



Universidade Federal de Pernambuco
Centro de Tecnologia e Geociências
Departamento de Engenharia Biomédica
Programa de Pós-Graduação em Engenharia Biomédica

Adrielly Sayonara de Oliveira Silva

Aplicação de Aprendizado de Máquina em Sinais de EEG para o Diagnóstico do Transtorno do Espectro Autista

Dissertação de Mestrado

Recife, outubro de 2024



Universidade Federal de Pernambuco
Centro de Tecnologia e Geociências
Departamento de Engenharia Biomédica
Programa de Pós-Graduação em Engenharia Biomédica

Adrielly Sayonara de Oliveira Silva

Aplicação de Aprendizado de Máquina em Sinais de EEG para o Diagnóstico do Transtorno do Espectro Autista

Dissertação de Mestrado

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Pernambuco como requisito para obtenção de título de mestre em Engenharia Biomédica.

Prof. Dr. Wellington Pinheiro dos Santos
Orientador

Profa. Dra. Juliana Carneiro Gomes Cassemiro
Coorientadora

Recife, outubro de 2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Silva, Adrielly Sayonara de Oliveira.

Aplicação de aprendizado de máquina em sinais de EEG para o diagnóstico do Transtorno do Espectro Autista / Adrielly Sayonara de Oliveira Silva. - Recife, 2024.
92f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Biomédica (PPGEE), 2024.

Orientação: Wellington Pinheiro dos Santos.
Coorientação: Juliana Carneiro Gomes Cassemiro.
Inclui referências.

1. Random Forest; 2. Eletroencefalograma (EEG); 3. Transtorno do Espectro Autista (TEA); 4. Diagnóstico precoce; 5. Aprendizado de máquina. I. Santos, Wellington Pinheiro dos. II. Cassemiro, Juliana Carneiro Gomes. III. Título.

UFPE-Biblioteca Central

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**

Ata da defesa/apresentação do Trabalho de Conclusão de Curso de Mestrado do Programa de Pós-graduação em Engenharia Biomédica - CTG da Universidade Federal de Pernambuco, no dia 22 de outubro de 2024.

ATA Nº 18

Aos 22 dias do mês de outubro de 2024, às 15:00, em sessão pública realizada de forma presencial, teve início a defesa/apresentação do Trabalho de Conclusão de Curso intitulada Aplicação de Aprendizado de Máquina em Sinais de EEG para o Diagnóstico do Transtorno do Espectro Autista do(a) mestrando(a) ADRIELLY SAYONARA DE OLIVEIRA SILVA, na área de concentração Computação Biomédica, sob a orientação do(a) Prof.(a) WELLINGTON PINHEIRO DOS SANTOS e coorientação do(a) Prof.(a) JULIANA CARNEIRO GOMES. A Comissão Examinadora foi aprovada pelo colegiado do programa de pós-graduação em 18 de outubro de 2024, sendo composta pelos examinadores: GISELLE MACHADO MAGALHAES MORENO do(a) UFPE; WELLINGTON PINHEIRO DOS SANTOS, do(a) da UFPE; MAIRA ARAUJO DE SANTANA, do(a) UFPE. Após cumpridas as formalidades conduzidas pelo(a) presidente(a) da comissão, professor(a) JULIANA CARNEIRO GOMES, o(a) candidato(a) ao grau de Mestre(a) foi convidado(a) a discorrer sobre o conteúdo do Trabalho de Conclusão de Curso. Concluída a explanação, o(a) candidato(a) foi arguido(a) pela Comissão Examinadora que, em seguida, reuniu-se para deliberar e conceder, ao mesmo, a menção APROVADA. Para a obtenção do grau de Mestre(a) em Engenharia Biomédica, o(a) concluinte deverá ter atendido todas às demais exigências estabelecidas no Regimento Interno e Normativas Internas do Programa, nas Resoluções e Portarias dos Órgãos Deliberativos Superiores, assim como no Estatuto e no Regimento Geral da Universidade, observando os prazos e procedimentos vigentes nas normas.

Dra. MAIRA ARAUJO DE SANTANA, UFPE

Examinadora Externa à Instituição

Dra. GISELLE MACHADO MAGALHAES MORENO, UFPE

Examinadora Interna

Dr. WELLINGTON PINHEIRO DOS SANTOS, UFPE

Examinador Interno

JULIANA CARNEIRO GOMES, UFPE

Presidente

ADRIELLY SAYONARA DE OLIVEIRA SILVA

Dedico este trabalho à minha mãe, Adriana, minha maior inspiração e fortaleza. Por todo o amor incondicional, pelos conselhos, pelos sacrifícios e pelo exemplo de coragem e determinação que sempre me guiou. Sua fé em mim, mesmo nos momentos mais desafiadores, foi o que me deu forças para continuar. Obrigada por ser meu porto seguro e minha luz em todos os momentos.

“A tarefa não é tanto ver o que ninguém viu, mas pensar o que ninguém pensou sobre aquilo que todo mundo vê.” – Arthur Schopenhauer

Resumo

O Transtorno do Espectro Autista (TEA) é uma condição complexa e heterogênea, com uma prevalência estimada de aproximadamente 1 em cada 44 crianças. O diagnóstico precoce é essencial para otimizar a qualidade de vida dos indivíduos afetados, pois possibilita a implementação de intervenções terapêuticas eficazes durante os períodos críticos do desenvolvimento infantil. Este estudo visa realizar validações algorítmicas para o desenvolvimento da ferramenta para apoio ao diagnóstico precoce baseado em sinais de eletroencefalograma (EEG) e aprendizado de máquina, com o objetivo de identificar características associadas ao TEA. Para isso, foram utilizados sinais de EEG de 56 indivíduos extraídos da base de dados de Sheffield. Posteriormente, foi realizada uma seleção manual dos dados de EEG para adequação às análises. Diversos métodos de aprendizado de máquina foram empregados, resultando em um desempenho de classificação elevado para os dois conjuntos de dados analisados: um com 9 eletrodos e outro com 15 eletrodos. Os resultados preliminares indicam que a análise dos sinais de EEG com configurações de 9 e 15 eletrodos apresenta um potencial significativo para a identificação de padrões associados ao TEA. Em particular, o modelo Random Forest com 500 árvores se destacou em ambas as bases de dados, alcançando uma acurácia de 98,06% na base com a configuração de 9 eletrodos e 98,49% na base com 15 eletrodos. Esses achados sugerem que o modelo proposto pode servir como uma ferramenta promissora no suporte ao diagnóstico clínico do TEA, proporcionando uma análise mais rápida e precisa dos sinais cerebrais. A eficácia observadas nos modelos destacam a viabilidade do uso de EEG combinado com técnicas de aprendizado de máquina para aprimorar o diagnóstico precoce do TEA.

Palavras-chave: Random Forest, Eletroencefalograma (EEG), Transtorno do Espectro Autista (TEA), diagnóstico precoce, aprendizado de máquina.

Abstract

Autism Spectrum Disorder (ASD) is a complex and heterogeneous condition, with an estimated prevalence of approximately 1 in 44 children. Early diagnosis is essential to optimize the quality of life for affected individuals, as it enables the implementation of effective therapeutic interventions during critical periods of child development. This study aims to develop a tool to support early diagnosis based on electroencephalogram (EEG) signals and machine learning, identifying characteristics associated with ASD. EEG signals from 56 individuals were used, extracted from the Sheffield database. A manual selection of EEG data was conducted for proper analysis. Various machine learning methods were employed, resulting in high classification performance for two datasets: one with 9 electrodes and the other with 15 electrodes. Preliminary results indicate that analyzing EEG signals with 9 and 15 electrodes shows significant potential for identifying patterns associated with ASD. In particular, the Random Forest model with 500 trees excelled in both datasets, achieving 98.06% accuracy in the 9-electrode configuration and 98.49% in the 15-electrode dataset. These findings suggest that the proposed model can serve as a promising tool in supporting the clinical diagnosis of ASD, providing faster and more accurate brain signal analysis. The observed effectiveness highlights the feasibility of using EEG combined with machine learning techniques to enhance the early diagnosis of ASD.

Keywords: Random Forest, Electroencephalogram (EEG), Autism Spectrum Disorder (ASD), Early Diagnosis, Machine Learning.

Sumário

Índice de Figuras	ix
Índice de Tabelas	xii
Tabela de Símbolos e Siglas	xiii
1 Introdução	1
1.1 Motivação e justificativa	1
1.2 Objetivos	3
1.3 Organização do trabalho	3
2 Fundamentação teórica	4
2.1 Transtorno do Espectro Autista	4
2.2 Eletroencefalograma	7
2.3 Princípios de aprendizado de máquina	11
2.4 Redes Neurais Artificiais	13
2.5 Árvores de Decisão	16
2.5.1 Random Forest	17
2.5.2 Random Tree	18
3 Trabalhos Relacionados	19
3.1 Metodologia	19
3.1.1 Semantic scholar	19
3.1.2 Termos de busca	20
3.1.3 Critérios de exclusão	20
3.1.4 Critérios de inclusão	20
3.1.5 Triagem dos artigos	20
3.2 Resultados	22
3.2.1 Principais padrões encontrados no eletroencefalograma	22
3.2.1.1 Eletrodos mais recorrentes	22
3.2.1.2 Características temporais	28
3.2.1.3 Características não-lineares	29
3.2.2 Técnicas de pré-processamento	31
3.2.2.1 Análise de Componentes Independentes (ICA)	32
3.2.2.2 Filtragem Passa-Banda	32
3.2.2.3 Outras técnicas de pré-processamento abordadas	33
3.2.3 Métodos de classificação	35
3.3 Discussão	37
3.3.1 Importância dos Padrões de Sinais Eletroencefalográficos	38
3.3.2 Relevância dos Métodos de Pré-processamento	39

3.3.3	Classificadores Mais Utilizados na Análise de EEG para Diagnóstico de TEA	40
3.3.4	Limitações do Estudo	41
3.4	Conclusão	42
4	Metodologia	44
4.1	Proposta	44
4.2	Base de dados	46
4.3	Experimento proposto	48
4.3.1	Análise da base de dados após interpolação	53
4.4	Métricas de avaliação	56
5	Resultados	59
5.1	Base com 9 Eletrodos	59
5.1.1	Base com 9 Eletrodos - Teste do Modelo	61
5.2	Base com 15 Eletrodos	62
5.2.1	Base com 15 Eletrodos - Teste do Modelo	64
5.3	Discussões	66
6	Conclusão	69
6.1	Dificuldades Encontradas	70
6.2	Contribuições	70
6.3	Trabalhos Futuros	71
	Referências	73

Índice de Figuras

Figura 1 – Representação das principais regiões cerebrais: o lobo frontal (azul), associado a funções executivas e controle motor; o lobo parietal (verde), responsável pela integração sensorial e percepção espacial; o lobo temporal (azul), envolvido no processamento auditivo e memórias; e o lobo occipital (vermelho), dedicado ao processamento visual.	8
Figura 2 – Registro da atividade cerebral: Coleta de EEG em uma criança, capturando os sinais elétricos do cérebro.	11
Figura 3 – Ilustração de um neurônio biológico.	14
Figura 4 – Esquema do neurônio matemático.	14
Figura 5 – A figura exemplifica a estrutura do MLP, destacando as diferentes camadas envolvidas no processamento dos dados. A camada de entrada é responsável por receber e transmitir os dados brutos para a próxima camada. As camadas ocultas realizam o processamento principal, aplicando funções de ativação para aprender padrões complexos. Finalmente, a camada de saída gera a resposta final, que pode ser uma classe ou um valor contínuo, dependendo do problema abordado.	16
Figura 6 – A Figura esquematiza a estrutura de uma árvore de decisão, ilustrando o nó raiz, nó interno, ramos e por fim as folhas da árvore.	17
Figura 7 – A Figura ilustra a estrutura e o funcionamento do <i>Random Forest</i>	18
Figura 8 – Fluxograma detalhando a metodologia aplicada no estudo, desde a coleta de artigos até a análise final. Este fluxograma ilustra as etapas principais: (1) definição dos objetivos de pesquisa, (2) revisão da literatura, (3) seleção de métodos de coleta de dados, (4) coleta de dados, (5) análise de dados e (6) interpretação e apresentação dos resultados.	21
Figura 9 – Representação do posicionamento dos eletrodos durante uma coleta de EEG, destacando em vermelho os eletrodos mais utilizados pelos autores nos estudos revisados.	28
Figura 10 – Distribuição dos métodos de pré-processamento utilizados nos estudos de diagnóstico de TEA através de sinais de EEG	34
Figura 11 – Distribuição dos classificadores utilizados nos estudos de diagnóstico de TEA através de sinais de EEG	37

Figura 12 – O diagrama descreve a abordagem integrada proposta para o diagnóstico do Transtorno do TEA. O processo inicia-se com uma triagem inicial, que é seguida pela avaliação clínica realizada por um neurologista ou psiquiatra, utilizando instrumentos de diagnóstico estabelecidos. Caso o TEA seja sugerido nessa avaliação, são coletados dados de EEG, que são então analisados com técnicas de aprendizado de máquina para auxiliar no diagnóstico precoce.	45
Figura 13 – Diagrama do método proposto.	46
Figura 14 – O gráfico ilustra a quantidade de eletrodos ausentes nos arquivos dos 56 indivíduos incluídos na base de dados.	47
Figura 15 – A Figura demonstra as localizações dos eletrodos usados na coleta dos dados de EEG, seguindo o posicionamento padronizado conforme configurado no EEGLAB. As diferentes cores indicam as várias regiões cerebrais, facilitando a identificação das áreas específicas associadas às atividades neurais registradas. Esse posicionamento padronizado é essencial para garantir consistência nos registros e comparabilidade entre estudos.	49
Figura 16 – O mapa dos 64 eletrodos originais foi utilizado como base para a seleção de configurações específicas. A Figura (a) representa a disposição dos 9 eletrodos selecionados, enquanto a Figura (b) ilustra a configuração dos 15 eletrodos escolhidos.	52
Figura 17 – A Figura esquematiza de forma detalhada o processo de treinamento/ validação e teste do modelo proposto.	53
Figura 18 – Distribuição dos eletrodos faltantes após a seleção manual.	54
Figura 19 – Distribuição dos eletrodos faltantes após a seleção manual por indivíduo na base com 15 eletrodos.	55
Figura 20 – Distribuição dos eletrodos faltantes após a seleção manual por indivíduo na base com 9 eletrodos.	55
Figura 21 – Distribuição dos eletrodos faltantes por região do cérebro.	56
Figura 22 – Os <i>boxplots</i> apresentados na Figura ilustram a distribuição da acurácia alcançada com a base de dados utilizando a configuração de 9 eletrodos.	61
Figura 23 – As matrizes de confusão para os classificadores <i>Random Forest</i> com 100 árvores e 500 árvores são apresentadas respectivamente para a base de 9 Eletrodos. Estas matrizes fornecem uma visão do desempenho dos classificadores, mostrando como cada modelo categorizou as instâncias nas classes positiva e negativa.	62
Figura 24 – Os <i>boxplots</i> apresentados na Figura ilustram a distribuição da acurácia alcançada com a base de dados utilizando a configuração de 15 eletrodos.	64

Figura 25 – As matrizes de confusão para os classificadores *Random Forest* com 100 árvores e 500 árvores são apresentadas respectivamente para a base de 15 Eletrodos. Estas matrizes fornecem uma visão do desempenho dos classificadores, mostrando como cada modelo categorizou as instâncias nas classes positiva e negativa. 65

Índice de Tabelas

Tabela 1 – A Tabela apresentando os artigos selecionados na revisão de literatura, destacando suas principais características e contribuições para o estudo do Transtorno do Espectro Autista através de dados de EEG.	23
Tabela 2 – Eletrodos mais recorrentes nos artigos foram Pz, F7, Fz, F4, F8, C3, Cz, C4, F3, O1, O2, Fp1, Fp2.	27
Tabela 3 – A Tabela apresenta os 34 atributos extraídos e suas respectivas fórmulas, ressaltando a diversidade de características estatísticas extraídas. Esses atributos incluem medidas estatísticas, características de frequência e tempo, além de outros parâmetros específicos importantes para uma avaliação detalhada dos sinais neurológicos. As fórmulas associadas a cada atributo fornecem uma fundamentação matemática para sua derivação, assegurando a consistência e a reprodutibilidade dos resultados obtidos.	51
Tabela 4 – Resultados da etapa de treinamento e validação do conjunto de dados com 9 eletrodos.	60
Tabela 5 – Resultados da etapa de teste do conjunto de dados com 9 eletrodos	62
Tabela 6 – Resultados da etapa de treinamento e validação do conjunto de dados com 15 eletrodos	63
Tabela 7 – Resultados da etapa de teste do conjunto de dados com 15 eletrodos	65
Tabela 8 – Contribuições derivadas dos resultados desta pesquisa.	71

Tabela de Símbolos e Siglas

μV	Microvolts
Σ	Somatório
BiLSTM	<i>Bidirectional Long Short-Term Memory Network</i>
CNN	Rede neural convolucional
DC	Decomposição de Componentes
DFA	Flutuações <i>Detrended</i>
DSM-5	Manual Diagnóstico e Estatístico de Transtornos Mentais, Quinta Edição
EEG	Eletroencefalograma
EMD	Decomposição por Modos Empíricos
ERPs	eventos relacionados a potenciais
Hz	Hertz
IA	Inteligência Artificial
ICA	Análise de Componentes Independente
IDW	Ponderação pelo Inverso da Distância
IIR	<i>Infinite Impulse Response</i>
k-NN	<i>k-Nearest Neighbors</i>
LDA	Análise Discriminante Linear
LR	<i>Logistic Regression</i>
LSTM	<i>Long Short-Term Memory</i>
MFA	Análise Marginal Fisher
MLP	<i>Multilayer Perceptron</i>

MSE	Entropia Multiescalar
NB	<i>Naive Bayes</i>
PCA	Análise de Componentes Principais
PIE	<i>Predictor Importance Estimate</i>
RF	<i>Random Forest</i>
SMOTE	<i>Synthetic Minority Oversampling Technique</i>
SSA	Análise de Espectro Singular
STFT	Transformada de Fourier de Curto Prazo
SUS	Sistema Único de Saúde
SVM	<i>Support Vector Machine</i>
TEA	Transtorno de Espectro Autista
VMD	Variação Modal <i>Decomposition</i>
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

Capítulo 1

Introdução

Este capítulo aborda as principais justificativas para o desenvolvimento deste trabalho, destacando a importância de um diagnóstico precoce do Transtorno do Espectro Autista (TEA). Além disso, discute o uso do eletroencefalograma (EEG) como ferramenta diagnóstica, especialmente quando associado ao aprendizado de máquina. São descritos os objetivos gerais e específicos do estudo e a organização do trabalho.

1.1 Motivação e justificativa

Distúrbios que alteram o funcionamento do Sistema Nervoso acometem aproximadamente 3,4 milhões de pessoas no mundo (CHOU *et al.*, 2021), apresentando um desafio significativo para os sistemas de saúde e para as famílias. Entre esses distúrbios, o Transtorno do Espectro Autista destaca-se por sua prevalência crescente e por suas complexas manifestações clínicas. Estima-se que uma a cada 44 crianças é diagnosticada com TEA (MAENNER *et al.*, 2021). A variedade de manifestações clínicas, como deficiências na comunicação social, comportamentos repetitivos, interesses altamente restritos e comportamentos sensoriais, caracteriza o TEA (LORD *et al.*, 2020). Embora seja identificado por esses sintomas, a condição é reconhecida também pela diversidade na intensidade dos sintomas, que podem variar significativamente entre os indivíduos diagnosticados (LORD *et al.*, 2018). Dessa maneira, a classificação do autismo é baseada no nível de suporte necessário para cada indivíduo, dividindo-se em três níveis: nível 1, onde o paciente precisa de suporte; nível 2, onde o paciente carece de suporte considerável; e nível 3, onde o paciente requer suporte muito substancial (VOLKMAR; REICHOW, 2013; KULAGE; SMALDONE; COHN, 2014).

Além disso, o quadro clínico do TEA abrange um vasto conjunto de manifestações, cujas consequências para os pacientes e suas famílias são múltiplas, envolvendo diversos aspectos da vida diária. Desta maneira, quanto mais cedo o diagnóstico, melhor será a qualidade de vida desses indivíduos (CHIANG; WINEMAN, 2014). Os primeiros sinais ocorrem por volta dos primeiros 12 meses de vida, contudo, em alguns casos os sintomas podem ser observados nos

primeiros 6 meses (TANNER; DOUNAVI, 2020; SARRETT; ROMMELFANGER, 2015). O diagnóstico do TEA geralmente pode ser realizado em torno dos primeiros 24 meses de vida (ZWAIGENBAUM *et al.*, 2016). Entretanto, é sabido que a média de idade do diagnóstico ocorre entre 2,7 a 7,2 anos de idade (LOUBERSAC *et al.*, 2021). O acesso a profissionais especializados, como psicólogos e psiquiatras infantis, é frequentemente limitado em áreas de menor recurso, o que pode retardar a identificação precoce de sintomas típicos do TEA, como dificuldades de comunicação, interação social e comportamentos repetitivos. A falta de uma rede de saúde acessível, especialmente em regiões mais vulneráveis, agrava essa situação. Além disso, fatores culturais e econômicos influenciam significativamente a percepção desses sintomas. Em alguns contextos, comportamentos característicos do TEA podem ser interpretados como timidez ou problemas de disciplina, o que atrasa a busca por ajuda especializada. Famílias em situação de pobreza enfrentam desafios adicionais, como a necessidade de priorizar questões de subsistência em detrimento de avaliações médicas de desenvolvimento, adiando a identificação e o tratamento adequados para o transtorno. Consequentemente, devido ao diagnóstico tardio, esses indivíduos sofrem atrasos na implementação de abordagens terapêuticas que ajudam a mitigar os sintomas.

