, como ciência de dados ou qualquer outra necessária.

4.2. Servidor

No processo de desenvolvimento do Servidor, foi utilizado o Node.js, que oferece um ambiente de execução altamente escalável, sendo fundamental para lidar com uma carga de trabalho cada vez maior. Sua arquitetura baseada em eventos e assincronismo permite que o servidor atenda a várias solicitações simultaneamente, garantindo maior capacidade de processamento e melhor tempo de resposta. Além disso, para utilizar as técnicas de ciência de dados no servidor, foi utilizada a linguagem de programação Python, devido à vasta quantidade de bibliotecas disponíveis, sua flexibilidade e escalabilidade, além da integração com o servidor em JavaScript.

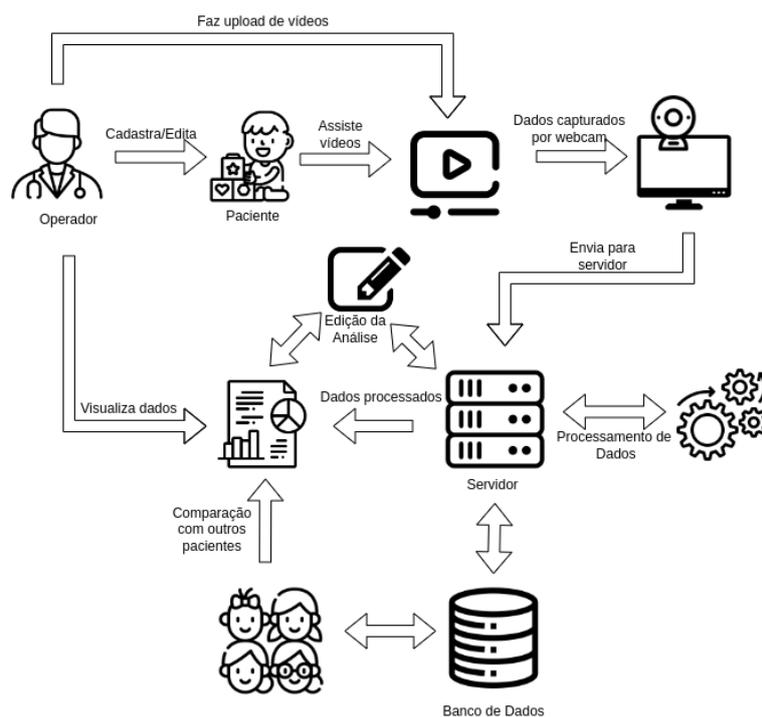


Figure 1. Diagrama ilustrativo da Aplicação Fonte: Elaborado pelo autor

4.3. Banco de Dados

Para o SGDB, foi utilizado o MongoDB, que é um banco de dados NoSQL orientado a documentos, oferecendo alta flexibilidade e escalabilidade. Ele armazena os dados em formato JSON-like chamado BSON (Binary JSON), permitindo uma fácil integração com aplicativos JavaScript e Node.js. Para garantir a segurança e a integridade dos dados, utilizamos o MongoDB Atlas como parte integrante de nosso sistema. O MongoDB Atlas é um serviço de banco de dados na nuvem que fornece recursos avançados de gerenciamento e segurança. Ele permite que salvemos nossos dados com confiabilidade e, ao mesmo tempo, oferece escalabilidade para atender às nossas necessidades crescentes. O banco de dados em MongoDB possui as entidades Coords, Patient e User. A entidade Coords representa coordenadas e informações relacionadas a um vídeo e paciente. A entidade Patient contém informações sobre um paciente, como nome, CPF do responsável e um valor relacionado à neurodiversidade. A entidade User armazena informações dos usuários do sistema, como email e senha. Cada entidade é representada por uma tabela separada no banco de dados, permitindo um gerenciamento eficiente e estruturado dos dados.

5. Resultados e Discussões

De maneira geral, os resultados obtidos pela aplicação estão em conformidade com as expectativas em termos de funcionalidade. A aplicação demonstra habilidade notável em identificar padrões de tendências no olhar do usuário, abrangendo tanto aspectos geoespaciais da tela quanto detalhes relacionados ao conteúdo exibido no vídeo.