Atualmente, o diagnóstico do TEA é essencialmente clínico, baseado em avaliações do comportamento dos indivíduos. Equipes compostas por uma gama de profissionais, incluindo psiquiatras, psicólogos clínicos e neuropsicólogos, utilizam observações e questionários para diagnosticar o TEA (HEINSFELD *et al.*, 2018; KHODATARS *et al.*, 2021). Além disso, há desafios adicionais, como a falta de precisão no diagnóstico e a demora no atendimento especializado. De acordo com ARARIPE *et al.* (2022), as famílias brasileiras de crianças com TEA enfrentam obstáculos consideráveis para acessar os cuidados necessários. Entre esses desafios estão as longas listas de espera, os custos elevados e a falta de serviços ou tratamentos disponíveis.

Consequentemente, indivíduos com TEA frequentemente enfrentam atrasos em intervenções essenciais para a mitigação dos sintomas e a melhoria da qualidade de vida. Esses atrasos no diagnóstico são particularmente prejudiciais, pois podem coincidir com a perda do período crítico de desenvolvimento infantil, durante o qual as intervenções terapêuticas demonstram maior eficácia (ABUBAKAR; KIPKEMOI, 2022). A ausência de um diagnóstico precoce priva pais e cuidadores de acesso a recursos educacionais e de suporte indispensáveis ao desenvolvimento das habilidades sociais, comunicativas e comportamentais da criança (ELDER *et al.*, 2017). Além disso, tais atrasos podem exacerbar problemas secundários, incluindo dificuldades acadêmicas, isolamento social e aumento da ansiedade ou depressão (BAJESTANI *et al.*, 2019). Assim, a identificação e a intervenção precoce são imperativas para garantir o melhor prognóstico possível para crianças com TEA.

Motivada por esse contexto, esta pesquisa visa desenvolver um modelo inovador que integra Aprendizado de Máquina e sinais eletroencefalográficos como uma ferramenta avançada de apoio ao diagnóstico de indivíduos com Transtorno do Espectro Autista. A aplicação de sinais de EEG, combinada com algoritmos de aprendizado de máquina, tem demonstrado resultados

promissores na detecção precoce do TEA (SILVA *et al.*, 2024b). A proposta central é que o sistema desenvolvido ofereça suporte especializado à equipe médica, facilitando a triagem inicial e a identificação precisa de indivíduos com o transtorno. Essa abordagem visa não apenas reduzir significativamente as filas de espera, mas também garantir que os pacientes sejam rapidamente encaminhados para as especialidades adequadas, otimizando o acesso aos tratamentos e intervenções necessárias. Assim, o modelo proposto busca aprimorar a eficiência do processo diagnóstico e melhorar a qualidade de vida das pessoas afetadas pelo TEA.

1.2 Objetivos

Este trabalho visa desenvolver um modelo inovador que integra Aprendizado de Máquina e sinais eletroencefalográficos como uma ferramenta avançada de apoio ao diagnóstico de indivíduos com Transtorno do Espectro Autista.

Como objetivos específicos deste trabalho, tem-se:

1. Realizar revisão bibliográfica para identificação padrões associados ao TEA e métodos de aplicação do aprendizado de máquina;
2. Desenvolver um modelo de aprendizado de máquina para análise de sinais de EEG associados ao TEA;
3. Testar e validar o desempenho do modelo.

1.3 Organização do trabalho

Este trabalho está estruturado em seções da seguinte forma: a Fundamentação Teórica apresenta os conceitos básicos que orientam os principais temas abordados. Na sequência, a Revisão Sistemática da Literatura oferece uma visão abrangente sobre os estudos realizados na área, incluindo os classificadores, técnicas de pré-processamento e padrões de EEG associados ao TEA. A Metodologia, apresentada no capítulo 4, descreve detalhadamente o escopo metodológico da pesquisa, com ênfase nas bases de dados utilizadas, no experimento proposto e nas métricas empregadas para avaliar os classificadores. No capítulo 5, são discutidos os Resultados obtidos no experimento. Finalmente, a Conclusão aborda as implicações do estudo e sugere direções para pesquisas futuras.

Capítulo 2

Fundamentação teórica

Este capítulo é dedicado à exploração dos fundamentos teóricos essenciais que orientam a análise e interpretação desta pesquisa. Através de uma revisão detalhada dos conceitos teóricos pertinentes, busca-se estabelecer uma base para a investigação, oferecendo uma compreensão mais detalhada dos princípios que sustentam as metodologias empregadas e as implicações dos resultados obtidos.

2.1 Transtorno do Espectro Autista

O Transtorno do Espectro Autista é uma condição neurodesenvolvimental que pode começar a manifestar seus sinais nos primeiros 12 meses de vida (MAESTRO *et al.*, 2005). Caracteriza-se por desafios substanciais na comunicação e na interação social, além de comportamentos repetitivos e interesses restritos. Indivíduos com TEA frequentemente apresentam uma elevada sensibilidade sensorial, reagindo de forma atípica a estímulos visuais, auditivos ou táteis (NAPOLITANO *et al.*, 2022). A variabilidade na apresentação dos sintomas implica que a experiência do autismo é única para cada indivíduo, o que torna o diagnóstico e a intervenção um processo altamente personalizado e desafiador.

A prevalência e incidência dos casos de TEA podem variar conforme a fonte de informação, refletindo diferentes métodos de coleta e análise de dados. Globalmente, estima-se que 98 em cada 10.000 pessoas sejam diagnosticadas com TEA (WANG *et al.*, 2022). No Brasil, estudos indicam que uma em cada 59 crianças é diagnosticada com a condição (MOLINI-AVEJONAS; MANDAJ, 2021). Esses números sugerem que o TEA é amplamente disseminado em diversas culturas e classes sociais. No entanto, a real prevalência do TEA pode estar subestimada, especialmente em áreas com acesso restrito a serviços de saúde especializados, onde as dificuldades de diagnóstico são mais acentuadas (ELSABBAGH *et al.*, 2012).

A subnotificação do TEA é agravada não apenas pela falta de conscientização das famílias sobre os sinais precoces do autismo, mas também pela ausência de informações adequadas para profissionais de saúde, educadores e outras pessoas envolvidas no cuidado e na rotina das

crianças (SIQUEIRA; PRAZERES; MAIA, 2022; BIVARCHI; KEHYAYAN; AL-KOHJI, 2021). Essa lacuna de conhecimento compromete a identificação precoce do transtorno e resulta em atrasos nas intervenções, que, quando realizadas de forma oportuna, têm o potencial de melhorar significativamente os prognósticos das crianças com TEA.

Dessa forma, é fundamental que políticas públicas foquem na promoção da conscientização em todos os níveis da sociedade e invistam na capacitação contínua de profissionais de saúde, educadores e cuidadores. Garantir que essas intervenções sejam realizadas desde os estágios iniciais do desenvolvimento pode fazer uma diferença decisiva no futuro dessas crianças, contribuindo para seu desenvolvimento e inclusão social.

Atualmente, a etiologia exata do Transtorno do Espectro Autista permanece insuficientemente compreendida, com pesquisas em andamento explorando as múltiplas dimensões desse transtorno neurodesenvolvimental complexo. Embora evidências substanciais sugiram que fatores genéticos desempenham um papel importante para o desenvolvimento da condição, não há identificação de um único gene ou mutação responsável pelo desenvolvimento do TEA. Estudos indicam uma predisposição hereditária, mas a contribuição específica de genes individuais para a manifestação do transtorno ainda não está plenamente elucidada (TORRE-UBIETA *et al.*, 2016; YOON *et al.*, 2020).

Além dos fatores genéticos, fatores ambientais também são considerados relevantes. Complicações durante a gravidez, exposições precoces a certas substâncias ou condições e outros fatores ambientais podem aumentar o risco de desenvolvimento do TEA. No entanto, essas hipóteses ainda estão em fase de investigação, e a interação entre fatores genéticos e ambientais é um campo de intensa pesquisa (YOON *et al.*, 2020).

A ausência de uma causa única e claramente definida para o TEA reflete a complexidade do transtorno, indicando que sua etiologia provavelmente resulta da interação de múltiplos fatores. Esse panorama ressalta a necessidade de uma abordagem multifacetada e integrada para a compreensão e o tratamento do TEA, considerando a ampla gama de possíveis influências que podem contribuir para o seu desenvolvimento (PARELLADA *et al.*, 2014).

O diagnóstico precoce do Transtorno do Espectro Autista enfrenta desafios substanciais. A escassez de profissionais especializados em várias regiões do Brasil exacerba a questão, resultando em extensos períodos de espera para avaliação e diagnóstico. Além disso, a heterogeneidade dos sintomas do TEA, que inclui déficits na comunicação e padrões comportamentais repetitivos, leva frequentemente a mal-entendidos ou atribuições incorretas a outras condições (HUS; SEGAL, 2021). Por exemplo, dificuldades comunicativas podem ser erroneamente interpretadas como problemas de fala não relacionados ao TEA, enquanto comportamentos repetitivos podem ser vistos como manias inofensivas. Tal interpretação inadequada dos sintomas pode resultar em diagnósticos incorretos ou tardios, privando crianças e suas famílias de intervenções cruciais durante o período mais eficaz para a implementação de tratamentos.

No Brasil, o diagnóstico do TEA idealmente deveria ser conduzido por uma equipe multidisciplinar composta por fonoaudiólogos, neurologistas, pediatras, psicólogos e psiquiatras (DIAS; CLÁUDIA, 2019). Contudo, na prática, o acesso a esses especialistas é frequentemente limitado, especialmente em regiões com poucos recursos, o que impede que esse modelo seja amplamente adotado. O diagnóstico do TEA é fundamentado nos critérios estabelecidos pelo DSM-5 (Manual Diagnóstico e Estatístico de Transtornos Mentais, Quinta Edição). Publicado em 2013, o DSM-5 unificou diversas condições previamente separadas, como o autismo clássico, a síndrome de Asperger e o transtorno invasivo do desenvolvimento não especificado, sob a denominação "Transtorno do Espectro Autista" (ASSOCIATION *et al.*, 2002). Isso simplificou os critérios diagnósticos, mas também trouxe desafios na padronização do diagnóstico, especialmente em sistemas de saúde pública com recursos limitados.

Os critérios diagnósticos do DSM-5 para o TEA incluem déficits persistentes na reciprocidade sócio-emocional e na comunicação não-verbal, dificuldades na interação social, comportamentos estereotipados, interesses restritos, e uma gama variada de respostas sensoriais, que podem manifestar-se como hipersensibilidade ou hipossensibilidade a estímulos sensoriais. Esses critérios visam garantir uma avaliação precisa e padronizada, considerando a complexidade e a variabilidade dos sintomas do TEA. A aplicação dos critérios do DSM-5, combinada com avaliações clínicas, permite uma abordagem abrangente e individualizada no diagnóstico do TEA, assegurando que as necessidades específicas de cada indivíduo sejam identificadas e tratadas de maneira adequada (ASSOCIATION *et al.*, 2002).

A classificação do TEA é baseada nos níveis de suporte necessário e é dividida em três categorias distintas. No Nível 1, os indivíduos apresentam dificuldades nas habilidades de comunicação social e na realização de tarefas cotidianas, porém, conseguem manter um grau considerável de independência. Esses indivíduos necessitam de suporte para aprimorar suas habilidades sociais e organizacionais, com intervenções voltadas para facilitar a integração e o funcionamento diário. No Nível 2, os déficits são mais pronunciados, com dificuldades significativas na comunicação e em comportamentos, exigindo um suporte substancial em diversas áreas da vida diária. A intervenção é necessária para lidar com as dificuldades de comunicação e para auxiliar na adaptação às rotinas e demandas do cotidiano. No Nível 3, os déficits são severos, abrangendo tanto a comunicação quanto comportamentos restritivos e repetitivos. Esses indivíduos necessitam de assistência contínua para realizar atividades básicas e garantir o bem-estar, refletindo a necessidade de um suporte intensivo e constante para possibilitar a funcionalidade e a qualidade de vida. Essas categorias permitem uma abordagem diferenciada e ajustada às necessidades específicas de cada indivíduo, conforme descrito por (GARDNER *et al.*, 2018).

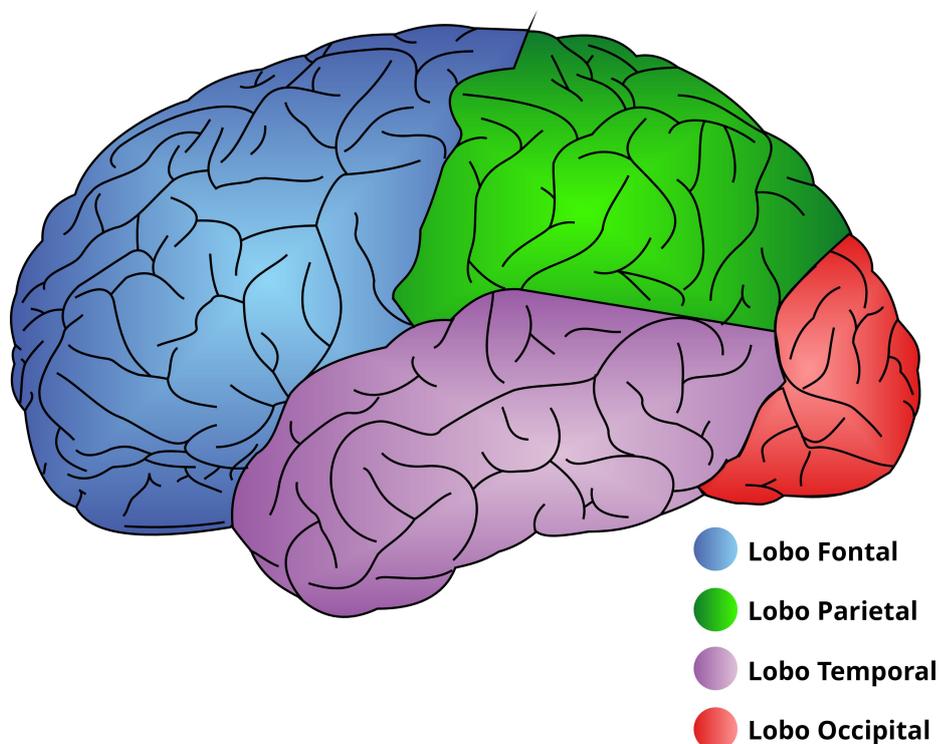
2.2 Eletroencefalograma

A eletroencefalografia é uma técnica não invasiva amplamente empregada para mensurar a atividade elétrica cerebral, por meio da colocação estratégica de eletrodos sobre o couro cabeludo (PASZKIEL, 2019). Essa abordagem permite a captura de sinais elétricos gerados pelos neurônios, fornecendo informações detalhadas sobre as funções cerebrais e possíveis distúrbios neurológicos (BLINOWSKA; DURKA, 2006). O EEG possibilita uma análise metódica da atividade elétrica cerebral, beneficiando-se da natureza não invasiva do método para o paciente. Essa técnica é fundamental para o estudo de padrões de atividade cerebral associados a diversos estados mentais, incluindo repouso, sono, atenção e respostas a estímulos específicos, contribuindo significativamente para a compreensão das dinâmicas neuronais e suas implicações clínicas.

As regiões cerebrais possuem especializações funcionais distintas, e o eletroencefalograma é uma ferramenta capaz de captar as atividades elétricas que refletem essas especializações (ANDERSON; KINNISON; PESSOA, 2013). O lobo frontal, localizado na parte anterior do cérebro, desempenha um papel em funções executivas, como planejamento, resolução de problemas, controle motor voluntário e regulação emocional. Além disso, essa região está intimamente ligada à linguagem e ao comportamento social, aspectos fundamentais para a interação humana (STUSS, 2011). O lobo parietal, situado na parte superior do cérebro, é responsável pela integração de informações sensoriais, percepção espacial e coordenação motora fina. Ele também desempenha um papel importante no processamento de estímulos táteis e visuais, permitindo a construção de uma representação precisa do ambiente (GOTTLIEB; SNYDER, 2010). Nas laterais do cérebro, o lobo temporal é conhecido no processamento auditivo, a formação e recuperação de memórias e o reconhecimento de objetos e faces. Sua contribuição para a regulação emocional e a compreensão da linguagem ressalta sua importância na dinâmica cognitiva e social (RICE *et al.*, 2018). Por outro lado, o lobo occipital, localizado na região posterior, é especializado no processamento visual. Ele interpreta estímulos relacionados a formas, cores e movimento, sendo essencial para a percepção e análise visual detalhada do ambiente (PALEJWALA *et al.*, 2021). Cada uma dessas regiões contribui para uma rede funcional integrada, e o EEG oferece uma janela para investigar essas interações complexas, especialmente em condições como o Transtorno do Espectro Autista, onde essas dinâmicas podem apresentar alterações significativas. A figura a 1 ilustra cada região citada.

No que tange ao custo do exame, conforme discutido por MCLANE *et al.* (2015), a disponibilidade e acessibilidade do EEG, assim como de outros testes diagnósticos, são estreitamente relacionadas ao nível de renda do país. De forma explícita, os custos e a facilidade de acesso a esses exames variam conforme a situação econômica do país. Pesquisas destacam a eletroencefalografia como uma ferramenta diagnóstica tanto econômica quanto eficiente para identificar anomalias neurológicas, incluindo convulsões não convulsivas (ALVI; SIULY; WANG, 2022). A natureza relativamente acessível do EEG torna-o uma opção viável em diversos

Figura 1 – Representação das principais regiões cerebrais: o lobo frontal (azul), associado a funções executivas e controle motor; o lobo parietal (verde), responsável pela integração sensorial e percepção espacial; o lobo temporal (azul), envolvido no processamento auditivo e memórias; e o lobo occipital (vermelho), dedicado ao processamento visual.



Fonte: A autora (2024)

contextos econômicos, promovendo diagnósticos precisos e contribuindo para a melhoria dos cuidados neurológicos em populações diversas.

Os elementos essenciais de um sistema de EEG compreendem eletrodos, amplificadores, gravadores e *software* de processamento de sinais. Esses componentes operam em sincronia para captar, amplificar, registrar e analisar a atividade elétrica cerebral, proporcionando uma base robusta e abrangente para diagnósticos, monitoramento e pesquisas em neurociência. Os eletrodos são responsáveis pela detecção dos sinais elétricos do cérebro, que são então amplificados para níveis utilizáveis pelos amplificadores. Os gravadores armazenam esses sinais, permitindo que o *software* de processamento de sinais execute análises detalhadas e complexas. Esse sistema integrado é fundamental para a identificação de anomalias neurológicas e para o avanço das pesquisas em neurociência, destacando-se como uma ferramenta vital para a prática clínica e científica.

A função primordial de um eletrodo em um eletroencefalograma é a medição e registro da atividade elétrica cerebral. Esta tarefa é realizada ao estabelecer uma conexão direta entre o couro cabeludo e o sistema de EEG, possibilitando a detecção e análise das ondas cerebrais. A seleção do tipo de eletrodo é fundamental para garantir a qualidade dos sinais obtidos. Os eletrodos

com gel são geralmente os mais utilizados devido à sua eficácia na fixação e na melhoria da condutividade elétrica entre o couro cabeludo e o sensor. O gel serve como meio de condução, reduzindo a impedância e garantindo que os sinais elétricos do cérebro sejam captados com maior precisão. No entanto, os eletrodos secos têm ganhado popularidade por apresentarem algumas vantagens práticas, como menor tempo de preparação e aplicação mais conveniente, já que dispensam o uso de gel. Embora os eletrodos secos tenham uma impedância geralmente superior em comparação com os eletrodos com gel, estudos indicam que as diferenças nas características dos sinais captados por ambos os tipos de eletrodos são mínimas, tornando os eletrodos secos uma abordagem viável e eficiente para a coleta de sinais de EEG. Além disso, a utilização de eletrodos secos pode ser particularmente benéfica em situações onde a rapidez e a simplicidade da preparação são essenciais, sem comprometer significativamente a qualidade dos dados obtidos (FLUMERI *et al.*, 2019; NG *et al.*, 2022; LIU *et al.*, 2019).

A frequência e a amplitude de um sinal de EEG são características essenciais que descrevem diferentes aspectos da atividade elétrica cerebral. Em condições fisiológicas normais, os sinais elétricos captados pelos eletrodos durante a realização de eletroencefalogramas apresentam uma amplitude que geralmente varia entre 15 a 150 μ V, com valores médios situando-se entre 30 a 80 μ V. Esses valores refletem a atividade elétrica cerebral típica, que pode sofrer flutuações significativas dependendo do estado cognitivo e fisiológico do indivíduo, como durante o relaxamento, concentração ou sono (NAYDENOV; YORDANOVA; MANCHEVA, 2022). A frequência dos sinais de EEG indica o ritmo da atividade cerebral, com diferentes faixas de frequência associadas a estados mentais e comportamentais específicos. Essas faixas são comumente categorizadas em bandas, como delta (0.5 – 4Hz), teta (4 – 7Hz), alfa (8 – 12Hz), beta (13 – 31Hz) e gama (32 – 90Hz) (ATTAR, 2022).

A amplitude da atividade elétrica cerebral pode ser considerada insuficiente para ser capturada adequadamente pelo eletroencefalograma, o que torna os amplificadores essenciais. Esses dispositivos intensificam os sinais elétricos originados da atividade cerebral, garantindo não apenas a precisão e confiabilidade no registro dos sinais, mas também possibilitando uma análise detalhada e robusta dos dados coletados (ZARIFI; PENG; ZARIFI, 2011).

Os gravadores são responsáveis pela medição e registro da atividade elétrica cerebral, sendo fundamentais para a obtenção de dados de EEG de alta qualidade. Esses dispositivos são amplamente utilizados em diversas áreas, incluindo a pesquisa em neurociência cognitiva e afetiva (FARRENS *et al.*, 2021). Além disso, os dados registrados têm aplicações significativas no diagnóstico e manejo de condições clínicas, na monitorização da profundidade da anestesia e na detecção de convulsões subclínicas (GUPTA; SINGH, 2015). A precisão e a qualidade dos dados obtidos pelos gravadores são cruciais para a interpretação confiável dos sinais elétricos cerebrais e para a implementação efetiva de intervenções clínicas e pesquisas avançadas.

Softwares especializados são amplamente utilizados para o processamento e análise de dados de EEG, possibilitando a aplicação de técnicas avançadas de processamento de sinais,

como filtragem, análise espectral e identificação de padrões, o que contribui para uma avaliação mais precisa e detalhada dos sinais elétricos cerebrais. No contexto da análise, esses programas desempenham múltiplas funções. Conforme destacado por [PRODANOV *et al.* \(2018\)](#), o *software* é fundamental para o processamento e visualização em tempo real das ondas cerebrais, oferecendo uma ferramenta indispensável para o treinamento em *biofeedback*. [DAS *et al.* \(2023\)](#) proporciona uma visão abrangente das ferramentas disponíveis para análise de dados de EEG, enfatizando a importância de uma fonte de referência robusta tanto para cientistas iniciantes quanto para pesquisadores experientes. A eficiência e a precisão na análise dos dados dependem diretamente da sofisticação e capacidade dos *softwares* utilizados, que facilitam a interpretação dos sinais e suportam a realização de pesquisas avançadas e práticas clínicas.

Na coleta de sinais de EEG, os sistemas de posicionamento de eletrodos 10-20 e 10-10 são amplamente adotados devido à sua eficácia na padronização da colocação dos eletrodos sobre o couro cabeludo ([RANA *et al.*, 2017](#)) como demonstrado na Figura 2. A manutenção da qualidade dos sinais eletroencefalográficos é de suma importância, e tal objetivo é alcançado através da adesão a protocolos de registro rigorosamente padronizados ([FARRENS *et al.*, 2021](#)). Esse rigor metodológico não apenas assegura a consistência e a confiabilidade dos dados capturados, mas também reforça a validade dos resultados obtidos, ao minimizar variabilidades associadas à configuração dos eletrodos e ao processo de coleta. A utilização sistemática desses protocolos é importante para garantir que os dados de EEG sejam comparáveis e reproduzíveis, facilitando a interpretação precisa e a replicação dos resultados em pesquisas e aplicações clínicas.

Estudos recentes têm demonstrado o uso promissor do EEG em diversas aplicações, como no reconhecimento de emoções em populações específicas e no controle motor em pacientes com deficiência. O trabalho de [SANTANA *et al.* \(2022\)](#) empregou eletroencefalograma e sinais fisiológicos, aliados a técnicas avançadas de inteligência artificial, para o reconhecimento de emoções em idosos, alcançando uma acurácia notável de 100%. Por sua vez, [GOMES *et al.* \(2023\)](#) utilizaram o EEG para classificar movimentos imaginados das mãos direita e esquerda em pacientes com deficiência motora, explorando sinais cerebrais gerados durante a Imaginação Motora. Esses estudos evidenciam a aplicabilidade do EEG em contextos diversos, desde a análise de estados emocionais até o desenvolvimento de tecnologias de reabilitação motora, reforçando seu potencial em neurociência computacional e interfaces cérebro-máquina.

Em síntese, o eletroencefalograma consiste em uma ferramenta imprescindível para a investigação da atividade cerebral, oferecendo dados detalhados sobre uma ampla gama de estados mentais e processos neurofisiológicos. Embora desafios econômicos possam impactar a acessibilidade do exame, a sua eficácia na identificação de anomalias neurológicas permanece notável. À medida que a tecnologia e as metodologias associadas ao EEG evoluem, a sua relevância no avanço da compreensão das funções cerebrais e na promoção de descobertas inovadoras na neurociência é cada vez mais evidente. O EEG, portanto, continua a desempenhar um papel central no campo da neurociência, com um potencial significativo para futuros avanços

Figura 2 – Registro da atividade cerebral: Coleta de EEG em uma criança, capturando os sinais elétricos do cérebro.



Fonte: Gerado pela autora no COPILOT em 31/07/2024.

na pesquisa e na prática clínica.

2.3 Princípios de aprendizado de máquina

O aprendizado de máquina, um ramo fundamental da inteligência artificial, capacita sistemas computacionais a aprenderem a executar tarefas e a aperfeiçoarem seu desempenho ao longo do tempo sem a necessidade de programação explícita (NAQA; MURPHY, 2015; HAHN, 2019). Essa tecnologia é particularmente valiosa em setores como a medicina, onde tem o potencial de automatizar e otimizar processos complexos, resultando em avanços significativos tanto na eficiência quanto na precisão das intervenções (NAQA; MURPHY, 2015). O aprendizado de máquina pode ser categoricamente dividido em três principais paradigmas: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço, cada um com suas próprias metodologias e aplicações específicas. Esses paradigmas permitem a exploração e a modelagem de dados de maneiras inovadoras, proporcionando um entendimento mais profundo e a capacidade de prever resultados em contextos variados.

De acordo com SINGH (2019), o aprendizado de máquina supervisionado envolve a aplicação de algoritmos projetados para prever instâncias futuras com base em dados previamente rotulados. Essa abordagem destaca-se por sua alta eficácia em tarefas de classificação, onde os dados são categorizados utilizando informações históricas. (CHOUDHARY; GIANEY, 2017; JIANG; GRADUS; ROSELLINI, 2020) ressaltam a importância dessa técnica em diversas

áreas, incluindo pesquisas em saúde mental, enfatizando a necessidade de algoritmos robustos e generalizáveis.

Um exemplo marcante dessa aplicação é a classificação de imagens médicas para diagnóstico, na qual algoritmos são treinados com um conjunto de imagens previamente rotuladas, possibilitando a previsão precisa da classificação de novas imagens (SANTANA *et al.*, 2022; PEREIRA *et al.*, 2021). Por exemplo, sistemas de aprendizado de máquina podem ser treinados para identificar sinais de condições específicas em radiografias, aumentando a acurácia e a eficiência no diagnóstico clínico.

Outro exemplo da aplicação de aprendizado supervisionado é a previsão de risco de readmissão hospitalar, como no estudo de BARROS (2023), que utiliza dados administrativos hospitalares para desenvolver modelos preditivos de readmissão. Além disso, a pesquisa desenvolvida neste estudo, que treina dados rotulados para identificar padrões associados ao TEA, também se enquadra nesse tipo de aprendizado. Essa capacidade de aprendizagem e adaptação contínua é essencial para a implementação de sistemas de suporte à decisão médica, destacando o potencial transformador do aprendizado de máquina supervisionado no campo da saúde (GOMES *et al.*, 2020).

O aprendizado de máquina não supervisionado, conforme descrito por VERMEULEN (2020), refere-se a uma abordagem que busca inferir funções capazes de descrever estruturas ocultas a partir de dados não rotulados. Diferente do aprendizado supervisionado, essa técnica não se concentra em identificar relações explícitas entre entradas e saídas. Na prática, um exemplo significativo de sua aplicação na área da saúde é a segmentação de pacientes com base em perfis de dados clínicos. Nesse contexto, os algoritmos analisam padrões de forma autônoma, agrupando pacientes com características similares (ESPINOLA *et al.*, 2021a; ESPINOLA *et al.*, 2021b).

Outro exemplo de aplicação desse tipo de aprendizado está no mapeamento do comportamento temporal de sinais cerebrais em epilepsia, como destacado por MACHADO *et al.* (2021). Essa técnica se mostra útil para a identificação de subgrupos específicos de pacientes que podem apresentar respostas similares a determinados tratamentos, permitindo, assim, a personalização de abordagens terapêuticas e a otimização dos resultados clínicos (SINGH, 2019). Ao identificar padrões latentes e agrupamentos nos dados, o aprendizado não supervisionado oferece uma perspectiva inovadora e crucial para a medicina personalizada, contribuindo para avanços significativos na precisão e eficácia dos tratamentos médicos.

Por outro lado, o aprendizado por reforço, uma vertente do aprendizado de máquina, capacita agentes de software a determinar o comportamento ideal em contextos específicos, utilizando recompensas como guia (MAHAJAN, 2014). Essa abordagem tem demonstrado sucesso notável em tarefas de visão computacional, tais como detecção de características e reconhecimento de objetos, onde as soluções aprendidas orientam ações futuras (BERNSTEIN; BURNAEV, 2018). As capacidades de autoaprendizagem e aprendizado em tempo real tornam o

aprendizado por reforço um componente crucial no campo do aprendizado de máquina (JHAVERI *et al.*, 2022). Sua aplicação permite que os agentes ajustem suas estratégias com base na interação contínua com o ambiente, otimizando o desempenho através de um processo iterativo de tentativa e erro recompensado. Esta capacidade de adaptação dinâmica é particularmente valiosa em cenários complexos e em constante mudança, onde a antecipação de todas as variáveis possíveis é impraticável. Assim, o aprendizado por reforço se destaca como uma metodologia robusta para o desenvolvimento de sistemas autônomos avançados, com aplicações que vão desde a robótica até a análise preditiva em contextos clínicos.

Em suma, o aprendizado de máquina constitui uma verdadeira revolução no domínio da inteligência artificial, conferindo aos computadores a capacidade de evoluir e aperfeiçoar seu desempenho de maneira autônoma. Suas variadas abordagens, como o aprendizado supervisionado, não supervisionado e por reforço, apresentam um amplo espectro de possibilidades. No contexto médico, essa tecnologia se destaca como uma ferramenta indispensável, automatizando processos complexos e aprimorando a eficiência e a precisão dos diagnósticos e tratamentos. À medida que avançamos em um cenário tecnológico dinâmico e em rápida evolução, o aprendizado de máquina continua a desempenhar um papel fundamental, impulsionando inovações e promovendo descobertas significativas na ciência e na prática clínica.

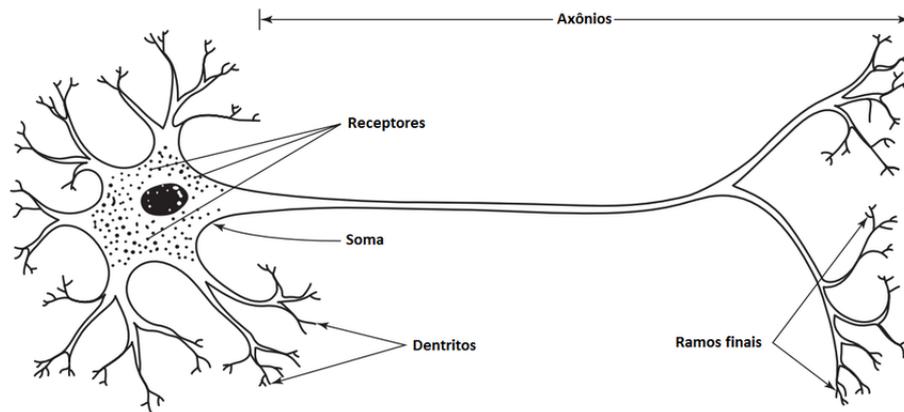
2.4 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são modelos de aprendizado de máquina inspirados na estrutura do cérebro humano. Esses modelos buscam replicar, de maneira abstrata, o comportamento dos neurônios, que são as células do sistema nervoso responsáveis pela transmissão de informações.

O neurônio biológico, representado na Figura 3, possui três partes principais: o corpo celular ou soma, os dendritos e o axônio. O axônio termina em ramificações responsáveis pela transmissão de sinais para outros neurônios, por meio de conexões chamadas sinapses, que transmitem informações através de impulsos elétricos. No cérebro humano, bilhões de neurônios estão interligados, formando uma complexa rede neural. Cada uma dessas estruturas desempenha uma função específica: o corpo celular processa as informações e as transmite para outros neurônios, enquanto os dendritos recebem impulsos elétricos (informações) provenientes de outras células. Essa arquitetura biológica inspirou o desenvolvimento de modelos matemáticos de aprendizado de máquina, como o neurônio matemático, introduzido por MCCULLOCH; PITTS (1943). Assim como os neurônios biológicos processam e transmitem informações, o neurônio matemático simula esse comportamento, recebendo entradas equivalentes aos impulsos elétricos, processando-as por meio de uma função de ativação e gerando uma saída.

A Figura 4 ilustra a estrutura de um neurônio matemático. Nessa representação, os sinais de entrada, X_1, X_2, \dots, X_n , correspondem aos dados que alimentam o modelo; no contexto

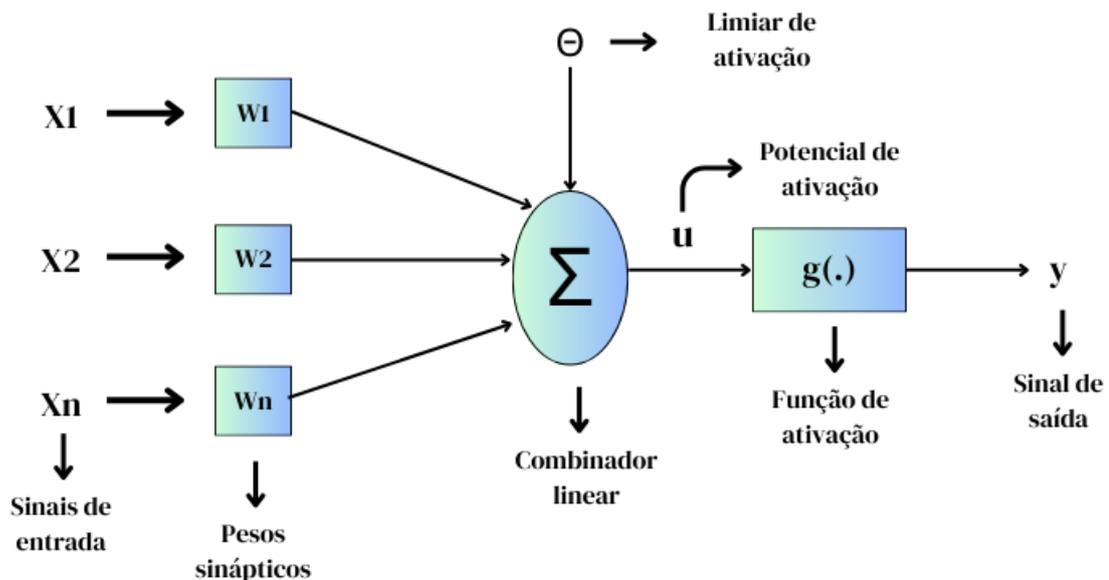
Figura 3 – Ilustração de um neurônio biológico.



Fonte: PINHEIRO (2014).

desta pesquisa, esses dados são os sinais de EEG de pacientes com TEA e indivíduos controle. Os pesos sinápticos, W_1, W_2, \dots, W_n , representam os parâmetros ajustados durante a etapa de treinamento do modelo. O somador linear Σ combina os sinais de entrada ponderados pelos seus respectivos pesos, gerando um valor conhecido como potencial de ativação. O limiar de ativação Θ define o valor a partir do qual a saída do neurônio é ativada. A diferença entre o valor gerado pelo somador linear e o limiar é processada pela função de ativação $g(u')$, que transforma o potencial de ativação em um valor de saída final, y (KOVÁCS, 2006; HAYKIN, 2001).

Figura 4 – Esquema do neurônio matemático.



Fonte: A autora (2024).

O cálculo realizado por um neurônio matemático segue uma sequência de operações fundamentais para transformar as entradas em uma saída, possibilitando que o modelo tome decisões ou contribua para uma rede neural maior. O processo inicia com a entrada ponderada, onde cada entrada X_i é multiplicada pelo respectivo peso W_i , conforme a equação $\sum_{i=1}^n X_i W_i$.

Esse passo ajusta a importância relativa de cada entrada com base nos pesos aprendidos durante o treinamento. Em seguida, as entradas ponderadas são somadas pelo combinador linear Σ , gerando o potencial de ativação $u = \sum_{i=1}^n X_i W_i$ (KOVÁCS, 2006; HAYKIN, 2001).

Após a soma das entradas, o próximo passo é a subtração do limiar de ativação Θ , resultando em $u' = u - \Theta$, o que define se o neurônio será ativado. O valor ajustado u' é então processado por uma função de ativação $g(u')$, que transforma o potencial de ativação em um valor final. A saída $y = g(u')$, por sua vez, pode ser utilizada como entrada para outros neurônios, contribuindo para o funcionamento de redes neurais mais complexas (KOVÁCS, 2006; HAYKIN, 2001).

Esse tipo de algoritmo é útil para uma ampla gama de problemas, especialmente aqueles que envolvem a classificação de condições médicas, como a identificação de pessoas com uma determinada doença ou não. Além disso, pode ser aplicado na predição de doenças, auxiliando na detecção precoce e no prognóstico. Outro exemplo é o processamento de imagens médicas, onde algoritmos podem ser treinados para identificar padrões anômalos em exames como radiografias e tomografias. O uso desses classificadores é extenso e não se limita apenas ao campo médico, podendo ser utilizado em diversos outros contextos e setores (SILVA *et al.*, 2024a; SILVA *et al.*, 2021).

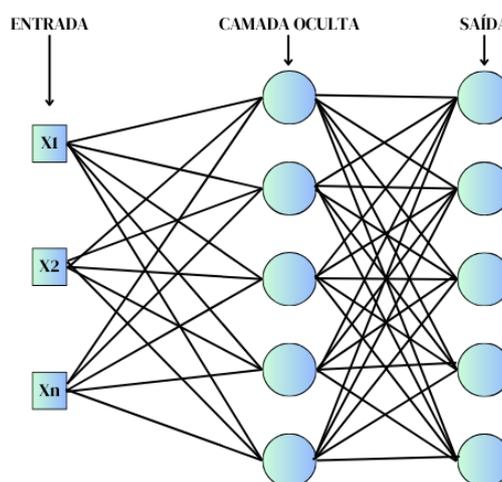
O Multilayer Perceptron (MLP) é um modelo de rede neural artificial baseado no trabalho pioneiro de ROSENBLATT (1958), que se inspirou no neurônio matemático proposto por MCCULLOCH; PITTS (1943). O MLP é amplamente utilizado em tarefas de classificação binária, onde a previsão é realizada por um único neurônio na camada de saída, ajustando seus pesos sinápticos durante o processo de aprendizado para melhorar o desempenho (BARBOSA *et al.*, 2021).

Uma das principais características do MLP é a presença de uma ou mais camadas ocultas entre a camada de entrada e a camada de saída. Essas camadas ocultas são responsáveis por permitir que a rede aprenda padrões complexos e não lineares a partir dos dados. A estrutura do MLP segue uma arquitetura de rede neural *feedforward*, na qual os dados fluem sequencialmente da entrada para a saída, sem laços de retroalimentação ou ciclos. Isso significa que a informação é propagada apenas em uma direção, facilitando a convergência durante o treinamento (HAYKIN, 2001).

Na camada de entrada, o MLP recebe os dados brutos, com cada neurônio representando uma característica específica do conjunto de dados. No entanto, os neurônios da camada de entrada não realizam cálculos, sua função é simplesmente transmitir os dados para as camadas subsequentes. As camadas ocultas, por sua vez, são o núcleo do processamento da rede. Nessa etapa, as entradas ponderadas, os dados multiplicados pelos respectivos pesos sinápticos, passam por uma função de ativação que permite à rede modelar padrões não lineares e interações complexas nos dados. Cada neurônio em uma camada oculta recebe as saídas da camada anterior, ajusta-as pelos pesos sinápticos, soma os valores resultantes (potencial de ativação), aplica

o limiar de ativação e, finalmente, processa o valor com a função de ativação. Este ciclo de processamento permite ao MLP aprender representações mais abstratas e profundas dos dados de entrada. A camada de saída, por fim, é responsável por gerar a previsão final do modelo. Dependendo do tipo de problema abordado, essa saída pode ser uma classe, no caso de problemas de classificação, ou um valor contínuo, no caso de problemas de regressão (HAYKIN, 2001; BARBOSA *et al.*, 2021). A Figura 5 ilustra o esquema do Multilayer Perceptron.

Figura 5 – A figura exemplifica a estrutura do MLP, destacando as diferentes camadas envolvidas no processamento dos dados. A camada de entrada é responsável por receber e transmitir os dados brutos para a próxima camada. As camadas ocultas realizam o processamento principal, aplicando funções de ativação para aprender padrões complexos. Finalmente, a camada de saída gera a resposta final, que pode ser uma classe ou um valor contínuo, dependendo do problema abordado.



Fonte: A autora (2024).

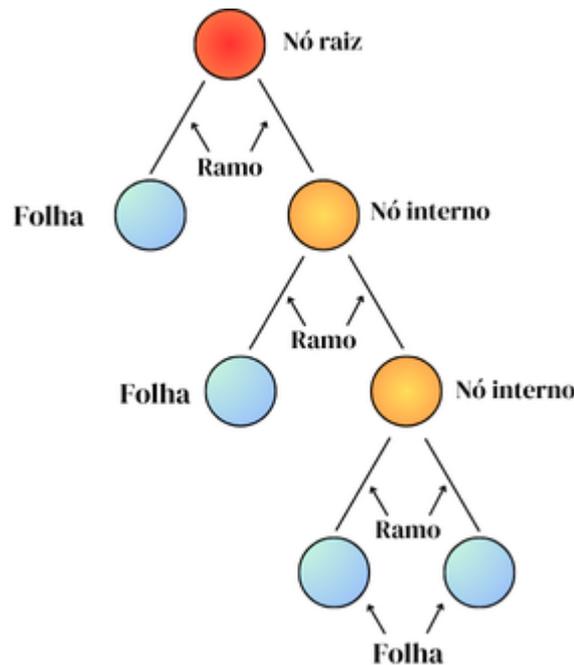
2.5 Árvores de Decisão

Árvores de decisão são algoritmos de aprendizado supervisionado desenvolvidos por QUINLAN (1987). Esses modelos são amplamente utilizados tanto para classificação quanto para regressão. A estrutura das árvores de decisão é baseada em uma hierarquia de decisões, onde cada nó interno corresponde a uma pergunta ou condição aplicada aos dados, e cada ramo representa um resultado possível dessa condição (GARETH *et al.*, 2013).

As árvores de decisão possuem a seguinte estrutura: o nó raiz, que representa a primeira condição a ser avaliada, é selecionado com base no conceito de entropia, visando a melhor separação dos dados em grupos distintos. Os ramos conectam os nós e representam as possíveis respostas ou caminhos que os dados podem seguir após a avaliação do nó anterior. Os nós internos continuam a avaliar as características dos dados, seguindo o fluxo estabelecido pelos ramos. Por fim, as folhas da árvore são onde ocorre a classificação ou a regressão, fornecendo o resultado final. Vale destacar que o processo de decisão em árvores é determinístico, sendo

orientado por métricas predefinidas, como a entropia ou o índice de Gini. A cada subdivisão dos dados, o algoritmo repete o processo de avaliação das características dos subconjuntos gerados, refinando as decisões a cada etapa (GARETH *et al.*, 2013). A Figura 6 esquematiza a estrutura de uma árvore de decisão.