No que diz respeito ao desempenho, é observado que a aplicação entrega resultados satisfatórios para vídeos curtos, pequenos e médios. Contudo, para vídeos mais

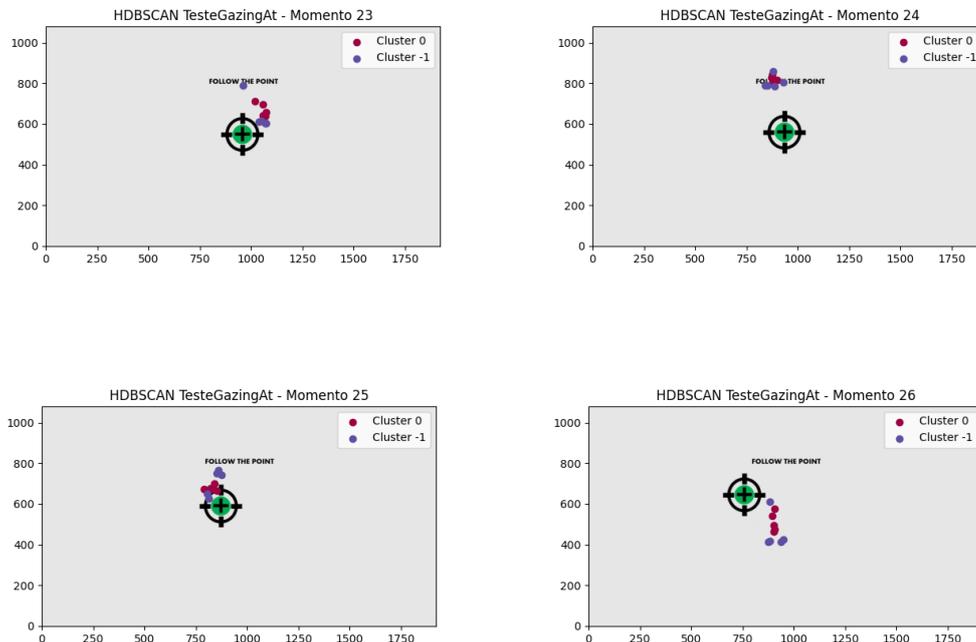


Figure 2. Teste de precisão do EyeTracker em ambiente com luminosidade adequada

extensos, a usabilidade para o usuário pode ser comprometida. A cada nova captura, o operador é obrigado a aguardar por mais de dois minutos para obter seus resultados, o que pode impactar a experiência do usuário.

Quanto à precisão do EyeTracker, destaca-se seu bom desempenho em ambientes bem iluminados, proporcionando resultados satisfatórios nessas condições ideais. No entanto, essa precisão pode ser comprometida em ambientes nos quais a iluminação não atende aos pré-requisitos necessários, evidenciando a sensibilidade do sistema a esse fator ambiental específico.

As Figuras 2 e 3 ilustram os resultados dos testes de precisão detalhados na seção anterior. Estes testes destacam a importância crucial da iluminação adequada durante a captura, mesmo após uma calibração cuidadosa que considera vários fatores, incluindo iluminação. A ausência de iluminação apropriada no momento da captura pode comprometer o desempenho do EyeTracker, resultando em dados imprecisos sobre a posição visual. Essa condição comprometerá não apenas a visualização do registro individual, mas também pode interferir na identificação de padrões em outras coletas, uma vez que dados incorretos servem como base de comparação para futuras capturas. Isso é especialmente crítico ao classificar pacientes com dados mal coletados como neurotípicos ou neuroatípicos, impactando negativamente na busca por padrões confiáveis.

Na Figura 4, podemos conferir o heatmap acerca das coordenadas capturadas pela ferramenta de rastreamento ocular em pacientes assinados como típicos e atípicos observando o mesmo vídeo. Como propunha o teste, os pacientes neuroatípicos tendem a observar a