Figura 6 – A Figura esquematiza a estrutura de uma árvore de decisão, ilustrando o nó raiz, nó interno, ramos e por fim as folhas da árvore.



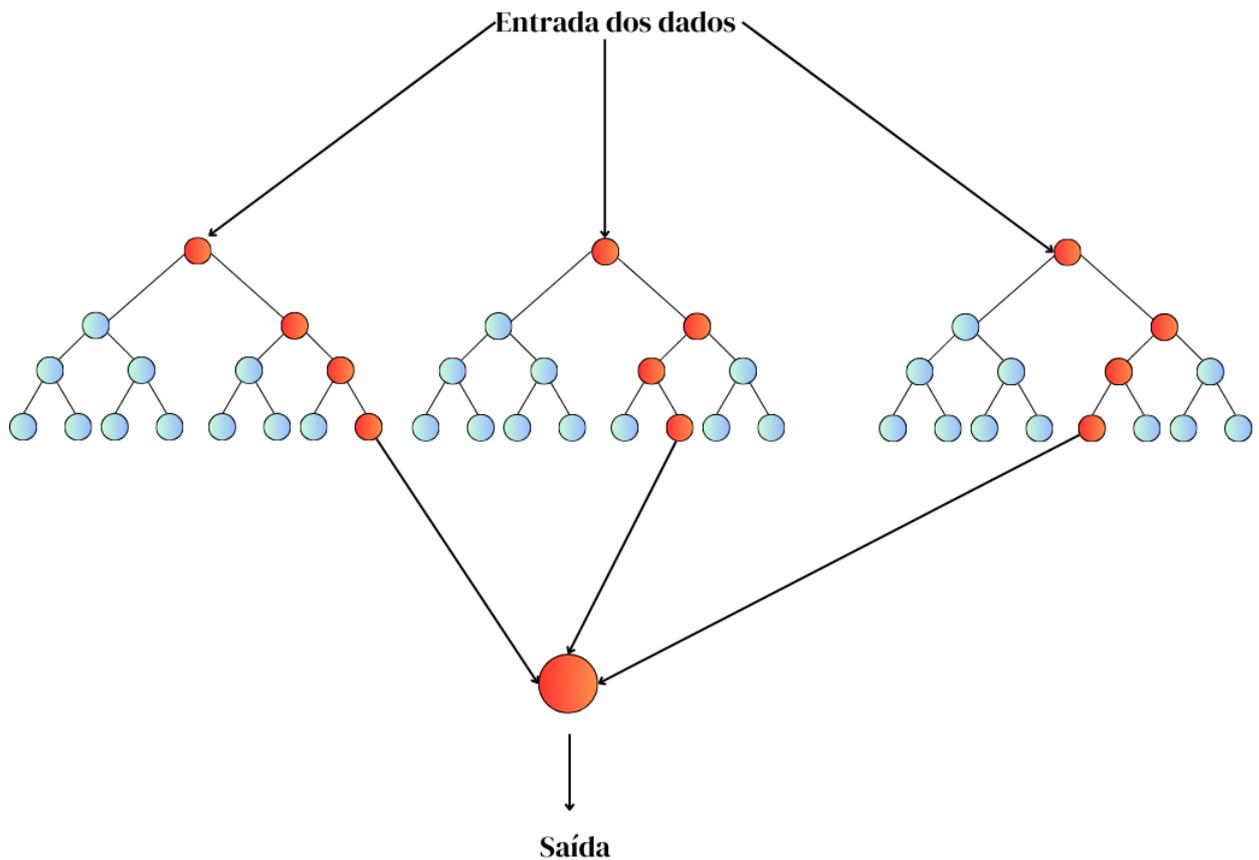
Fonte: A autora (2024).

2.5.1 Random Forest

O *Random Forest* é um conjunto de árvores de decisão, combinadas de maneira aleatória, para gerar uma resposta final ao problema proposto. Como um modelo de ensemble, ele se destaca por sua robustez, já que cada árvore no conjunto contribui com uma predição individual, e a resposta final é obtida por votação ou pela média das predições. Esse método foi desenvolvido por BREIMAN (2001).

No *Random Forest*, um subconjunto aleatório dos dados é usado para construir cada árvore, e essas árvores não utilizam todas as características do conjunto de dados. De forma aleatória, o algoritmo seleciona um subconjunto de características para cada nó, o que torna as árvores mais heterogêneas. Após a construção das árvores, os resultados individuais são combinados. Para problemas de classificação, essa combinação é feita por meio de votação majoritária entre as árvores, enquanto, para regressão, a média das predições define o resultado. Isso contribui para a robustez e eficácia do modelo, tornando-o menos propenso a *overfitting* (GARETH *et al.*, 2013). A Figura 7 exemplifica o processo de tomada de decisão do *Random Forest*.

Figura 7 – A Figura ilustra a estrutura e o funcionamento do *Random Forest*.



Fonte: A autora (2024).

2.5.2 Random Tree

O Random Tree é um algoritmo baseado em árvores de decisão, construído com um grau significativo de aleatoriedade. Nesse algoritmo, nem todas as características são consideradas em cada nó. Em vez disso, um subconjunto de características aleatórias é selecionado para cada nó da árvore. As decisões feitas em cada nó, portanto, baseiam-se apenas nesse subconjunto de características, o que introduz uma variação no processo de construção da árvore. Essa abordagem tem como objetivo melhorar a capacidade de generalização do modelo, evitando o overfitting e tornando o algoritmo mais robusto, especialmente em cenários com grande variabilidade nos dados (GARETH *et al.*, 2013).

Capítulo 3

Trabalhos Relacionados

Os trabalhos citados ao longo deste capítulo foram obtidos por meio de uma revisão sistemática da literatura. A Seção 3.1 detalha a metodologia aplicada para a obtenção desses estudos. A Seção 3.2 apresenta os resultados encontrados. Já a Seção 3.3 traz uma discussão aprofundada sobre os trabalhos mencionados neste capítulo, finalmente, a seção 3.4 conclui o capítulo.

3.1 Metodologia

Nesta seção, será detalhado a metodologia utilizada para a condução desta revisão sistemática da literatura. Serão explicados os critérios de inclusão e exclusão dos estudos, os termos de busca empregados e o processo de seleção dos artigos.

3.1.1 Semantic scholar

A ferramenta *Semantic Scholar* foi utilizada como fonte de pesquisa para esta revisão sistemática da literatura. Este recurso permite a pesquisa em mais de 50 bases de dados, garantindo uma ampla cobertura e acesso a uma vasta gama de artigos científicos e estudos relacionados. A escolha do *Semantic Scholar* deve-se à sua capacidade de fornecer resultados abrangentes, facilitando a identificação de literatura relevante e a filtragem em vários bancos de dados simultaneamente. As buscas foram direcionadas para publicações de pesquisa original em conferências ou periódicos, focando no uso de eletroencefalograma associado a técnicas de inteligência artificial. O período considerado para a coleta dos estudos foi de janeiro de 2019 a março de 2024, abrangendo os últimos cinco anos. Essa delimitação temporal foi escolhida para garantir que a revisão incluísse as pesquisas mais recentes e relevantes, refletindo os avanços e tendências atuais na aplicação de IA em EEG para o diagnóstico precoce de TEA.

3.1.2 Termos de busca

A busca foi realizada utilizando um conjunto de termos de inclusão cuidadosamente selecionados para maximizar a relevância dos resultados. Esse conjunto foi elaborado para capturar estudos focados no uso de EEG associado a técnicas de inteligência artificial no contexto do diagnóstico precoce de TEA. Os termos utilizados foram: ("**artificial intelligence**"OR "**deep learning**"OR "**machine learning**") AND ("**Autism Spectrum Disorder**"OR "**ASD**") AND ("**electroencephalogram**"OR "**EEG**"). A busca inicial resultou em 229 artigos, que foram posteriormente avaliados quanto à relevância e qualidade, com o objetivo de identificar aqueles que melhor abordassem o tema em questão.

3.1.3 Critérios de exclusão

Para garantir a relevância dos estudos, foram estabelecidos critérios de exclusão específicos. Os trabalhos que não estavam disponíveis em inglês foram excluídos, levando em consideração a limitação de compreensão da língua, assim como aqueles que não estavam acessíveis na íntegra. Trabalhos duplicados foram removidos para evitar redundância e garantir a originalidade dos dados analisados. Além disso, foram excluídos trabalhos em formatos como pôsteres, tutoriais, editoriais, capítulos de livro ou resumos simples, por não fornecerem detalhes suficientes para uma análise crítica. Também foram eliminados estudos que não utilizavam técnicas de inteligência artificial na análise de EEG para o diagnóstico do TEA, assegurando o foco na integração de IA e EEG. Trabalhos que não usavam sinais de EEG como fonte de dados para o diagnóstico do TEA foram descartados para manter a pertinência ao tema central da revisão. Além disso, foram excluídos estudos envolvendo participantes sem diagnóstico confirmado de TEA ou com outras condições neuropsiquiátricas, a fim de evitar confusões nos resultados. Por fim, trabalhos que combinavam EEG com outras tecnologias para o diagnóstico do TEA foram retirados para manter o foco exclusivamente na análise de EEG e inteligência artificial.

3.1.4 Critérios de inclusão

Os critérios de inclusão foram estabelecidos para garantir a seleção de artigos com características alinhadas às necessidades do estudo. Os trabalhos escolhidos utilizaram técnicas de inteligência artificial, como aprendizado de máquina, redes neurais ou métodos similares, para analisar dados de eletroencefalograma no contexto do diagnóstico do autismo. Foi essencial que esses estudos demonstrassem a aplicação prática dessas técnicas na análise de EEG, oferecendo contribuições significativas para o diagnóstico precoce do TEA.

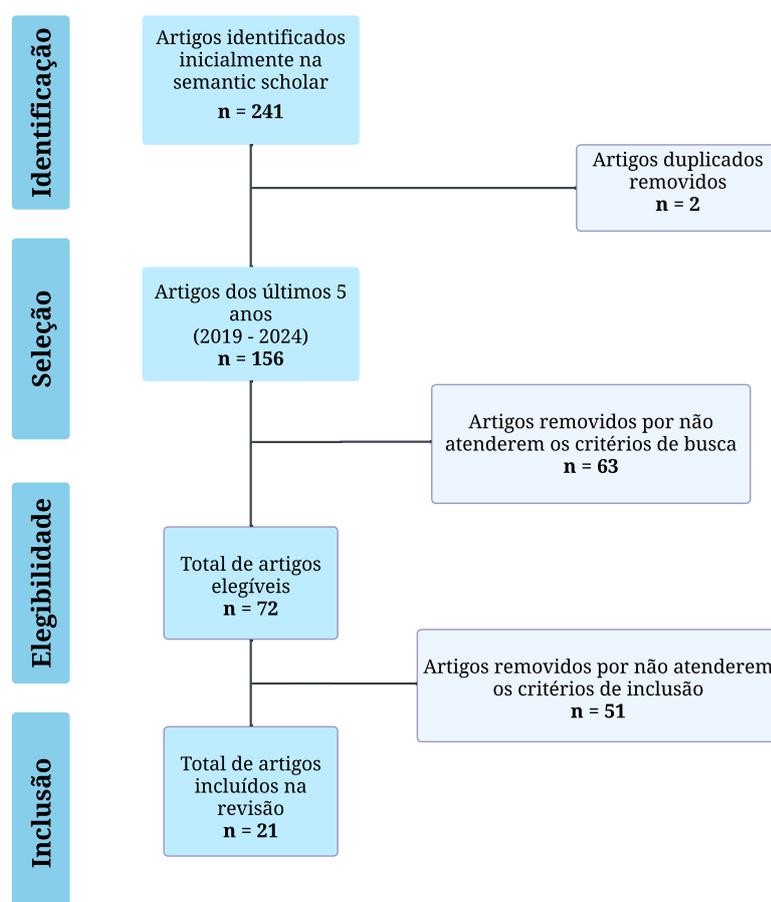
3.1.5 Triagem dos artigos

Os artigos foram submetidos a um processo de triagem em três etapas: leitura dos títulos, leitura dos resumos e leitura completa do artigo. Inicialmente, 229 artigos foram identificados

por meio dos termos de busca. Após a aplicação do filtro temporal de 2019 a 2024, 158 artigos permaneceram. Desses, 6 artigos foram excluídos devido à falta de acesso, pois exigiam pagamento para leitura, e 2 foram removidos por serem duplicados. Posteriormente, 63 artigos foram excluídos com base na análise dos títulos. Durante a revisão dos resumos, mais 40 artigos foram descartados por não atenderem aos critérios de exclusão estabelecidos. Por fim, na etapa de leitura completa dos artigos, 26 trabalhos adicionais foram excluídos. Ao final do processo de triagem, restaram 21 artigos para serem discutidos nesta revisão. A Figura 8 representa o esquema usado da metodologia para este estudo.

Figura 8 – Fluxograma detalhando a metodologia aplicada no estudo, desde a coleta de artigos até a análise final. Este fluxograma ilustra as etapas principais: (1) definição dos objetivos de pesquisa, (2) revisão da literatura, (3) seleção de métodos de coleta de dados, (4) coleta de dados, (5) análise de dados e (6) interpretação e apresentação dos resultados.

("artificial intelligence" OR "deep learning" OR "machine learning") AND ("Autism Spectrum Disorder" OR "ASD") AND ("electroencephalogram" OR "EEG")



Fonte: A autora (2024).

3.2 Resultados

Nesta seção, serão apresentados os resultados relacionados aos artigos selecionados para esta revisão. Serão apresentados os principais achados desses estudos.

Após a aplicação dos critérios de exclusão e inclusão, foram selecionados 21 estudos. A Tabela 1 resume as principais características desses estudos.

3.2.1 Principais padrões encontrados no eletroencefalograma

O eletroencefalograma é uma ferramenta essencial na neurociência e na medicina, permitindo uma análise detalhada da atividade elétrica cerebral. Por meio da detecção de padrões específicos de ondas cerebrais, como delta, theta, alfa, beta e gama, o EEG auxilia na identificação de condições neurológicas, como epilepsia e demências, além do monitoramento de outras doenças (AKILA *et al.*, 2020; ALVI; SIULY; WANG, 2021). A sua aplicação é não invasiva e economicamente viável (GOPU; NEELAVENI; KARANTHARAJ, 2009). Dessa maneira, vários estudos observaram uma oportunidade de utilizar essa ferramenta para auxiliar no diagnóstico precoce de TEA. O uso de sinais de eletroencefalograma nesse contexto permite a identificação de padrões neurológicos característicos do TEA, possibilitando intervenções mais precoces e personalizadas.

As próximas subseções apresentam os achados na literatura sobre as características do EEG relacionadas ao Transtorno do Espectro do Autismo. Serão discutidos os eletrodos mais recorrentes utilizados para aquisição de sinais de EEG em estudos sobre TEA, bem como as características temporais desses sinais, como amplitude e frequência. Além disso, serão abordadas as características não-lineares do EEG, como complexidade e entropia.

3.2.1.1 Eletrodos mais recorrentes

O eletroencefalograma utiliza dois sistemas principais para a organização e colocação dos eletrodos no couro cabeludo: o sistema internacional 10-20 e o sistema internacional 10-10. No sistema 10-20, os eletrodos são posicionados em intervalos de 10% ou 20% da distância total entre pontos anatômicos específicos no crânio. Em contrapartida, o sistema 10-10 possui uma colocação de eletrodos mais densa e detalhada, com intervalos de 10% da distância total entre os pontos anatômicos.

Nos trabalhos selecionados, todos utilizaram o sistema internacional 10-20. No entanto, apenas 11 estudos forneceram informações detalhadas sobre quais canais foram utilizados na análise do EEG. Dentre esses, dois estudos foram conduzidos pelo mesmo autor em anos diferentes. Levando isso em consideração, a frequência com que esses eletrodos foram utilizados pelos autores é apresentada na Tabela 2.

Os eletrodos descritos na Tabela 15 estão organizados em diferentes áreas do cérebro

Tabela 1 – A Tabela apresentando os artigos selecionados na revisão de literatura, destacando suas principais características e contribuições para o estudo do Transtorno do Espectro Autista através de dados de EEG.

Autor(es) / Ano	Sistema de EGG	Quantidade de eletrodos	Eletrodos analisados	Quantidade de participantes	Idade dos participantes	Frequência de amostragem	Tempo de Gravação	Pré-processamento	Métodos de classificação	Métricas utilizadas	Resultados	Limitações
Abdulhay et al., 2022	10-20	64	*	122	4 - 13 anos	500 Hz	20 minutos	Hilbert transform, Empirical Mode Decomposition (EMD), Normalização dos Componentes, Cálculo das Contrapartes Analíticas e Cálculo da Entropia de Shannon	Modelo baseado em EMD	Acurácia, valor preditivo negativo, valor preditivo positivo, razão de verossimilhança negativa, razão de verossimilhança positiva, especificidade e sensibilidade	O modelo proposto atingiu uma acurácia de 93,44%. O custo computacional pode ser um obstáculo significativo.	
Abdulhay et al., 2023	10-20	64	*	120	4 - 13 anos	500 Hz	25 minutos	Análise de Componentes Principais (PCA)	SCG-based NN	Acurácia, sensibilidade, especificidade, valor preditivo negativo e valor preditivo positivo	Acurácia de 98,5%, sensibilidade de 99,1%, especificidade de 99,9%, valor preditivo positivo de 99,4% e valor preditivo negativo de 98,2%. O custo computacional pode ser um obstáculo significativo.	
Ali et al., 2021	*	117	*	53	*	500 Hz	2 - 12 minutos	*	BiLSTM e LSTM	Acurácia, precisão, sensibilidade	Os resultados mais promissores foram observados ao utilizar uma divisão de 90% para treino e 10% para validação na rede LSTM bidirecional. Nessa configuração, a acurácia alcançada foi de 99,70% na etapa de validação e de 99,6% na etapa de teste. O desbalanceamento da base de dados é uma limitação significativa.	
Ali et al., 2022	*	128	*	53	*	500 Hz	2 - 12 minutos	Segmentação e aumento de dados	LSTM, BiLSTM, CNN-LSTM e ConVnet BiLSTM	Acurácia, precisão, sensibilidade, especificidade e F1 score	A BiLSTM demonstrou desempenho superior nos modelos simples, alcançando uma acurácia de 94,84%. Por outro lado, nos modelos híbridos, o ConVnet BiLSTM se destacou, atingindo uma acurácia de 97,72%. Além disso, ambos os modelos apresentaram vantagens em termos de tempo computacional. O desbalanceamento da base de dados é uma limitação significativa.	
Aslam et al., 2021	*	20	F7, F8, CP5 e CP2	17	5 - 17 anos	250 Hz	9 minutos	*	SNN	Acurácia	O trabalho alcançou uma acurácia de 85,50% na classificador shallow neural network. A limitação da pequena base de dados e a escassez de métricas adicionais para avaliar o desempenho do modelo representam aspectos que devem ser considerados neste estudo.	
Chen et al., 2023	10-20	32	*	446	3 - 11 anos	250 Hz	*	Transformada em wavelet contínua	EEGMAE	Acurácia	Utilizando avaliação linear com diferentes dimensões de incorporação, a dimensão de incorporação de 312 apresentou a melhor acurácia, alcançando 86,70%. Na abordagem que emprega a avaliação linear com diferentes proporções de máscara, a acurácia também foi de 86,70%. No entanto, ao aplicar a estratégia de pré-treinamento ajustando para 10%, foi obtida uma acurácia de 91,30%. pesar do banco de dados ser robusto, há uma necessidade significativa de balanceamento para garantir a representatividade equitativa dos diferentes grupos. Além disso, o custo computacional apresentado é elevado, o que pode limitar a aplicabilidade prática das metodologias propostas.	

Fonte: A autora (2024)

Continuação da Tabela 1

Autor(es) / Ano	Sistema de EGG	Quantidade de eletrodos	Eletrodos analisados	Quantidade de participantes	Idade dos participantes	Frequência de amostragem	Tempo de Gravação	Pré-processamento	Métodos de classificação	Métricas utilizadas	Resultados	Limitações
Kansara et al., 2024	*	14	*	5	*	*	*	ICA	CNN	Acurácia, precisão, sensibilidade	Os autores dividiram o conjunto de dados em várias proporções para treino e teste. A divisão de 85% dos dados para treino e 15% para teste apresentou o melhor resultado, alcançando uma acurácia de 92,34%.	O tamanho do banco de dados é relativamente pequeno.
Kong, Xiaoli, Jing Li e Gaoxiang Ouyang., 2023	*	128	O2, O1, Pz, P4, C4, T4, T5, P3, Cz, C3, Fz, F4, F8, T3, Fp2, F7 e Fp1	34	4 - 8 anos	*	*	ICA e aumento de dados	LDA, MLP, Backpropagation neural network, random forest, LR e SVM	Acurácia, sensibilidade, F1 score, área ROC	O estudo adotou três metodologias distintas para avaliar as características do EEG no contexto do diagnóstico do TEA. A primeira metodologia focou na avaliação das características do microestado, onde o LDA foi identificado como o melhor classificador, alcançando uma acurácia de 91%. A segunda metodologia utilizou características estatísticas, com o MLP destacando-se como o melhor classificador, com uma acurácia de 80%. Na terceira metodologia, que combinou as duas abordagens anteriores, o LDA novamente superou os outros modelos, atingindo uma acurácia de 92%.	Baixa variabilidade na idade dos participantes da pesquisa.
Melinda et al., 2023	10-20	16	FP1, F3, F7, T3, T5, O1, C4, FP2, Fz, F4, F8, C3, Cz, Pz, Oz e O2	16	9 - 16 anos	256 Hz	*	ICA E transformada discreta em Wavelet	LDA	Sensibilidade, precisão, acurácia e F1 score	Os autores alcançaram uma acurácia de 99% com o método proposto.	O tamanho do banco de dados é relativamente pequeno.
Menaka et al., 2024	*	8	O1, O2, T7, T8, F4, F3, F7 e F8	20	5 - 7 anos	*	10 minutos	filtro passa-banda e parada	AlexNet, VGG16, ResNet50, AlexNet customizada	Acurácia e teste de parada	A AlexNet demonstrou ser o classificador mais eficaz, alcançando uma acurácia de 85,16%. Além disso, aprendeu o maior teste de parada, com um coeficiente cepstral LFCC de 0,3480. Posteriormente, após modificações, a acurácia da AlexNet foi aprimorada, atingindo 90%.	O tamanho do banco de dados é relativamente pequeno, com apenas 20 participantes no total.
Mohi-ud Din e Jayanthi, 2021	10-20	16	*	17	*	256 Hz	*	Transformada em wavelet	SqueezeNet deep CNN e GoogLeNet deep CNN	Acurácia	A rede neural SqueezeNet alcançou uma acurácia de 80,71% usando o conjunto de teste, entretanto, na validação a acurácia do modelo alcançou 82,98%.	O desbalanceamento da base de dados é uma limitação significativa.
Mohi-ud Din et al., 2023	*	125 - 128	*	28	30 - 165 meses	500 Hz	2 - 12 minutos	Filtro passa-banda	SVM, Árvore de decisão, LR, KNN e FNN	Acurácia, precisão, sensibilidade e especificidade	Neste estudo, foram empregadas duas metodologias distintas. Na primeira, o classificador KNN demonstrou o melhor desempenho, alcançando uma acurácia de 90%. Entretanto, mesmo na segunda metodologia, o KNN manteve sua posição como o modelo mais eficaz, atingindo uma acurácia ainda maior, de 93%.	O banco de dados é relativamente pequeno.

Fonte: A autora (2024)

Continuação da Tabela 1

Autor(es) / Ano	Sistema de EGG	Quantidade de eletrodos	Eletrodos analisados	Quantidade de participantes	Idade dos participantes	Frequência de amostragem	Tempo de Gravação	Pré-processamento	Métodos de classificação	Métricas utilizadas	Resultados	Limitações
Oh et al., 2021	10-20	64	*	77	4 - 13 anos	500 Hz	20 minutos	MFA	SVM	Verdadeiros negativos, verdadeiros positivos, falso positivo, falso negativo, acurácia, precisão, sensibilidade e especificidade	O SVM polinomial de grau 2 foi o melhor classificador com a acurácia de 98,7%.	O processo de extração de recursos é realizado manualmente, e a seleção dos recursos ideais também é feita de forma manual, o que torna o procedimento complexo e suscetível a erros. Além disso, os dados disponíveis são insuficientes para treinar um modelo de aprendizado profundo para a classificação, limitando a eficácia e a capacidade de generalização do modelo.
Peng et al., 2021	10-20	14	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 eAF4	80	2 - 7 anos	*	*	ICA, DC, extração de sinais de diferentes ritmos e Janelamento de dados	SVM	Acurácia	Os resultados deste estudo demonstraram que a utilização do algoritmo de seleção de características L1-Norm em combinação com um classificador SVM linear resultou em uma melhoria significativa na acurácia de 93,8%.	Baixa variabilidade na idade dos participantes da pesquisa.
Radhakrishnan et al., 2021	10-20	19	Fp1, Fp2, F7, F3, Fz, F4, F8, P3, P4, Pz, T3, T5, T4, T6, O1, O2, C3, C4 e Cz	*	3 - 7 anos	500 Hz	*	filtro passa-faixa e um filtro gaussiano	DFA	Acurácia	Os resultados da análise indicam que certas regiões cerebrais apresentaram forças semelhantes de autoafinidade em crianças com desenvolvimento típico e crianças com TEA. Especificamente, o lado esquerdo do cérebro em crianças TD e a parte frontal do cérebro em crianças com TEA exibiram consistência nos valores do parâmetro de Hurst. O canal C3, em particular, mostrou diferenças estatisticamente significativas entre os dois grupos, alcançando uma acurácia de 71% na diferenciação entre crianças TD e crianças com TEA.	Falta de informações sobre os bancos de dados utilizados
Radhakrishnan et al., 2022	10-20	19	Fp1, Fp2, F7, F3, Fz, F4, F8, P3, P4, Pz, T3, T5, T4, T6, O1, O2, C3, C4 e Cz	6	3 - 7 anos	500 Hz	*	Anomalias através do PyCaret	MCD, Floresta de isolamento e ABOD	*	Os resultados do estudo indicaram que a detecção de anomalias por meio do módulo de Detecção de Anomalias do PyCaret foi eficaz na análise dos padrões de EEG de crianças autistas em resposta a estímulos visuais. Foram identificadas diferenças significativas nos padrões de anomalias entre crianças com transtorno do espectro autista e crianças em desenvolvimento típico.	O tamanho do banco de dados é relativamente pequeno.
Roopa Rechal et al., 2021	*	8	C3, Cz, C4, CPz, P3, Pz, P4 e POz	13	21 - 26 anos	250 Hz	*	VMD e PIE	KNN, RNAs e SVM	Acurácia, sensibilidade, especificidade, precisão, medida F e média G	De modo geral, todos os classificadores apresentaram desempenho acima de 90%. No entanto, o SVM, quando aplicado com PIE, obteve os melhores resultados, alcançando uma acurácia de 98,08%. As outras métricas também foram superiores a 99%, com a sensibilidade atingindo 100%.	Tamanho reduzido das bases de dados e a falta de informações detalhadas sobre elas, assim como a falta de diversidade de idade entre os participantes.

Fonte: A autora (2024)

Continuação da Tabela 1

Autor(es) / Ano	Sistema de EGG	Quantidade de eletrodos	Eletrodos analisados	Quantidade de participantes	Idade dos participantes	Frequência de amostragem	Tempo de Gravação	Pré-processamento	Métodos de classificação	Métricas utilizadas	Resultados	Limitações
Sanabria-Barradas, Saneer e Gramados-Ramos, 2022	10-20	19	*	8	*	1000 Hz	180 segundos	CP e SSA	Árvore de decisão	Acurácia	Ao utilizar todas as 66 características extraídas (incluindo atributos relacionados a faces e objetos), a acurácia da classificação foi de apenas 33%. No entanto, ao considerar apenas os 33 atributos relacionados a objetos, a acurácia da classificação aumentou para 100%.	Embora os resultados demonstrem uma acurácia considerável na classificação dos indivíduos com TEA, a ausência de informações sobre como o modelo e ausência em qual algoritmo foi utilizado
Tasnim et al., 2022	*	8	C3, Cz, C4, CPz, P3, P4, POz, Pz	15	*	250 Hz	*	Aumento de dados com SMOTE	LDA, SVM, MLP, random forest e Métodos de Ensemble	Acurácia	A escolha do LDA como o melhor classificador, devido ao custo computacional, resultou em uma acurácia de 66,36% na primeira fase e 62,07% na segunda fase do estudo. Posteriormente, os resultados dos quatro classificadores baseados em aprendizado de máquina foram utilizados para criar um modelo de ensemble por meio de uma estratégia de votação suave. Esse ensemble model alcançou uma acurácia de 75,15%, representando uma melhora significativa em relação aos classificadores individuais.	A coleta de dados se restringiu aos indivíduos com TEA, não havendo um grupo de controle para comparação. Além disso, foram utilizadas poucas métricas na avaliação do modelo, limitando a análise.
Tawhid et al., 2021	10-20	16	Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, Pz, T5, O1, Oz e O2	16	6 - 20 anos	256 Hz	*	CAR, IIR e normalização	NB, LDA, random forest, KNN, LR, SVM e CNN	Sensibilidade, especificidade, F1 score, Area ROC e acurácia	Entre os modelos baseados em aprendizado de máquina, o SVM alcançou a melhor acurácia, atingindo 95,25%. Por outro lado, entre os modelos baseados em aprendizado profundo, o modelo 3 (B164) destacou-se com uma acurácia de 99,15%.	O desbalançamento entre os grupos TEA e típicos, juntamente com uma grande disparidade na distribuição etária dos participantes, representa uma limitação significativa deste estudo.
Wadhara et al., 2023	10-20	32	F7, F3, Fz, F8, Fp1, F4, Fp2, O1, O2, T3, T5, C3, C4, T4, T8, P7, Pz, P4, P8, Oz	66	5 - 21 anos	256 Hz	20 minutos	ICA	SVM, RNN, LSTM, Bi-LSTM, GRU e GRU modificada	Acurácia, precisão, sensibilidade e F1 score	O método proposto, um GRU modificado, demonstrou ser o modelo mais eficaz, com uma acurácia de 97,28% tanto no treinamento quanto no teste, alcançando resultados consistentes em ambas as etapas.	A complexidade e o custo computacional representam desafios significativos neste trabalho.

Fonte: A autora (2024)

Tabela 2 – Eletrodos mais recorrentes nos artigos foram Pz, F7, Fz, F4, F8, C3, Cz, C4, F3, O1, O2, Fp1, Fp2.

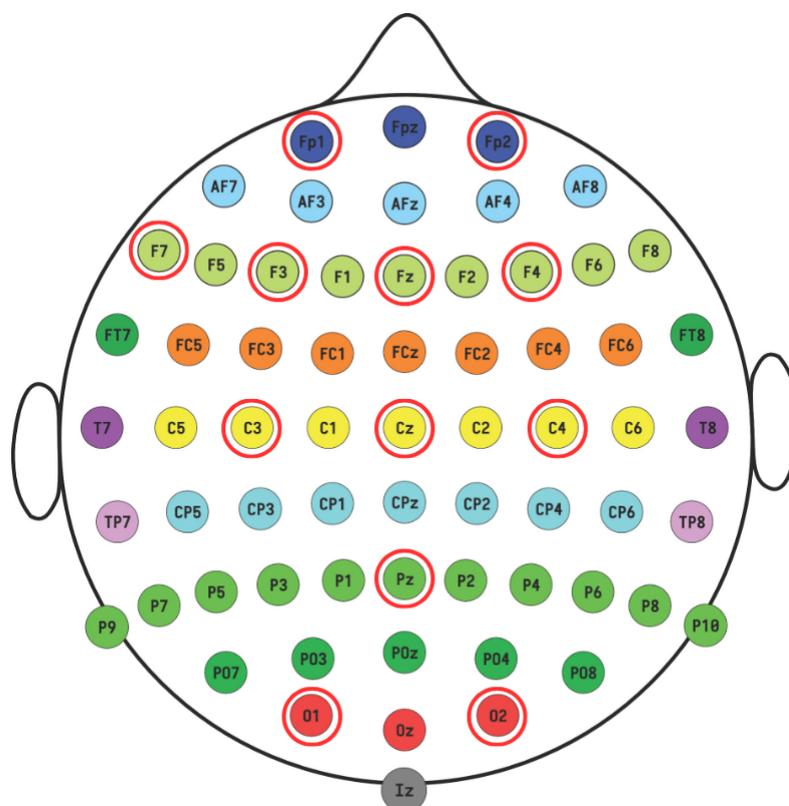
Canais	Quantidade
Pz	8
F7	8
Fz	8
F4	8
F8	8
C3	7
Cz	7
C4	7
F3	7
O1	7
O2	7
Fp1	6
Fp2	6

Fonte: A autora (2024)

humano, cada uma responsável por funções distintas. Os eletrodos Fp1 e Fp2 estão localizados na região do córtex fronto-polar. O eletrodo Fp1, situado no lado esquerdo, desempenha um papel importante em funções relacionadas à cognição, percepção e memória. Contudo, o eletrodo Fp2, localizado no lado direito, está associado à cognição social e aspectos afetivos (BLUDAU *et al.*, 2014). Os eletrodos localizados na região frontal do cérebro, como F3, F4, Fz, F7 e F8 desempenham papéis importantes em diversas funções cognitivas. Por exemplo, a área frontal está envolvida no controle motor, na produção da fala, no comportamento prospectivo e na memória (CATANI *et al.*, 2012). A região central do cérebro, representada pelos eletrodos C3, Cz e C4, está relacionada ao processamento do controle motor (MARCUS; JACOBSON, 2003). Os eletrodos O1 e O2 estão posicionados na região occipital do cérebro, conhecida por estar associada a funções relacionadas à visão (DUPONT *et al.*, 1997). Por último, a região parietal, representada pelo eletrodo Pz, é especializada em funções na integração de estímulos sensoriais e na execução de movimentos coordenados (CULHAM; VALYEAR, 2006). A Figura 9 representa os eletrodos mais recorrentes nos artigos selecionados para esta revisão.

A variabilidade na quantidade dos eletrodos utilizados em cada estudo pode não está associada aos resultados de acurácia obtidos para classificação de autismo. Por exemplo, em pesquisas que empregaram um número reduzido de eletrodos, como o estudo de ASLAM *et al.* (2021), que utilizou apenas 4 eletrodos, foi alcançada uma acurácia de 85,50% ao aplicar um Shallow Neural Network (SNN). Este tipo de rede neural artificial utiliza apenas uma camada oculta entre a camada de entrada e a camada de saída. No entanto, estudos como o de WADHERA; BEDI; SHARMA (2023), que empregaram 20 eletrodos e classificadores baseados em aprendizado de máquina e redes neurais artificiais, obtiveram resultados superiores,

Figura 9 – Representação do posicionamento dos eletrodos durante uma coleta de EEG, destacando em vermelho os eletrodos mais utilizados pelos autores nos estudos revisados.



Fonte: A autora (2024)

alcançando uma acurácia de 97,28% com uma Gated Recurrent Unit (GRU). Nesse modelo, foi adicionada uma estrutura bidirecional, onde duas camadas foram utilizadas para permitir que a rede neural processasse os sinais de entrada de forma ordenada e sistemática.

Com base nesses resultados, pode sugerir que a localização dos eletrodos utilizados deve ser mais direcionada para áreas conhecidas na neurociência que correspondem a menor ativação cerebral em pacientes com TEA. Um exemplo é a região frontotemporal, que, quando comparada a indivíduos neurotípicos, apresenta uma menor ativação da região em indivíduos com TEA (HIRATA *et al.*, 2018).

3.2.1.2 Características temporais

As características temporais do EEG estão relacionadas à forma como a atividade elétrica cerebral se comporta ao longo do tempo. Essa atividade é representada por meio de uma variedade de padrões de ondas cerebrais, que abrangem diferentes frequências e amplitudes, incluindo eventos relacionados a potenciais (ERPs) e análises de ritmo oscilatório. Essas ondas, como delta, theta, alpha, beta e gamma, refletem uma diversidade de estados mentais e processos cognitivos. Portanto, analisar essas características temporais permite uma compreensão mais profunda do funcionamento do cérebro em diversos cenários.

No contexto do autismo, vários estudos têm se dedicado à análise das características temporais do EEG a fim de identificar padrões distintivos associados ao transtorno. Por exemplo, [SANABRIA-BARRADAS; SANEI; GRANADOS-RAMOS \(2022\)](#) desenvolveram uma abordagem híbrida de fatoração para detectar os ERPs. Eles aplicaram essa análise para remover as atividades cerebrais beta e, posteriormente, estimaram automaticamente os parâmetros dos eventos relacionados a potenciais. Com essa abordagem, conseguiram identificar componentes como o P1, associado à percepção de estímulos sensoriais, como a forma de objetos, timbre e luminosidade. Além disso, identificaram outro componente, o N170, associado à percepção de emoções e processos cognitivos. Ao analisar a amplitude e latência das respostas cerebrais em indivíduos do grupo de controle em comparação com aqueles com TEA, torna-se evidente uma diferença significativa no tempo de resposta a estímulos visuais, tanto de faces quanto de objetos. Essa disparidade na amplitude e latência das respostas sugere variações nos processos neurais subjacentes à percepção e processamento desses estímulos entre os dois grupos.

Por outro lado, [ABDULHAY *et al.* \(2023\)](#) analisaram as ondulações de alta frequência na faixa de 75 a 250 Hz e observaram uma diferença significativa nas oscilações entre indivíduos com TEA e neurotípicos. Enquanto o espectro de potência dos sujeitos neurotípicos diminuiu consistentemente com o aumento da frequência, o espectro de potência das crianças com TEA apresentou-se irregular e sem um padrão específico. Essas observações sugerem variações na dinâmica neural de alta frequência entre os dois grupos, contribuindo para uma melhor compreensão das diferenças neurofisiológicas associadas ao TEA.

Além disso, [RADHAKRISHNAN; BORUAH; RAMAMURTHY \(2022\)](#) observaram variações significativas na atividade cerebral que podem ser associadas a diferenças no desenvolvimento, condições neurológicas ou respostas a estímulos. Os autores destacam que as anomalias encontradas nesses sinais abrangem principalmente as áreas frontoparietal, temporal e parietal. Essas variações regionais indicam possíveis disfunções nas conexões neurais e no processamento de informações de indivíduos com TEA.

Esses achados destacam a importância das características temporais do EEG na identificação de padrões neurais associados ao autismo. Compreender essas variações temporais é crucial para avançar na identificação de biomarcadores específicos do TEA, o que pode, por sua vez, levar ao desenvolvimento de métodos diagnósticos mais precisos e intervenções terapêuticas personalizadas. As futuras pesquisas devem continuar a explorar essas dinâmicas temporais, utilizando tecnologias e metodologias avançadas para aprofundar nossa compreensão das complexidades neurofisiológicas do TEA.

3.2.1.3 Características não-lineares

Características não-lineares são propriedades que não podem ser adequadamente representadas por equações lineares simples e frequentemente capturam aspectos complexos e dinâmicos dos dados. No contexto da análise de sinais de EEG, essas características são im-

portantes porque a atividade cerebral é inerentemente não-linear e complexa. Exemplos de características não-lineares incluem entropia, dimensão fractal, análise de flutuações detrended (DFA) e entropia multiescalar (MSE).

No estudo [ABDULHAY et al. \(2023\)](#), foram observadas diferenças na entropia do espectro de potência na faixa de ripples em várias regiões cerebrais entre crianças com Transtorno do Espectro Autista e neurotípicas. Especificamente, diferenças normalizadas notáveis foram detectadas nos seguintes canais: F4, F8, FC6, T8, AF4, TP7, TP8, F2, F6 e C5. Essas diferenças foram mais significativas em algumas crianças com TEA quando comparadas às crianças neurotípicas. As regiões mencionadas mostram variações consideráveis na entropia, que é uma medida da complexidade e previsibilidade dos sinais de EEG. Essa análise sugere que a entropia pode ser um indicador robusto das diferenças na atividade cerebral entre indivíduos com TEA e aqueles sem o transtorno.

[DIN; JAYANTHY \(2021\)](#) utilizaram a transformada *wavelet* para gerar escalogramas, que são representações em tempo-frequência dos sinais de EEG, capturando tanto características de alta quanto de baixa frequência de maneira não linear. Esses escalogramas foram convertidos em imagens RGB e utilizados para treinar redes neurais profundas pré-treinadas, como *GoogLeNet* e *SqueezeNet*, através da técnica de aprendizado por transferência. As redes neurais profundas foram re-treinadas para reconhecer padrões complexos nos escalogramas. Essa análise revelou que as CNNs, ao processarem escalogramas gerados a partir de sinais de EEG, conseguiram capturar e interpretar com sucesso as complexas características não lineares das atividades cerebrais, levando a uma classificação precisa dos sujeitos. A abordagem mostrou-se eficaz na identificação de padrões específicos associados a diferentes estados mentais, destacando o potencial das técnicas de aprendizado profundo combinadas com transformadas *wavelet* para a análise avançada de EEG.

O método proposto por [PENG et al. \(2021\)](#) utilizou diversas características não-lineares extraídas dos sinais de EEG para diferenciar crianças com TEA de crianças com desenvolvimento típico. Eles selecionaram essas características para capturar a complexidade, variabilidade e padrões não-lineares dos sinais cerebrais durante a visualização de estímulos emocionais positivos e negativos. Entre as características analisadas estavam entropia diferencial, entropia de amostragem e expoente de *Lyapunov*, entre outras. Essas características refletem a diversidade e a dinâmica das respostas cerebrais diante de estímulos emocionais, fornecendo uma representação mais abrangente das atividades cerebrais subjacentes. Ao utilizar essas características não-lineares, os pesquisadores puderam realizar uma análise detalhada das diferenças nas respostas cerebrais entre os dois grupos de crianças, contribuindo para uma melhor compreensão das características neurais associadas ao TEA.

Os pesquisadores [TAWHID et al. \(2021\)](#) utilizaram uma abordagem centrada no emprego de características não lineares para a detecção automatizada do Transtorno do Espectro Autista a partir de sinais de eletroencefalograma. Adotando a Transformada de *Fourier* de Curto Prazo

(STFT) para gerar imagens de espectrograma, o estudo preserva tanto a informação temporal quanto a de frequência, permitindo uma análise detalhada das dinâmicas cerebrais complexas associadas ao TEA. A utilização de características não lineares, como dimensão fractal, expoente de *Lyapunov* e entropia, desempenha um papel crucial na captura das complexidades e padrões não lineares dos sinais cerebrais.

Em outro estudo de [ABDULHAY *et al.* \(2022\)](#) identificaram características não-lineares significativas nos sinais de EEG de indivíduos com TEA em comparação com neurotípicos. Utilizando a Decomposição por Modos Empíricos (EMD), os pesquisadores calcularam a entropia de amplitude e frequência, revelando variações distintas entre os grupos. A análise mostrou que indivíduos com autismo apresentavam diferenças marcantes nas regiões cerebrais, com zonas de maior e menor entropia indicando possíveis alterações na conectividade neural. A Análise de Componentes Principais (PCA) destacou dois *clusters* distintos entre TEA e neurotípicos, corroborando a eficácia das características não-lineares na diferenciação dos grupos. Comparado com a MSE, o método proposto demonstrou maior precisão, sensibilidade e especificidade na classificação, sublinhando a relevância das técnicas não-lineares para um diagnóstico mais acurado do TEA.

Em síntese, a análise das características não-lineares nos sinais de EEG tem se mostrado fundamental para desvendar a complexidade das atividades cerebrais relacionadas ao Transtorno do Espectro Autista. Estudos recentes destacam que diferenças significativas na entropia, dimensão fractal e outras métricas não-lineares foram observadas entre indivíduos com TEA e neurotípicos. Essas descobertas apontam para alterações na conectividade neural e na dinâmica cerebral em pessoas com TEA. Além disso, técnicas inovadoras, como o uso de redes neurais profundas em escalogramas de EEG e a aplicação de transformadas em *wavelet*, têm apresentado resultados promissores na identificação de padrões complexos e na classificação precisa de estados mentais associados ao autismo. Assim, as características não-lineares emergem como ferramentas cruciais para compreender melhor o TEA e podem guiar o desenvolvimento de intervenções mais eficazes e personalizadas para indivíduos com esse transtorno neurológico.