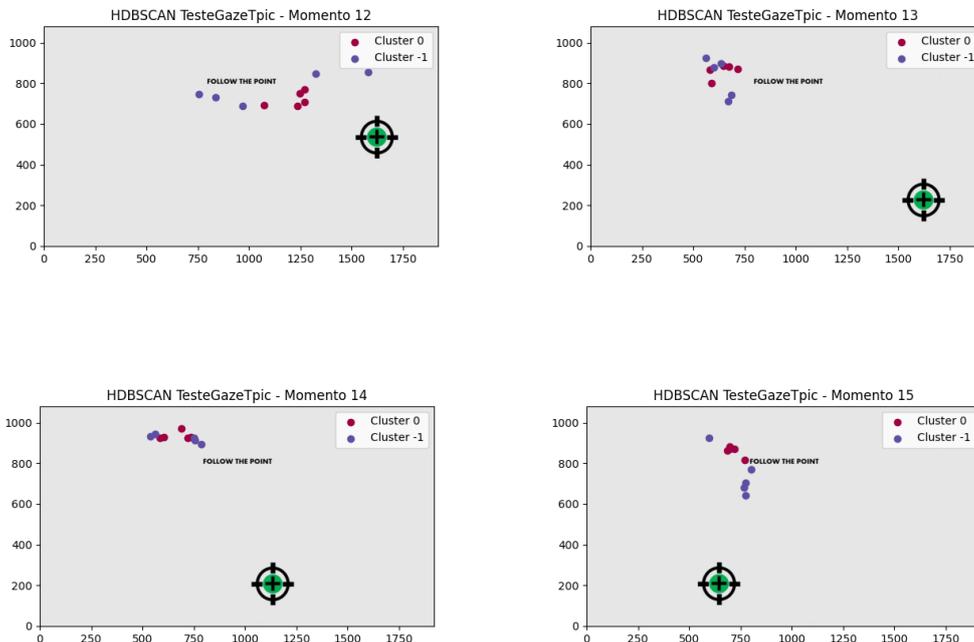


Figure 3. Teste de precisão do EyeTracker em ambiente sem luminosidade suficiente

parte inferior esquerda do vídeo, já pacientes neurotípicos tendem a manter seu olhar mais central direita da tela. Podemos também conferir os clusters gerados por estes registros respectivamente figura 5. É importante ressaltar que todos os testes foram realizados por apenas um estudante, na busca de comprovar a eficácia da ferramenta à diferenciar, caso existam, os padrões de fixação de olhar do paciente.

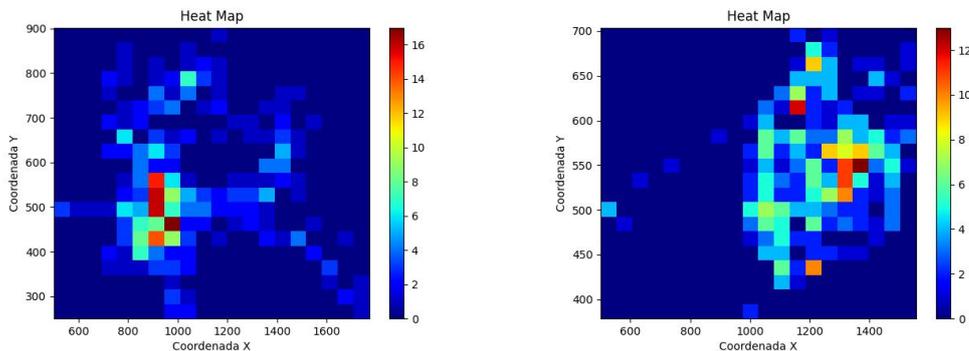


Figure 4. Exemplo de Heatmap Paciente Neuroatípico x Neurotípico

Além dos resultados já mencionados, é relevante destacar uma função adicional que contribuiu para contextualizar a coleta de dados e aprofundar a compreensão pós-análise: a visualização do heatmap sobreposto ao vídeo utilizado para capturar os dados do paciente. Nessa representação visual, as áreas onde o paciente fixou o olhar são identi-

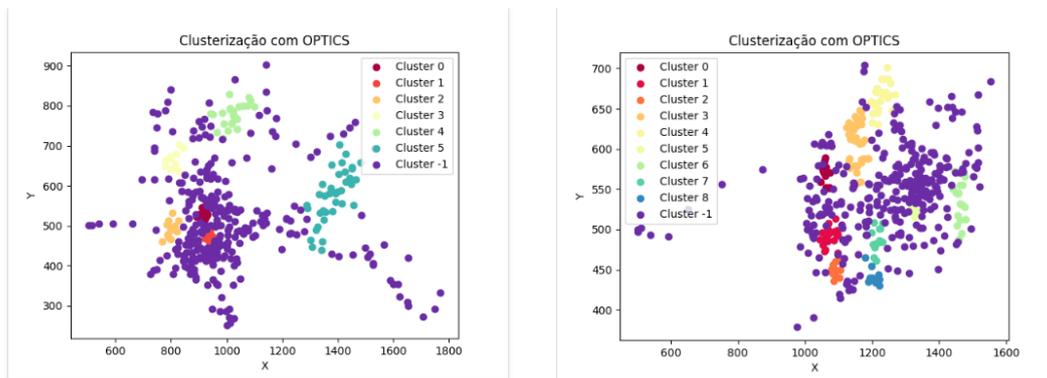


Figure 5. Exemplo de Cluster Paciente Neuroatípico x Neurotípico

ficadas por tonalidades mais quentes, enquanto as regiões sem interesse são exibidas com cores mais frias. Esta representação pode ser observada na figura. 6.