3.2.2 Técnicas de pré-processamento

O pré-processamento desempenha um papel essencial na análise de sinais de EEG, ajudando a melhorar a qualidade dos dados e a identificar padrões significativos nas atividades cerebrais. Essas técnicas são fundamentais para lidar com os desafios inerentes aos sinais de EEG, como artefatos de movimento, ruídos elétricos, piscadas de olhos e variações individuais na atividade cerebral. Nesse contexto, uma variedade de métodos de pré-processamento tem sido desenvolvida e aplicada para tornar os sinais de EEG mais adequados para análise quantitativa e qualitativa.

Os trabalhos revisados utilizaram uma variedade de técnicas de pré-processamento, sendo algumas mais recorrentes, como a Análise de Componentes Independentes (ICA), filtragem

passa-banda e a Transformada *Wavelet*. Outros estudos também combinaram essas técnicas com outros métodos de pré-processamento para melhorar a qualidade e a representação dos sinais de EEG. Essa diversidade de abordagens demonstra a busca por estratégias eficazes para extrair informações relevantes dos dados de EEG e prepará-los para análises posteriores.

3.2.2.1 Análise de Componentes Independentes (ICA)

O ICA é uma técnica usada para separar os sinais de EEG em seus componentes independentes. Ele funciona separando os sinais de EEG em componentes individuais, de modo que sinais provenientes de diferentes fontes, como piscadas de olhos, movimentos musculares e atividade cerebral, possam ser identificados e separados. Isso permite que os pesquisadores isolem e analisem especificamente a atividade cerebral de interesse, eliminando interferências indesejadas e melhorando a qualidade dos dados para análise posterior.

Diversos pesquisadores empregaram essa abordagem. Por exemplo, [WADHERA; BEDI; SHARMA \(2023\)](#) aplicaram o ICA para eliminar artefatos musculares, oculares e outras atividades que introduzem ruídos nos sinais de EEG. Utilizando o ICA, o sinal foi decomposto em um conjunto de componentes independentes, partindo do pressuposto de que os sinais de diferentes fontes são independentes entre si e que os componentes independentes possuem uma distribuição não gaussiana. Essa metodologia permitiu uma limpeza eficiente dos dados, resultando em uma análise mais precisa da atividade cerebral relevante.

Em concordância, [MELINDA et al. \(2023\)](#), [PENG et al. \(2021\)](#), [KONG; LI; OUYANG \(2023\)](#) e [KANSARA et al. \(2024\)](#) também aplicaram o ICA para separar os sinais de EEG em componentes independentes, permitindo a identificação e eliminação de artefatos, como piscadas oculares e movimentos musculares, e melhorando assim a qualidade dos dados para uma análise mais precisa da atividade cerebral.

3.2.2.2 Filtragem Passa-Banda

A filtragem passa-banda é utilizada para remover ruídos indesejados e focar nas frequências de interesse dos sinais de EEG. Este método ajuda a melhorar a clareza dos sinais, eliminando frequências irrelevantes para a análise específica. Estudos como os de [MENAKA et al. \(2024\)](#) e [DIN; JAYANTHY \(2023\)](#) demonstraram a eficácia da filtragem passa-banda na remoção de ruídos e artefatos, melhorando a qualidade dos dados de EEG para análises subsequentes.

Além disso, a filtragem passa-banda pode ser combinada com outras técnicas de pré-processamento para otimizar ainda mais a qualidade dos dados. Por exemplo, a combinação de filtragem passa-banda com ICA pode resultar em uma remoção mais eficiente de artefatos e ruídos. [PENG et al. \(2021\)](#) utilizaram ICA, decomposição de componentes (DC), extração de sinais de diferentes ritmos e janelamento de dados, associando essas técnicas à filtragem passa-banda para refinar a análise dos sinais de EEG. [SANABRIA-BARRADAS; SANEI; GRANADOS-RAMOS \(2022\)](#) discutiram a combinação de filtragem passa-banda com Análise de Espectro

Singular (SSA) e decomposição através de *CANDECOMP/PARAFAC* (CP), destacando como essas metodologias avançadas podem melhorar ainda mais a limpeza e a análise dos dados de EEG.

3.2.2.3 Outras técnicas de pré-processamento abordadas

No contexto da análise de sinais de EEG, além das técnicas citadas, diversos estudos têm explorado outras abordagens para o pré-processamento dos dados, conforme demonstrado na Tabela 1.

[ABDULHAY et al. \(2023\)](#) utilizaram a Análise de Componentes Principais (PCA) para reduzir a dimensionalidade dos dados do eletroencefalograma relacionados ao transtorno do espectro do autismo. A PCA é uma técnica estatística que permite identificar os principais padrões de variabilidade nos dados, o que resulta na redução do número de variáveis originais, ao mesmo tempo em que preserva a maior parte da informação contida nos dados. Essa abordagem simplificada torna a análise dos dados mais eficiente, facilitando a identificação de padrões e características relevantes associadas ao TEA.

Em seu estudo, a Variação Modal *Decomposition* (VMD) associada ao *Predictor Importance Estimate* (PIE) foi empregada por [RECHAL; KUMAR; KHALEELULLA \(2021\)](#). O VMD foi utilizado como técnica de extração de características para decompor os sinais de EEG em modos variacionais, permitindo uma representação adaptativa dos sinais em diferentes modos. Isso facilitou a identificação de padrões distintos nos sinais de EEG. Posteriormente, o algoritmo PIE foi aplicado para selecionar as melhores características dos sinais de EEG extraídos pelo VMD. Essa técnica auxilia na identificação das características mais relevantes para distinguir entre sinais típicos e autistas. As características selecionadas foram então utilizadas como entrada para os algoritmos de aprendizado supervisionado, contribuindo para uma análise mais precisa e eficaz dos sinais de EEG no contexto do transtorno do espectro autista.

No estudo realizado por [OH et al. \(2021\)](#), foi aplicada a Análise Marginal *Fisher* (MFA) para a redução de dados, uma variante da Análise Discriminante Linear (LDA). Essa técnica foi empregada com o propósito de condensar o grande número de características extraídas em componentes principais, o que possibilita que o modelo capture informações essenciais para previsões precisas. A utilização da MFA permite uma representação mais eficiente e compacta dos dados, contribuindo para uma análise mais eficaz e uma melhor compreensão das relações entre as características extraídas e as classes de interesse.

[TAWHID et al. \(2021\)](#) utilizaram técnicas de pré-processamento, como *Common Average Referencing* (CAR), *Infinite Impulse Response* (IIR) filter e normalização, para preparar adequadamente os sinais de EEG para a extração de características e geração de imagens de espectrograma. Essas etapas foram cruciais para a análise e classificação dos dados de EEG em relação ao transtorno do espectro autista. A aplicação dessas técnicas permitiu aos pesquisadores remover artefatos e ruídos dos sinais de EEG, padronizar os dados e prepará-los para a extração

de características relevantes. Isso contribuiu significativamente para a precisão do sistema de detecção de TEA baseado em imagens de espectrograma de EEG. Essas abordagens de pré-processamento foram fundamentais para garantir a qualidade e a confiabilidade dos resultados obtidos na classificação dos sinais de EEG associados ao TEA.

Além das técnicas mencionadas, algumas outras abordagens têm sido exploradas na literatura para o pré-processamento de sinais de EEG. Entre essas técnicas, destaca-se a detecção de anomalias através do *PyCaret*, que oferece uma variedade de ferramentas para identificar padrões incomuns nos dados, auxiliando na detecção de eventos anômalos nos sinais de EEG. O aumento de dados com *Synthetic Minority Oversampling Technique (SMOTE)* também tem sido adotado por pesquisadores para equilibrar conjuntos de dados desproporcionalmente representados, o que pode melhorar a capacidade dos modelos de aprendizado de máquina em reconhecer padrões em sinais de EEG.

Em suma, as técnicas de pré-processamento desempenham um papel crucial na preparação dos dados de EEG para análise. Essas técnicas não apenas ajudam a remover artefatos e ruídos dos sinais de EEG, mas também facilitam a extração de características relevantes e a identificação de padrões significativos nas atividades cerebrais. Portanto, investir em um pré-processamento robusto é fundamental para garantir a qualidade e a confiabilidade das análises subsequentes, contribuindo assim para avanços significativos na compreensão e no diagnóstico de distúrbios neurológicos, como o transtorno do espectro do autismo.

A Figura 10 mostra a distribuição os métodos de pré - processamento utilizados pelos autores.

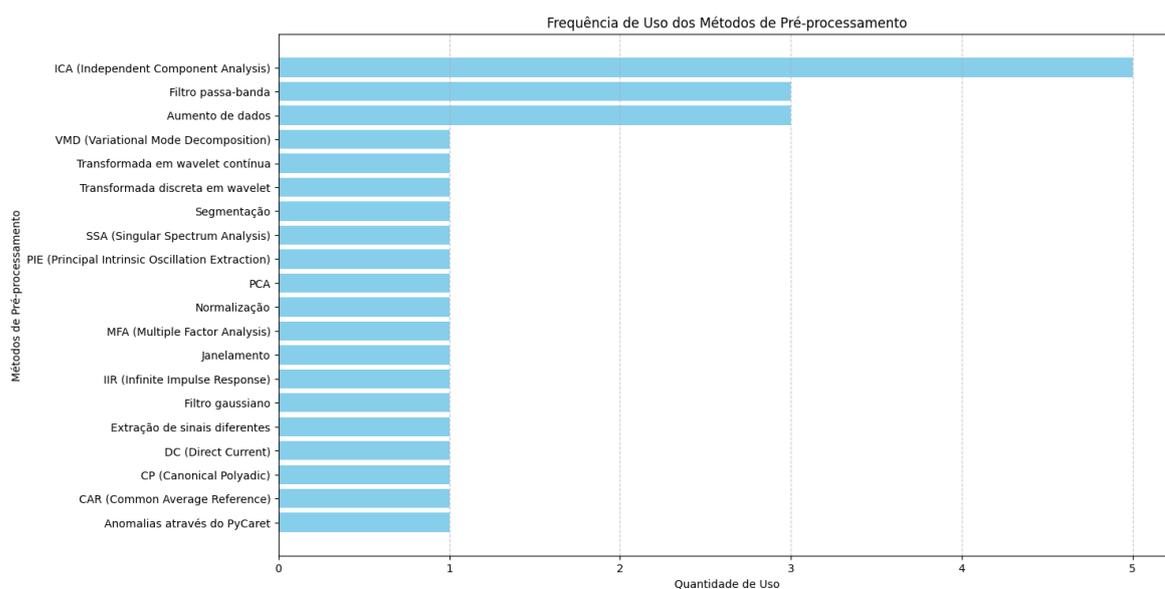


Figura 10 – Distribuição dos métodos de pré-processamento utilizados nos estudos de diagnóstico de TEA através de sinais de EEG

3.2.3 Métodos de classificação

Nesta seção, será explorado diferentes métodos de classificação que têm sido empregados na identificação de TEA com base em dados de EEG. Diversas técnicas serão abordadas, incluindo aprendizado de máquina e redes neurais.

A classificação precisa e eficaz entre indivíduos com Transtorno do Espectro Autista e com desenvolvimento típico é fundamental para diagnósticos precoces e intervenções adequadas. O uso de sinais de EEG como uma fonte de dados para essa classificação tem sido amplamente explorado devido à sua capacidade de refletir diretamente a atividade cerebral. A alta dimensionalidade e complexidade dos dados de EEG tornam os classificadores baseados em aprendizado de máquina e redes neurais artificiais particularmente úteis. Esses métodos são capazes de identificar padrões complexos nos dados, algo que métodos tradicionais muitas vezes não conseguem realizar de forma eficaz. A capacidade desses algoritmos de aprender com os dados e identificar relações não lineares e multifacetadas permite a construção de modelos que podem discriminar com precisão entre diferentes estados neurofisiológicos. Isso melhora substancialmente a capacidade de diagnóstico precoce e preciso do TEA.

Um dos métodos mais utilizados é o *Linear Discriminant Analysis* (LDA). O LDA é um classificador linear que busca encontrar a combinação linear de características que melhor separam as classes no espaço de características. Ele maximiza a separação entre múltiplas classes, calculando a linha (ou hiperplano, em dimensões superiores) que melhor discrimina entre elas, com base em suas variâncias e covariâncias. Essa técnica é particularmente útil em problemas de classificação com classes bem definidas e ajuda a melhorar a precisão ao lidar com dados de alta dimensionalidade (TASNIM *et al.*, 2022).

TAWHID *et al.* (2021), TASNIM *et al.* (2022), MELINDA *et al.* (2023) e KONG; LI; OUYANG (2023) utilizam o LDA em suas pesquisas. Em alguns casos, o algoritmo demonstrou um desempenho excelente. Por exemplo, MELINDA *et al.* (2023) alcançaram uma acurácia de 99% em sua aplicação do LDA.

Outro método amplamente utilizado é o *Support Vector Machine* (SVM). O SVM é um método de aprendizado supervisionado que busca encontrar o hiperplano que melhor separa as classes no espaço de características. Este método é especialmente eficaz em problemas de classificação binária, permitindo a separação clara das classes através do ajuste do hiperplano. Além disso, o SVM oferece flexibilidade ao permitir a modificação dos pesos dos kernels e polinômios, o que pode melhorar o desempenho do modelo ao lidar com diferentes tipos de dados (RECHAL; KUMAR; KHALEELULLA, 2021).

O SVM foi bastante utilizado nos artigos selecionados. Estudos como os de OH *et al.* (2021) e PENG *et al.* (2021) utilizaram o SVM como o único classificador. Contudo, a maioria dos estudos incorporou uma variedade de algoritmos para realizar a classificação. Por exemplo, TASNIM *et al.* (2022) combinaram vários algoritmos de aprendizado de máquina e

redes neurais artificiais, incluindo SVM, LDA, *Random Forest* e *Multilayer Perceptron* (MLP). Eles desenvolveram um modelo *ensemble* utilizando a abordagem de soft-voting para melhorar a precisão da classificação.

Além desses métodos, o *Logistic Regression* (LR) também tem sido utilizado na literatura para resolver problemas de classificação binária. O LR é uma técnica estatística que modela a relação entre uma variável dependente binária e uma ou mais variáveis independentes, estimando as probabilidades usando a função logística. Ele é especialmente eficiente em situações onde é necessário determinar a separação entre duas classes distintas com base em características preditivas. O LR calcula coeficientes para cada variável independente, permitindo prever a probabilidade de um evento pertencer a uma classe específica com base nos valores das variáveis independentes (LARGET, 2008).

KONG; LI; OUYANG (2023) exploraram três metodologias distintas em seu estudo. Embora o LR tenha sido testado em todas elas, não se destacou como o melhor classificador em nenhuma. Nas duas primeiras metodologias, alcançou uma acurácia de 75%. No entanto, na terceira metodologia, o LR apresentou um desempenho superior, atingindo 86% de acurácia.

As Redes Neurais Artificiais (RNAs) também têm sido amplamente exploradas nos estudos, com várias delas passando por modificações para melhorar o desempenho na classificação entre os dois grupos. Um exemplo notável é o estudo de MENAKA *et al.* (2024), no qual foram adicionadas duas camadas convolutivas e alterada a ordem das camadas, além de ajustes no otimizador e taxa de aprendizado para aprimorar a convergência do modelo.

Outra abordagem foi desenvolvida por ALI *et al.* (2022), que propuseram a arquitetura *ConvNet BiLSTM* integrando redes neurais convolucionais (CNN) com redes neurais recorrentes bidirecionais de longa memória (BiLSTM) para a classificação do TEA. As CNNs são eficazes na extração de características hierárquicas através de camadas de convolução e *pooling*, adequadas para dados estruturados em grade como imagens, enquanto as BiLSTMs capturam dependências temporais em ambas as direções com unidades LSTM. O estudo ajustou a arquitetura para melhorar a precisão e eficiência do modelo de classificação.

O *EEGMAE* é um tipo de *autoencoder*, uma arquitetura de rede neural usada para aprendizado não supervisionado de representações de dados. Ele foi especificamente desenvolvido para dados de EEG, onde funciona mascarando aleatoriamente a entrada e treinando o modelo para reconstruir os dados originais a partir das partes mascaradas. O modelo foi proposto por CHEN; GAOXIANG; LI (2023).

Além dos métodos discutidos, como o *Linear Discriminant Analysis*, *Support Vector Machine* e *Logistic Regression*, *BiLSTM*, diversos outros classificadores foram explorados na literatura para o diagnóstico do Transtorno do Espectro Autista utilizando sinais de EEG. Exemplos adicionais incluem o *Random Forest*, *k-Nearest Neighbors* (k-NN), *Naive Bayes* (NB), entre outros. Cada um desses classificadores apresentou suas próprias vantagens e aplicações

específicas, contribuindo para a diversidade de abordagens na busca por métodos mais eficazes de classificação e diagnóstico precoce do TEA com base em dados de EEG.

A Figura 11 discrimina todos os classificadores utilizados pelos estudos explorados nesta revisão.

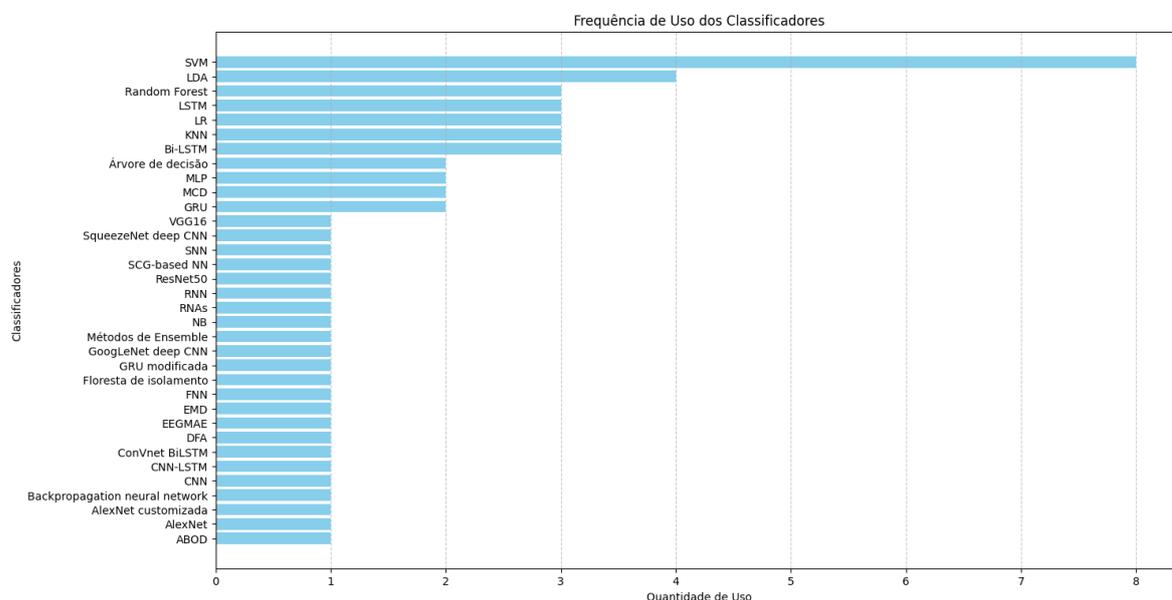


Figura 11 – Distribuição dos classificadores utilizados nos estudos de diagnóstico de TEA através de sinais de EEG

3.3 Discussão

Cada estudo traz consigo suas próprias limitações, características únicas e resultados variados, todos contribuindo de maneira significativa para o desenvolvimento desta pesquisa. A análise detalhada dos trabalhos mencionados ao longo da revisão da literatura, conforme apresentado na Tabela 1, revela um panorama abrangente sobre o uso de inteligência artificial e sinais de eletroencefalograma no diagnóstico do Transtorno do Espectro Autista.

A maioria dos estudos revisados enfatiza a necessidade de identificar padrões cerebrais específicos associados ao TEA, visando melhorar a precisão e a rapidez do diagnóstico. No entanto, uma lacuna significativa na pesquisa atual é destacada pela falta de evidências baseadas em pesquisas clínicas robustas, incluindo testes em populações maiores após o desenvolvimento inicial dos modelos propostos.

De forma geral, todos os classificadores examinados demonstraram resultados promissores na diferenciação entre indivíduos com TEA e aqueles com desenvolvimento típico, sublinhando a importância crucial de compreender os padrões neurais característicos dos indivíduos com TEA. A revisão também enfatiza a relevância crescente das técnicas de inteligência artificial no avanço do diagnóstico precoce e preciso do TEA, enfatizando a necessidade contínua de pesquisa para aprimorar esses métodos e ampliar sua aplicabilidade clínica.

Os estudos revisados não estão isentos de limitações. Problemas como a falta de detalhes sobre o grau de autismo dos participantes nas bases de dados e a variabilidade nos métodos de coleta de dados e na configuração de eletrodos são identificados como desafios significativos. Estas limitações destacam a urgência de padronização nos protocolos de coleta de dados e a inclusão de informações mais precisas sobre os participantes, a fim de melhorar a precisão e a generalização dos modelos desenvolvidos.

Outra observação relevante é a diversidade nas métricas de avaliação utilizadas nos estudos. Embora a acurácia seja frequentemente reportada, outras métricas como precisão, sensibilidade, especificidade, *F1-score* e a área sob a curva ROC (AUC-ROC) são igualmente importantes para uma avaliação abrangente do desempenho dos classificadores. A falta de uma padronização nessas métricas entre os estudos ressalta a necessidade de estabelecer um conjunto comum de métricas de avaliação para facilitar comparações diretas e melhorar a consistência e a qualidade da pesquisa na área.

Os achados desta revisão sublinham a complexidade e a importância da análise de sinais de EEG e da aplicação de inteligência artificial no diagnóstico do TEA. Apesar dos avanços significativos alcançados, há desafios consideráveis a serem superados. A padronização nos protocolos de coleta de dados, juntamente com o uso de métricas de avaliação comuns, são passos fundamentais para avançar na precisão e na aplicabilidade clínica desses métodos, contribuindo assim para melhores resultados clínicos e qualidade de vida para os indivíduos afetados pelo TEA.

3.3.1 Importância dos Padrões de Sinais Eletroencefalográficos

A análise dos padrões de EEG tem se mostrado fundamental no diagnóstico do Transtorno do Espectro Autista, permitindo identificar quais áreas no cérebro são essenciais para avaliação em pessoas com essa condição. Investigar quais tipos de ondas cerebrais são mais prevalentes nessas populações é crucial para identificar padrões distintivos que não apenas melhoram o diagnóstico, mas também ampliam a compreensão da complexidade do TEA.

Características não lineares têm ganhado destaque nos estudos por revelarem diferenças quantitativas nas propriedades dos sinais cerebrais entre grupos, bem como aspectos qualitativos sobre a organização neural e o processamento de informações nos indivíduos afetados pelo TEA. A análise detalhada dessas características permite uma visão mais aprofundada das diferenças neurofisiológicas que marcam esse transtorno.

Métodos avançados de análise, como medidas de complexidade temporal e espacial dos sinais de EEG, têm se mostrado sensíveis para capturar nuances nas alterações neurofisiológicas associadas ao TEA. Estudos detalhados desses padrões revelam não só diferenças específicas na atividade cerebral entre indivíduos com e sem TEA, mas também abrem caminho para o desenvolvimento de intervenções terapêuticas mais precisas e adaptadas às necessidades

individuais. A identificação de padrões específicos de ondas cerebrais pode auxiliar na criação de biomarcadores mais eficazes para o diagnóstico precoce e a monitorização do progresso terapêutico.

A compreensão aprofundada desses padrões pode não apenas melhorar a precisão diagnóstica, mas também orientar estratégias terapêuticas mais eficazes e personalizadas para o manejo do TEA. Esses avanços são essenciais para a criação de abordagens de tratamento mais direcionadas, considerando a heterogeneidade do espectro autista e as diferentes manifestações clínicas observadas. Intervenções terapêuticas baseadas em padrões específicos de EEG podem ser desenvolvidas para atender melhor às necessidades individuais, potencializando os resultados clínicos.

Sendo assim, o aprofundamento nas técnicas de análise de EEG e a exploração das características não lineares dos sinais cerebrais são passos cruciais para o avanço na compreensão e no tratamento do TEA. A integração de métodos avançados de análise com intervenções terapêuticas personalizadas tem o potencial de transformar significativamente a abordagem ao TEA, oferecendo uma melhor qualidade de vida para os indivíduos afetados. Esses esforços contínuos em pesquisa e desenvolvimento são essenciais para enfrentar os desafios apresentados pela complexidade do espectro autista e para promover um tratamento mais eficaz e adaptado às necessidades de cada paciente.

3.3.2 Relevância dos Métodos de Pré-processamento

As técnicas de pré-processamento são essenciais para lidar com os desafios inerentes aos registros de EEG, como artefatos de movimento, ruídos elétricos, piscadas de olhos e variações individuais na atividade cerebral. Entre as técnicas frequentemente mencionadas na literatura, a Análise de Componentes Independentes, a filtragem passa-banda e a Transformada *Wavelet* se destacam por sua capacidade de melhorar a qualidade dos dados e identificar padrões significativos nas atividades cerebrais.

A aplicação dessas técnicas no pré-processamento molda diretamente a qualidade e a confiabilidade das conclusões tiradas dos estudos de EEG. Elas não apenas garantem a remoção de artefatos que poderiam distorcer os resultados, mas também contribuem para a precisão dos modelos analíticos utilizados para entender as complexidades das atividades cerebrais no contexto do Transtorno do TEA. A ICA, por exemplo, é eficaz na separação de sinais sobrepostos, isolando componentes específicos que correspondem a diferentes fontes de atividade cerebral e artefatos. Este método permite uma discriminação clara entre os sinais de interesse e os ruídos, facilitando a análise posterior.

A filtragem passa-banda, por sua vez, é fundamental para eliminar frequências indesejadas que podem mascarar as atividades cerebrais relevantes. Este tipo de filtragem seleciona apenas as frequências dentro de um intervalo específico, melhorando a qualidade do sinal e

permitindo uma análise mais precisa das atividades neurais.

Além disso, a Transformada *Wavelet* oferece uma análise multirresolução, capaz de capturar características temporais e frequenciais dos sinais de EEG de forma simultânea. Essa técnica é particularmente útil para identificar padrões dinâmicos e transitórios no EEG, que podem ser indicativos de atividades cerebrais específicas associadas ao TEA.

A combinação dessas técnicas de pré-processamento pode ser uma solução eficaz para maximizar a remoção de ruídos e artefatos, aumentando a clareza e a utilidade dos dados de EEG. Por exemplo, a integração da ICA com a filtragem passa-banda e a Transformada *Wavelet* pode oferecer uma abordagem mais robusta para separar sinais de interesse de ruídos e artefatos. Essa abordagem combinada pode facilitar a identificação de padrões sutis e significativos nas atividades cerebrais, proporcionando uma compreensão mais detalhada das bases neurais do TEA.

Investir em estratégias robustas de pré-processamento é fundamental para avançar no campo da neurociência e para desenvolver métodos diagnósticos mais precisos e sensíveis para transtornos neurológicos como o TEA. O contínuo desenvolvimento e aperfeiçoamento dessas técnicas são cruciais para aprimorar a compreensão das bases neurais do TEA e para desenvolver intervenções mais eficazes e personalizadas para indivíduos afetados. Essas técnicas não apenas melhoram a qualidade dos dados de EEG, mas também aumentam a eficácia dos algoritmos de inteligência artificial aplicados, potencializando a detecção de padrões sutis e significativos nas atividades cerebrais associadas ao TEA.

Portanto, o avanço na área de pré-processamento de EEG representa um passo vital para a neurociência e a medicina, oferecendo novas oportunidades para a compreensão e o tratamento do TEA. A integração e o desenvolvimento contínuo dessas técnicas de pré-processamento são essenciais para alcançar uma análise mais precisa e confiável dos sinais cerebrais, promovendo o desenvolvimento de intervenções mais eficazes e personalizadas.

3.3.3 Classificadores Mais Utilizados na Análise de EEG para Diagnóstico de TEA

Esta revisão identificou classificadores consistentes no diagnóstico precoce do Transtorno do Espectro Autista, sugerindo que a análise de sinais EEG utilizando técnicas de inteligência artificial pode desempenhar um papel crucial no diagnóstico precoce do transtorno. A combinação de métodos avançados de pré-processamento com classificadores robustos melhora significativamente a precisão da análise, facilitando a detecção de padrões neurofisiológicos específicos associados ao TEA.

Os estudos revisados demonstraram que a importância dos classificadores corretos na análise de EEG associada ao TEA reside na capacidade de identificar padrões distintivos que diferenciam indivíduos com TEA de indivíduos com desenvolvimento típico. Embora técnicas

avançadas como redes neurais profundas tenham ganhado destaque por sua capacidade de aprender representações complexas dos dados, em muitos casos, classificadores mais simples demonstram ser igualmente eficazes e economicamente viáveis.

Classificadores como a Máquina de Vetores de Suporte e a Análise Discriminante Linear têm sido amplamente utilizados na literatura devido à sua simplicidade, interpretabilidade e desempenho robusto na tarefa de classificação de dados de EEG. Esses métodos são capazes de aprender decisões de fronteira linear ou não linear entre classes de maneira eficiente, especialmente quando os dados são bem estruturados e as características relevantes são claramente definidas.

Embora redes neurais e outros métodos de aprendizado profundo possam oferecer vantagens em termos de flexibilidade e capacidade de lidar com grandes conjuntos de dados complexos, eles também exigem recursos computacionais significativos e podem ser menos transparentes em relação ao processo de decisão. Em contraste, classificadores mais simples como o SVM podem ser implementados de maneira eficiente, exigindo menos poder computacional e oferecendo uma interpretabilidade direta das decisões de classificação. Isso os torna particularmente úteis em contextos clínicos onde a simplicidade, a interpretabilidade e os custos são considerações importantes.

Uma característica notável do SVM é a capacidade de ajustar a complexidade do modelo através da escolha do tipo de *kernel* e do parâmetro de regularização *C*. Por exemplo, modificando o grau do polinômio no SVM, é possível ajustar a flexibilidade do modelo, tornando-o mais robusto para capturar relações não lineares nos dados de EEG associados ao TEA. Essa flexibilidade permite adaptar o SVM às características específicas dos dados, melhorando ainda mais sua capacidade de discriminação entre indivíduos com TEA e desenvolvimento típico.

Desta forma, a aplicação de classificadores robustos como o SVM e o LDA, combinados com técnicas avançadas de pré-processamento de EEG, representa um avanço significativo no diagnóstico precoce e preciso do TEA. Esses métodos não apenas aumentam a precisão da classificação, mas também oferecem soluções economicamente viáveis e interpretáveis, essenciais para a implementação em ambientes clínicos. Continuar a explorar e desenvolver esses classificadores, bem como investigar novas abordagens de IA, é fundamental para melhorar ainda mais a acurácia diagnóstica e a compreensão dos mecanismos neurofisiológicos subjacentes ao TEA.

3.3.4 Limitações do Estudo

Embora os resultados deste estudo sejam promissores, é crucial reconhecer várias limitações que podem impactar a interpretação e a aplicabilidade dos achados. Primeiramente, o tamanho da amostra e a diversidade dos participantes foram restritos, o que pode limitar a generalização dos resultados para uma população mais ampla. A falta de informações detalhadas

sobre o grau de autismo dos indivíduos nas bases de dados também representa uma limitação significativa, pois a heterogeneidade clínica dentro do espectro autista pode influenciar as características dos sinais de EEG analisados.

Além disso, houve considerável variabilidade nos métodos de coleta de dados entre os estudos revisados, incluindo diferenças no número de eletrodos utilizados, configurações de montagem e procedimentos de pré-processamento. Essas discrepâncias dificultam a comparação direta entre os resultados e podem introduzir vieses que afetam a robustez das conclusões.

Outra limitação identificada é a heterogeneidade nas métricas de avaliação utilizadas nos estudos revisados. A variedade de medidas de desempenho dos classificadores dificulta a comparação dos resultados entre diferentes estudos e limita a capacidade de determinar consistentemente qual método é mais eficaz para o diagnóstico precoce do TEA a partir de sinais de EEG.

Além disso, a ausência de grupos de controle em alguns estudos compromete a validade dos resultados. A comparação entre indivíduos com TEA e indivíduos com desenvolvimento típico é fundamental para validar a eficácia dos classificadores na diferenciação entre esses grupos. A falta de grupos de controle pode subestimar ou superestimar a capacidade discriminativa dos modelos, tornando os resultados menos confiáveis para aplicação clínica.

Desta maneira, enquanto os avanços na aplicação de inteligência artificial e métodos de pré-processamento de EEG para diagnóstico de TEA são promissores, é essencial abordar e mitigar essas limitações. Futuras pesquisas devem priorizar o aumento do tamanho da amostra e a inclusão de uma maior diversidade de participantes, bem como padronizar métodos de coleta de dados e métricas de avaliação. A incorporação de grupos de controle adequados também é crucial para fortalecer a validade externa e a utilidade clínica dos estudos nesta área. Ao superar esses desafios, podemos avançar significativamente no desenvolvimento de ferramentas diagnósticas mais precisas e confiáveis para o TEA, melhorando assim os resultados clínicos e a qualidade de vida dos indivíduos afetados.

3.4 Conclusão

A revisão sistemática realizada destaca o potencial promissor das técnicas de inteligência artificial na análise de EEG para o diagnóstico do Transtorno do Espectro Autista. Além do SVM, diversos outros classificadores como LDA e modelos híbridos foram identificados como eficazes, embora com resultados variáveis de acordo com as especificidades dos estudos e dos dados analisados.

A padronização nos métodos de coleta de dados e nas métricas de avaliação emerge como um ponto crucial para avançar na precisão diagnóstica e na generalização dos resultados obtidos. As limitações encontradas, como a heterogeneidade nos métodos de coleta de dados e

nas métricas de avaliação, sublinham a necessidade contínua de pesquisa para o desenvolvimento de métodos diagnósticos mais precisos e personalizados para indivíduos com TEA.

Olhando para o futuro, as direções emergentes incluem a expansão para estudos longitudinais, que podem proporcionar percepções valiosas sobre a evolução dos padrões cerebrais ao longo do tempo. A integração de dados multimodais também representa uma oportunidade significativa, permitindo uma análise mais abrangente e holística dos marcadores biológicos do TEA. Além disso, o desenvolvimento de ferramentas colaborativas e plataformas de compartilhamento de dados pode acelerar significativamente o progresso na área, facilitando a replicação de estudos e a validação de resultados em diferentes contextos clínicos e populacionais.

Em suma, enquanto avançamos no uso de inteligência artificial e análise de EEG para diagnóstico do TEA, é essencial abordar as limitações existentes e explorar novas oportunidades de pesquisa. Com um compromisso contínuo com a inovação metodológica e a colaboração interdisciplinar, podemos melhorar substancialmente a capacidade de diagnosticar, entender e intervir eficazmente no Transtorno do Espectro Autista, melhorando assim a qualidade de vida dos indivíduos afetados e suas famílias.

Capítulo 4

Metodologia

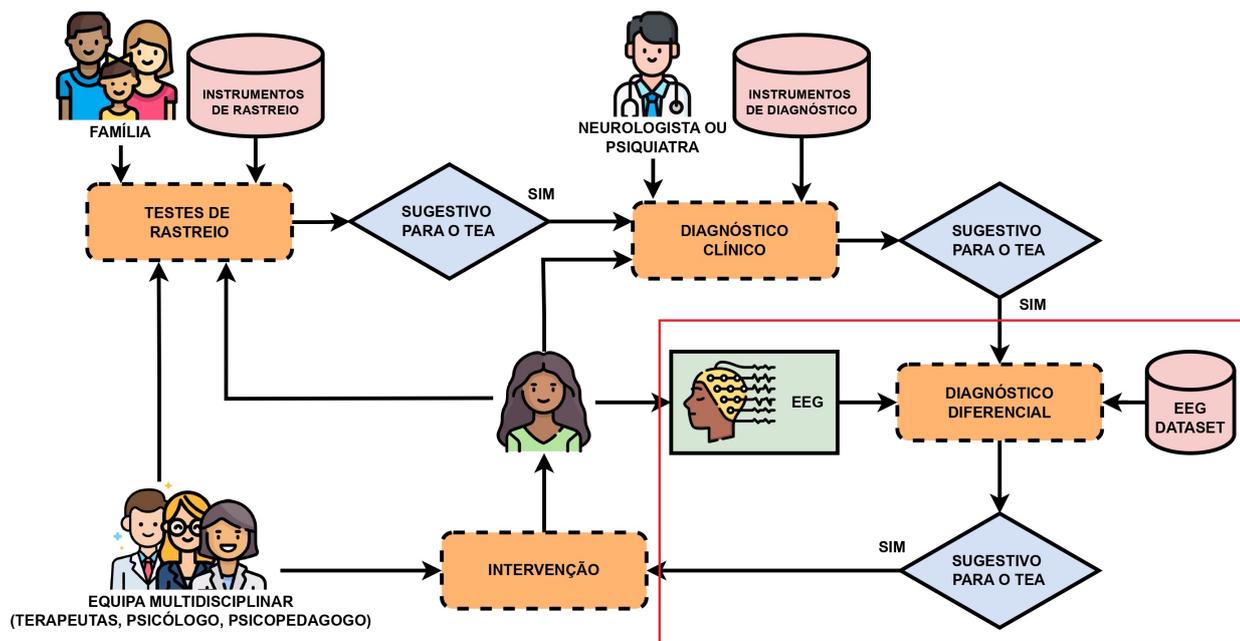
Este capítulo tem como propósito elucidar a estrutura metodológica do estudo, fornecendo detalhes sobre a escolha e características da base de dados, assim como os algoritmos utilizados. Além disso, serão discutidas as métricas a serem utilizadas na avaliação do desempenho dos modelos.

4.1 Proposta

É importante salientar que esta pesquisa integra um projeto mais amplo denominado MONAN, cujo objetivo é desenvolver um dispositivo que apoie o diagnóstico do Transtorno do Espectro Autista utilizando sinais eletroencefalográficos como fonte de dados. Este dispositivo, composto por *hardware* e *software*, visa auxiliar a equipe médica no diagnóstico de TEA, fornecendo uma ferramenta avançada para a análise e interpretação dos sinais cerebrais. A Figura 12 ilustra o esquema proposto para o projeto maior.

Como ilustrado na Figura 12, a pesquisa principal visa utilizar uma base de dados própria, representativa da população brasileira, para alcançar um diagnóstico precoce do Transtorno do Espectro Autista. O processo inicia-se com a participação ativa da família, que observa e relata sinais precoces de TEA. A partir dessas observações, são utilizados instrumentos de rastreio, como questionários e avaliações iniciais, para identificar possíveis indicadores do transtorno. Os testes de rastreio são realizados e, se os resultados indicarem a possibilidade de TEA, o próximo passo é o encaminhamento para um especialista. Um neurologista ou psiquiatra então conduz um diagnóstico clínico detalhado utilizando instrumentos de avaliação mais precisos. Se o diagnóstico clínico também sugerir a presença de TEA, avança-se para a etapa de diagnóstico diferencial, que visa excluir outras condições com sintomas semelhantes. Nessa fase, um exame de eletroencefalograma é realizado para coletar dados cerebrais, que serão analisados utilizando técnicas de aprendizado de máquina. A proposta é integrar um dispositivo de *hardware* e *software* que permita a análise automatizada dos sinais de EEG, facilitando a obtenção de um diagnóstico mais preciso e precoce.

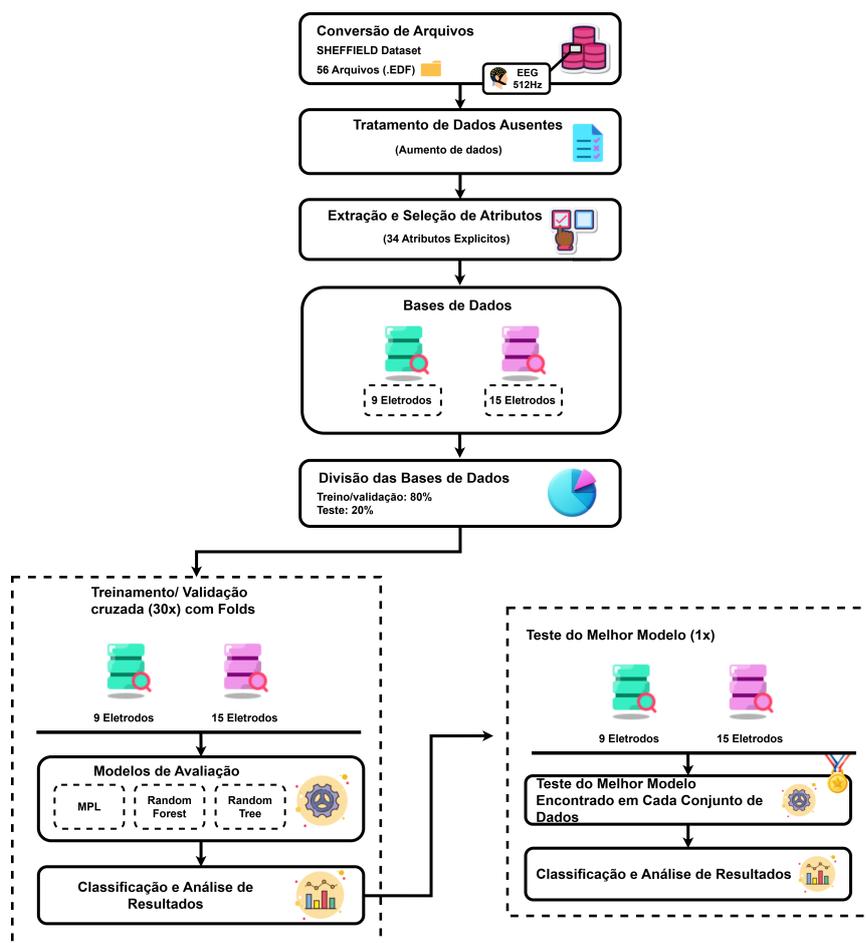
Figura 12 – O diagrama descreve a abordagem integrada proposta para o diagnóstico do Transtorno do TEA. O processo inicia-se com uma triagem inicial, que é seguida pela avaliação clínica realizada por um neurologista ou psiquiatra, utilizando instrumentos de diagnóstico estabelecidos. Caso o TEA seja sugerido nessa avaliação, são coletados dados de EEG, que são então analisados com técnicas de aprendizado de máquina para auxiliar no diagnóstico precoce.



Fonte: A autora (2024).

No entanto, para o desenvolvimento desta pesquisa, foi utilizada uma base de dados pública. Neste contexto, a Figura 13 ilustra o modelo proposto, que envolve a conversão dos dados e a extração de atributos, entre outras etapas. Cada um desses processos será descrito com detalhes nas seções subsequentes.

Figura 13 – Diagrama do método proposto.