Figure 6. Heatmap sobreposto ao video da Coleta

6. Conclusão

O transtorno do espectro autista (TEA) é um desafio complexo que afeta não apenas os indivíduos diagnosticados, mas também suas famílias. Este artigo enfocou a importância do diagnóstico precoce do TEA e a necessidade de fornecer suporte apropriado às famílias afetadas. O diagnóstico precoce é fundamental para garantir que as intervenções e terapias adequadas sejam implementadas o mais cedo possível, melhorando as perspectivas de desenvolvimento das crianças afetadas.

Neste trabalho, foi desenvolvido um software que possibilita a análise e observação de diversos padrões de olhar com base na observação de vídeos. Constatamos que a capacidade de registrar e interpretar os movimentos oculares através da ferramenta, para entender o comportamento humano no contexto de explorar diferenças em pessoas com neurotipicidade típica e atípica, ao se tratar no transtorno do espectro autista.

Para abordar esse desafio, desenvolvemos um projeto que permite realizar a captura e visualização de dados com o intuito de analisar padrões de comportamento ocular (eye-tracking) em indivíduos com e sem TEA. O objetivo é fornecer uma ferramenta de software que auxilie os especialistas na identificação acelerada de padrões de atenção, reduzindo o tempo necessário para análise manual. Acredita-se que essa abordagem pode ajudar a acelerar o processo de diagnóstico e melhorar a precisão das avaliações.

Ao automatizar parte do processo de análise, busca-se aliviar a carga de trabalho dos profissionais da área, possibilitando um diagnóstico mais rápido e eficaz. Isso pode contribuir para melhorar a qualidade de vida das crianças afetadas e suas famílias, ao garantir que elas recebam o suporte necessário o mais cedo possível.

Em última análise, este projeto representa um passo importante em direção a uma abordagem mais eficiente e precisa no diagnóstico do TEA, fornecendo um valioso recurso para os especialistas da área. No entanto, é importante ressaltar que o diagnóstico e o tratamento do TEA são desafios contínuos que exigem esforços multidisciplinares e um compromisso contínuo com a pesquisa e o desenvolvimento de novas ferramentas e terapias. Este trabalho visa contribuir para o progresso nessa área e ajude a melhorar a vida das pessoas afetadas pelo TEA.

7. Referências

[Jones and Klin 2013] Jones, Warren, Klin, Ami. (2013). Attention to Eyes is Present But in Decline in 2–6 Month-Olds Later Diagnosed with Autism. *Nature*. 504. 10.1038/nature12715.

[Schwartzman et al. 2015] Schwartzman, José, Velloso, Renata, D’Antino, Maria, Santos, Silvana. (2015). The eye-tracking of social stimuli in patients with Rett syndrome and autism spectrum disorders: A pilot study. *Arquivos de neuro-psiquiatria*. 73. 402-7. 10.1590/0004-282X20150033.

[Kong et al. 2022] Kong, Xue-Jun, Wei, Zhen, Sun, Binbin, Tu, Yiheng, Huang, Yiting, Cheng, Ming, Yu, Siyi, Wilson, Georgia, Park, Joel, Feng, Zhe, Vangel, Mark, Kong, Jian, Wan, Guobin. (2022). Different Eye Tracking Patterns in Autism Spectrum Disorder in Toddler and Preschool Children. *Frontiers in Psychiatry*. 13. 899521. 10.3389/fpsy.2022.899521.

[Sasson and Elison 2012] Sasson, Noah, Elison, Jed. (2012). Eye Tracking Young Children with Autism. *Journal of visualized experiments: JoVE*. 61. 10.3791/3675.

[Shaw et al. 2021] Shaw, Kelly, McArthur, Dedria, Hughes, Michelle, Bakian, Amanda, Lee, Li-Ching, Pettygrove, Sydney, Maenner, Matthew. (2021). Progress and Disparities in Early Identification of Autism Spectrum Disorder: Autism and Developmental Disabilities Monitoring Network, 2002–2016. *Journal of the American Academy of Child Adolescent Psychiatry*. 61. 10.1016/j.jaac.2021.11.019.

[Google Developers n.d.] Google Developers. (n.d.). Text Classification Guide. Retrieved from <https://developers.google.com/machine-learning/guides/text-classification>

[Fernandes and Dias 2019] Fernandes, Fernando, Dias, Alexandre. (2019). Perspectivas do uso de mineração de dados e aprendizado de máquina em saúde e

segurança no trabalho. *Revista Brasileira de Saúde Ocupacional*. 44. 10.1590/2317-6369000019418.

[Sheikh et al. 2012] Sheikh, Asim, Alnoukari, Mouhib, El Sheikh, Asim. (2012). Knowledge Discovery Process Models. 10.4018/978-1-61350-050-7.ch004.

[Mollas et al. 2019] Mollas, Ioannis, Tsoumakas, Grigorios, Bassiliades, Nick. (2019). LionForests: Local Interpretation of Random Forests through Path Selection.

[Battisti and Dornelles Filho 2016] Battisti, Elisa, Dornelles Filho, Adalberto. (2016). MUDANÇA FÔNICA EM PROGRESSO NO PORTUGUÊS DE CONTATO: PALATALIZAÇÃO DE /t/ e /d/ E VOCA-LIZAÇÃO DE /l/ NUMA COMUNIDADE ÍTALO-BRASILEIRA. *ReVEL*. 218.

[Rock Content n.d.] Rock Content. (n.d.). Mapa de Calor: O que é e Como Utilizar essa Estratégia no seu Negócio. Retrieved from <https://rockcontent.com/br/blog/mapa-de-calor/>

[WebGazer: Papoutsaki et al. 2016] WebGazer: Scalable Webcam Eye Tracking Using User Interactions. Retrieved from <https://cs.brown.edu/people/apapouts/papers/ijcai2016webgazer.pdf>

BIBLIOGRAFIA

- [1] Jones, Warren & Klin, Ami. (2013). Attention to Eyes is Present But in Decline in 2–6 Month-Olds Later Diagnosed with Autism. *Nature*. 504. 10.1038/nature12715.
- [2] Schwartzman, José & Velloso, Renata & D’Antino, Maria & Santos, Silvana. (2015). The eye-tracking of social stimuli in patients with Rett syndrome and autism spectrum disorders: A pilot study. *Arquivos de neuro-psiquiatria*. 73. 402-7. 10.1590/0004-282X20150033.
- [3] Kong, Xue-Jun & Wei, Zhen & Sun, Binbin & Tu, Yiheng & Huang, Yiting & Cheng, Ming & Yu, Siyi & Wilson, Georgia & Park, Joel & Feng, Zhe & Vangel, Mark & Kong, Jian & Wan, Guobin. (2022). Different Eye Tracking Patterns in Autism Spectrum Disorder in Toddler and Preschool Children. *Frontiers in Psychiatry*. 13. 899521. 10.3389/fpsy.2022.899521.
- [4] Sasson, Noah & Elison, Jed. (2012). Eye Tracking Young Children with Autism. *Journal of visualized experiments : JoVE*. 61. 10.3791/3675.
- [5] Shaw, Kelly & McArthur, Dedria & Hughes, Michelle & Bakian, Amanda & Lee, Li-Ching & Pettygrove, Sydney & Maenner, Matthew. (2021). Progress and Disparities in Early Identification of Autism Spectrum Disorder: Autism and Developmental Disabilities Monitoring Network, 2002–2016. *Journal of the American Academy of Child & Adolescent Psychiatry*. 61. 10.1016/j.jaac.2021.11.019.
- [6] Google Developers. (n.d.). Text Classification Guide. Retrieved from <https://developers.google.com/machine-learning/guides/text-classification>
- [7] Fernandes, Fernando & Dias, Alexandre. (2019). Perspectivas do uso de mineração de dados e aprendizado de máquina em saúde e segurança no trabalho. *Revista Brasileira de Saúde Ocupacional*. 44. 10.1590/2317-6369000019418.
- [8] Sheikh, Asim & Alnoukari, Mouhib & El Sheikh, Asim. (2012). Knowledge Discovery Process Models. 10.4018/978-1-61350-050-7.ch004.
- [9] Mollas, Ioannis & Tsoumakas, Grigorios & Bassiliades, Nick. (2019). LionForests: Local Interpretation of Random Forests through Path Selection.
- [10] Battisti, Elisa & Dornelles Filho, Adalberto. (2016). MUDANÇA FÔNICA EM PROGRESSO NO PORTUGUÊS DE CONTATO: PALATALIZAÇÃO DE /t/ e /d/ E VOCA-LIZAÇÃO DE /l/ NUMA COMUNIDADE ÍTALO-BRASILEIRA. *ReVEL*. 218.
- [11] Rock Content. (n.d.). Mapa de Calor: O que é e Como Utilizar essa Estratégia no seu Negócio. Retrieved from <https://rockcontent.com/br/blog/mapa-de-calor/>
- [12] WebGazer: Scalable Webcam Eye Tracking Using User Interactions. Retrieved from <https://cs.brown.edu/people/apapouts/papers/ijcai2016webgazer.pdf> *WebGazer: Scalable Webcam Eye Tracking Using User Interactions*