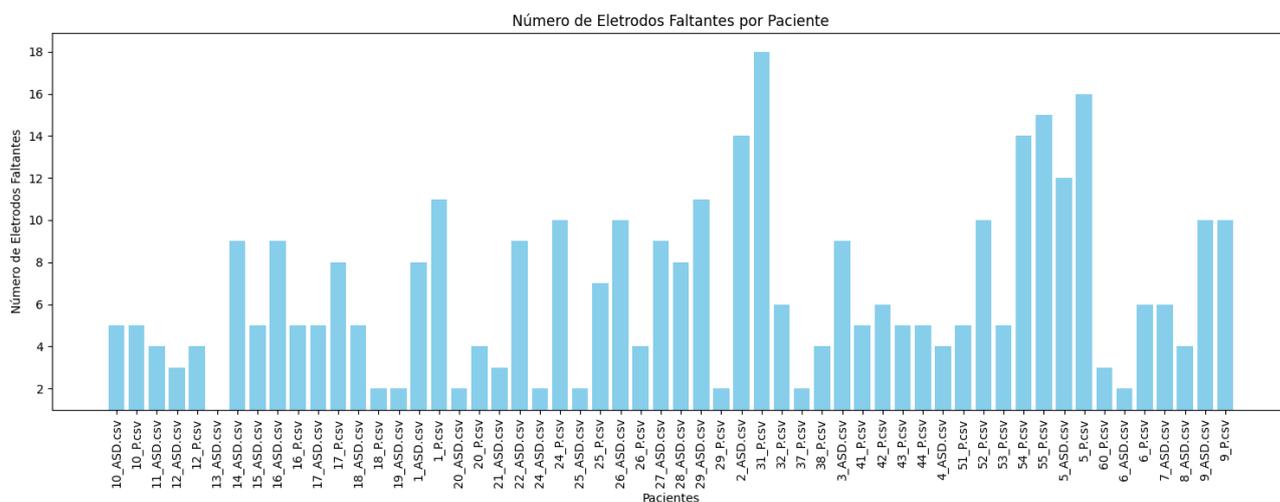


Fonte: A autora (2024).

4.2 Base de dados

Inicialmente, foi realizada uma busca em diversas bases de dados públicas, resultando na escolha da base de dados de Sheffield ([DICKINSON; JESTE; MILNE, 2022](#)), que contém três conjuntos de dados. O *Dataset 1* foi o foco principal desta pesquisa, pois os demais conjuntos de dados não estavam disponíveis publicamente. Este conjunto de dados inclui registros de eletroencefalograma de 56 indivíduos, 28 com TEA e 28 um grupo de controle, com idades variando entre 18 e 68 anos, coletados utilizando o sistema Biosemi Active Two EEG durante períodos de estímulo visual e repouso. Os dados foram submetidos a um processo de filtragem, empregando um filtro passa-banda na faixa de 0,01 a 140 Hz, com uma taxa de amostragem inicial de 2048 Hz. Posteriormente, a taxa de amostragem foi reduzida para 512 Hz, utilizando o canal Cz como referência. Para a análise, foram implementadas montagens com 64 ou 128 sensores, conforme descrito por [DICKINSON; JESTE; MILNE \(2022\)](#), assegurando a equalização prévia dos canais antes da realização das análises. Para garantir a consistência, as montagens com 64 eletrodos foram consideradas, uma vez que representavam a maioria dos dados disponíveis. O EEGLAB ([DELORME; MAKEIG, 2004](#)) foi utilizado pelos autores da base de dados para

Figura 14 – O gráfico ilustra a quantidade de eletrodos ausentes nos arquivos dos 56 indivíduos incluídos na base de dados.



Fonte: A autora (2024).

realizar o processo de filtragem, aplicando uma banda de transição e margens da banda passante de 1 Hz. Além disso, antes de disponibilizar os dados com a frequência de amostragem reduzida para 512 Hz, as partes dos dados que estavam corrompidas ou contaminadas por anomalias foram excluídas, garantindo a qualidade e a integridade dos sinais para análises posteriores.

Durante a análise da base de dados utilizada, foram identificados alguns problemas críticos. A ausência de dados em alguns eletrodos, conforme demonstrado na Figura 14, é um deles. Embora comum em bases de EEG devido a interferências técnicas e movimentos involuntários, esses eletrodos faltantes podem resultar em lacunas nos dados, prejudicando a análise dos resultados. Além disso, a falta de padronização nos sistemas de posicionamento dos eletrodos pode acarretar variações na localização exata dos eletrodos, influenciando a precisão das medições e a interpretação dos padrões de atividade cerebral. Por fim, o uso de sistemas de alta densidade de eletrodos, apesar de fornecer uma melhor resolução espacial, aumenta a complexidade dos dados, gerando um grande volume de informações que pode sobrecarregar os recursos computacionais e dificultar a análise dos padrões cerebrais.

4.3 Experimento proposto

Foi utilizada a base de dados de Sheffield (DICKINSON; JESTE; MILNE, 2022), à qual tivemos acesso apenas a um dos três conjuntos de dados originalmente disponíveis. Após a aquisição dos dados, observou-se que os arquivos estavam nos formatos .set e .fdt, frequentemente utilizados em softwares específicos de análise de EEG. No entanto, para garantir maior compatibilidade e facilitar a análise subsequente, esses dados foram convertidos para o formato .edf (*European Data Format*), amplamente utilizado na manipulação de sinais biomédicos devido à sua padronização e versatilidade.

Para garantir uma maior acessibilidade e facilitar o uso dos dados, foi identificada a necessidade de converter os dados para o formato .csv (*Comma-Separated Values*). Este formato é amplamente reconhecido e utilizado devido à sua simplicidade e compatibilidade com diversas ferramentas de análise de dados, como planilhas eletrônicas e softwares estatísticos. A conversão foi realizada por meio de um *script* em Python 3.11.1 (ROSSUM; DRAKE, 2009), utilizando bibliotecas especializadas na leitura e manipulação de arquivos biomédicos, como NumPy, Pandas, Glob, OS, Utils, Math e Distance. Esse processo garantiu que todas as informações relevantes dos sinais eletroencefalográficos fossem preservadas e organizadas de maneira estruturada, mantendo a integridade dos dados originais.

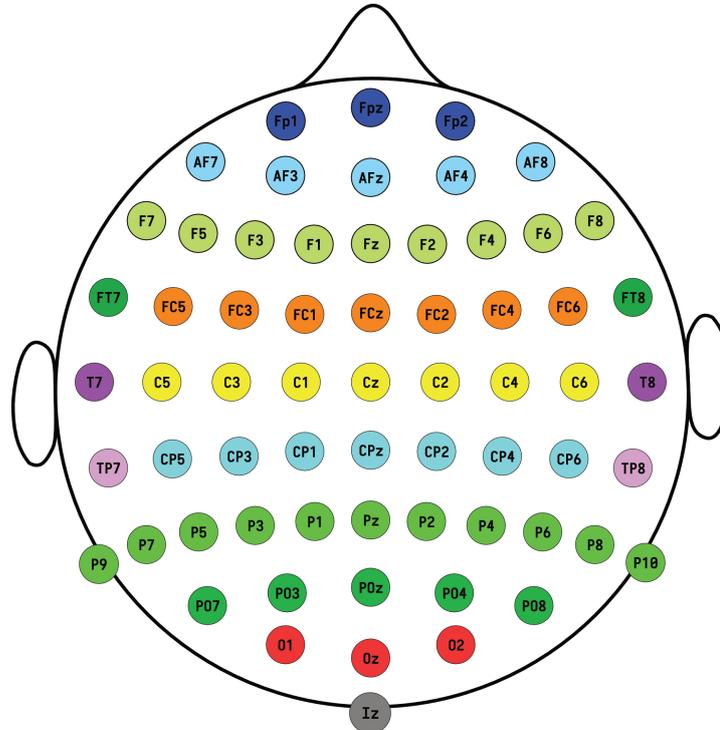
Ao realizar as conversões, foi observado que apenas um dos arquivos não apresentava dados faltantes, ou seja, era o único que continha informações completas em todos os eletrodos. Para lidar com os dados ausentes nos demais arquivos, utilizou-se o método de interpolação de caráter exploratório denominado Ponderação pelo Inverso da Distância (IDW) (JOSEPH; KANG, 2011). A fórmula da Ponderação pelo Inverso da Distância foi modificada, substituindo o inverso da distância pela exponencial negativa, visando reduzir o custo computacional e evitar problemas relacionados à divisão por zero. Inicialmente, acreditava-se que a execução de várias interpolações dessa forma reduziria a propagação de erros. Primeiro, foi feita uma correlação visual entre o sistema de 128 eletrodos e o de 64 eletrodos. Em seguida, os canais ausentes foram identificados e colunas vazias foram inseridas para representá-los. Essas colunas foram organizadas de modo que as colunas adjacentes corresponderiam a canais espacialmente mais próximos. A representação de todos os canais foi realizada utilizando a Figura 15, gerada pelo EEGLAB a partir do arquivo ASD 113, o único que continha sinais em todos os eletrodos.

Para determinar as coordenadas, foi empregado o software GIMP (versão 2.10.34) (OLIVER *et al.*, 2006). Isso permitiu o cálculo da distância entre cada ponto utilizando a Equação 4.1.

$$d_{ab} = \sqrt{(X_2 - X_1)^2 + (Y_2 - Y_1)^2} \quad (4.1)$$

Essa fórmula é baseada no teorema de Pitágoras (MAOR, 2019), que foi adaptado para calcular a distância entre dois pontos quaisquer. Nesta fórmula, a e b são os pontos em questão,

Figura 15 – A Figura demonstra as localizações dos eletrodos usados na coleta dos dados de EEG, seguindo o posicionamento padronizado conforme configurado no EEGLAB. As diferentes cores indicam as várias regiões cerebrais, facilitando a identificação das áreas específicas associadas às atividades neurais registradas. Esse posicionamento padronizado é essencial para garantir consistência nos registros e comparabilidade entre estudos.



Fonte: A autora (2024).

com x_1 e y_1 representando as coordenadas do ponto a e x_2 e y_2 as coordenadas do ponto b . A Equação 4.2 foi aplicada para preencher os canais que estavam faltando.

O canal ausente, designado como P_j , é o valor que será estimado através da interpolação. Os canais restantes, representados por P_i , são os canais conhecidos que não estão faltando. É importante garantir que o índice i seja distinto de j para evitar a inclusão do próprio canal ausente no cálculo. Após o processamento dos dados, foi gerada uma nova tabela com todos os canais preenchidos, a qual foi convertida para um arquivo CSV para facilitar o uso e a análise subsequentes.

A equação de interpolação usada para estimar o valor de P_j é dada por:

$$p_j = \frac{\sum_{i=1}^m (P_i x^e)^{-d_{ij}}}{\sum_{i=1}^m (e)^{-d_{ij}}} \quad (4.2)$$

Nesta equação, o valor de p_j é calculado como uma média ponderada dos valores dos canais conhecidos P_i . O peso atribuído a cada canal conhecido é baseado na distância d_{ij} entre o canal P_i e o canal ausente P_j . A distância é elevada a uma potência negativa, o que significa que

canais mais próximos ao canal ausente têm um impacto maior na estimativa. O denominador da equação normaliza esses pesos, garantindo que a soma dos pesos seja igual a 1, o que permite uma média ponderada adequada. Esse método de interpolação proporciona uma estimativa robusta para canais ausentes, utilizando as informações disponíveis e levando em consideração a proximidade dos canais conhecidos. A fórmula tem sido eficaz para preencher canais faltantes em diversos conjuntos de dados de sinais fisiológicos, conforme demonstrado em estudos anteriores (VANDEKAR *et al.*, 2015).

Utilizando o software GNU Octave, versão 8.2.0 (EATON *et al.*, 2023), o sinal de EEG foi processado com janelamento e atributos relevantes foram extraídos dos dados disponíveis. Para cada janela, foram obtidos 34 atributos, listados na Tabela 3, que se mostraram altamente relevantes e eficazes em pesquisas anteriores sobre EEG e sinais fisiológicos periféricos (SANTANA *et al.*, 2023a).

Na coluna esquerda da Tabela 3, foram extraídas informações estatísticas como média, variância, desvio padrão, raiz quadrada da média, variação da amplitude média, desvio absoluto da diferença, valor absoluto integrado, detector de logaritmo, integral quadrada simples, valor absoluto médio, kernel médio do logaritmo, assimetria, curtose, amplitude máxima e os 3°, 4° e 5° momentos. Por outro lado, a coluna direita da Tabela 3 inclui atributos relacionados ao domínio tempo-frequência dos sinais, tais como comprimento da forma de onda, cruzamento zero, mudanças de sinal de inclinação, parâmetros *Hjorth* (atividade, mobilidade e complexidade), frequência média, frequência mediana, potência média, frequência de pico, razão do espectro de potência, potência total, variância da frequência central, entropia de *Shannon* e os 1°, 2° e 3° momentos espectrais. As janelas utilizadas tinham duração de 2 segundos, com sobreposição de 0,5 segundos e uma frequência de amostragem de 512 Hz.

Posteriormente, foi realizada uma seleção manual de 9 e 15 eletrodos. Essa escolha considerou as dificuldades associadas à coleta de dados em crianças com autismo, que frequentemente enfrentam desafios relacionados à sensibilidade sensorial durante o procedimento. A motivação foi a de que a redução do número de eletrodos poderia facilitar a coleta, minimizando o desconforto e a dificuldade para os pacientes. Além disso, essa abordagem foi pensada em função da aplicabilidade no Sistema Único de Saúde (SUS), onde a disponibilidade de sistemas de EEG com um grande número de eletrodos pode ser limitada. A escolha de um número reduzido de eletrodos visa também aumentar a viabilidade da implementação em cenários reais, proporcionando uma solução prática e acessível para a realização de exames eletroencefalográficos em contextos clínicos com recursos limitados.

A seleção das configurações com 9 e 15 eletrodos foi fundamentada em evidências da neurociência, com base em estudos anteriores que identificaram uma menor ativação cerebral nas regiões frontal e frontotemporal em pacientes com Transtorno do Espectro Autista durante a execução de tarefas cognitivas sociais e não sociais, quando comparados a indivíduos saudáveis (HIRATA *et al.*, 2018). Essas descobertas sugerem que a focalização nas áreas específicas de

Tabela 3 – A Tabela apresenta os 34 atributos extraídos e suas respectivas fórmulas, ressaltando a diversidade de características estatísticas extraídas. Esses atributos incluem medidas estatísticas, características de frequência e tempo, além de outros parâmetros específicos importantes para uma avaliação detalhada dos sinais neurológicos. As fórmulas associadas a cada atributo fornecem uma fundamentação matemática para sua derivação, assegurando a consistência e a reprodutibilidade dos resultados obtidos.

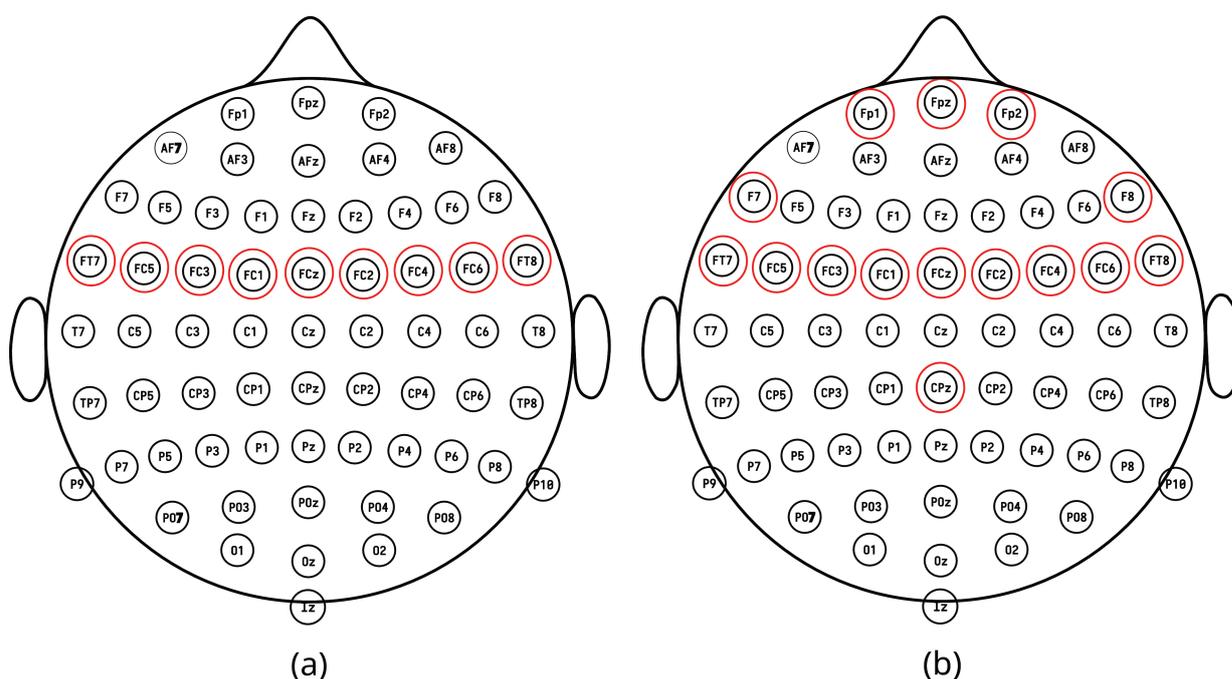
Atributo	Expressão matemática	Atributo	Expressão matemática
Média	$\mu = \frac{1}{N} \sum_{n=1}^N x_n$	Comprimento de onda	$WL = \sum_{n=1}^{N-1} x_{n+1} - x_n $
Slope Sign Changes	$SSC = \sum_{n=1}^{N-1} [f(x_n - x_{n-1}) \times (x_n - x_{n+1})]$ $f(x) = \begin{cases} 1, & \text{se } x \geq \text{threshold} \\ 0, & \text{caso contrário} \end{cases}$	Detector de passagem por zeros (Zero crossing)	$ZC = \sum_{n=1}^{N-1} [sgn(x_n \times x_{n+1}) \cap x_n - x_{n+1} \geq \text{threshold}]$ $sgn(x) = \begin{cases} 1, & \text{se } x \geq \text{threshold} \\ 0, & \text{caso contrário} \end{cases}$
Desvio padrão	$\sigma = \sqrt{\frac{1}{N-1} \sum_{n=1}^N x_n - \mu ^2}$	Variância	$\text{var} = \frac{1}{N-1} \sum_{n=1}^N (x_n - \mu)^2$
Erro médio quadrático	$RMS = \sqrt{\frac{\sum_{n=1}^N (x_n)^2}{N}}$	Parâmetro de atividade de Hjorth	$Hjorth_{\text{activity}} = \frac{1}{N-1} \sum_{n=1}^N (x_n - \mu)^2$
Mudança média de amplitude	$AAC = \frac{1}{N} \left(\sum_{n=1}^N \left \frac{dx(t)}{dt} \right \right)$	Parâmetro de mobilidade de Hjorth	$Hjorth_{\text{mobility}} = \sqrt{\frac{\text{var} \left(\frac{dx(t)}{dt} \right)}{\text{var}(x(t))}}$
Difference Absolute Deviation	$DASDV = \sqrt{\frac{1}{N} \sum_{n=1}^N \left(\frac{dx(t)}{dt} \right)^2}$	Parâmetro de complexidade de Hjorth	$Hjorth_{\text{complex}} = \frac{Hjorth_{\text{mobility}} \left(\frac{dx(t)}{dt} \right)}{Hjorth_{\text{mobility}}(x(t))}$
Integrated Absolute Value	$IAV = \sum_{n=1}^N x_n$	Frequência média	$MNF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j}$ <small>Onde f_j, P_j são as frequências e a potência do espectro, respectivamente, e M é o comprimento das frequências.</small>
Detector logarítmico	$LOGD = e^{\frac{1}{N} \sum_{n=1}^N \log(x_n)}$	Frequência mediana	$MDF = \frac{1}{2} \sum_{j=1}^M P_j$
Simple Square Integral	$SSI = \sum_{n=1}^N x_n^2$	Potência média	$MNP = \sum_{j=1}^M \frac{P_j}{M}$
Valor médio absoluto	$MAV = \frac{1}{N} \sum_{n=1}^N x_n $	Frequência de pico	$PKF = \max(P_j)$
Mean Logarithm Kernel	$MLOGK = \frac{1}{N} \left \sum_{n=1}^N x_n \right $	Densidade espectral de potência	$PSR = \frac{PKF}{\sum_{j=1}^M P_j}$
Assimetria (skewness)	$s = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \mu)^3}{\sigma^3}$	Potência total	$TP = \sum_{j=1}^M P_j$
Curtose	$\text{kurt} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \mu)^4}{\sigma^4}$	Primeiro momento espectral	$SM1 = \sum_{j=1}^M f_j P_j$
Amplitude máxima	$MAX = \max(x_n)$	Segundo momento espectral	$SM2 = \sum_{j=1}^M f_j^2 P_j$
Terceiro momento	$M3 = \left \frac{1}{N} \sum_{n=1}^N (x_n)^3 \right $	Terceiro momento espectral	$SM3 = \sum_{j=1}^M f_j^3 P_j$
Quarto momento	$M4 = \left \frac{1}{N} \sum_{n=1}^N (x_n)^4 \right $	Variância da frequência central	$VCF = \frac{SM2}{TP} - \left(\frac{SM1}{TP} \right)^2$
Quinto momento	$M5 = \left \frac{1}{N} \sum_{n=1}^N (x_n)^5 \right $	Entropia de Shannon	$E = - \sum_i s_i^2 \log(s_i^2), \text{ onde } s \text{ é o sinal.}$

Fonte: (SANTANA *et al.*, 2023b).

interesse pode otimizar a detecção de padrões relevantes, alinhando a escolha dos eletrodos com as áreas cerebrais mais afetadas pelo TEA.

A Figura 16 ilustra os eletrodos escolhidos manualmente para gerar as bases de 9 de 15 eletrodos, são eles: FP1, FPZ, FP2, F7, F8, FT7, FC5, FC3, FC1, FCZ, FC2, FC4, FC6, FT8 e CPZ.

Figura 16 – O mapa dos 64 eletrodos originais foi utilizado como base para a seleção de configurações específicas. A Figura (a) representa a disposição dos 9 eletrodos selecionados, enquanto a Figura (b) ilustra a configuração dos 15 eletrodos escolhidos.



Fonte: A autora (2024).

Em seguida, foram geradas duas bases de dados distintas: uma com a configuração de 9 eletrodos e outra com 15 eletrodos. Para a divisão e análise dos dados, utilizou-se o software *Waikato Environment for Knowledge Analysis* (WEKA), versão 3.9.6 (EIBE *et al.*, 2016). Cada conjunto foi particionado em 80% para treino e 20% para teste. O processo de treinamento foi realizado por meio de validação cruzada com 10 folds e 30 repetições para cada classificador. Em cada repetição, os dados eram reembaralhados e divididos novamente em 10 folds, garantindo que os resultados fossem menos influenciados por uma única divisão específica dos dados. Essa abordagem visa minimizar variações aleatórias e melhorar a confiabilidade dos resultados.

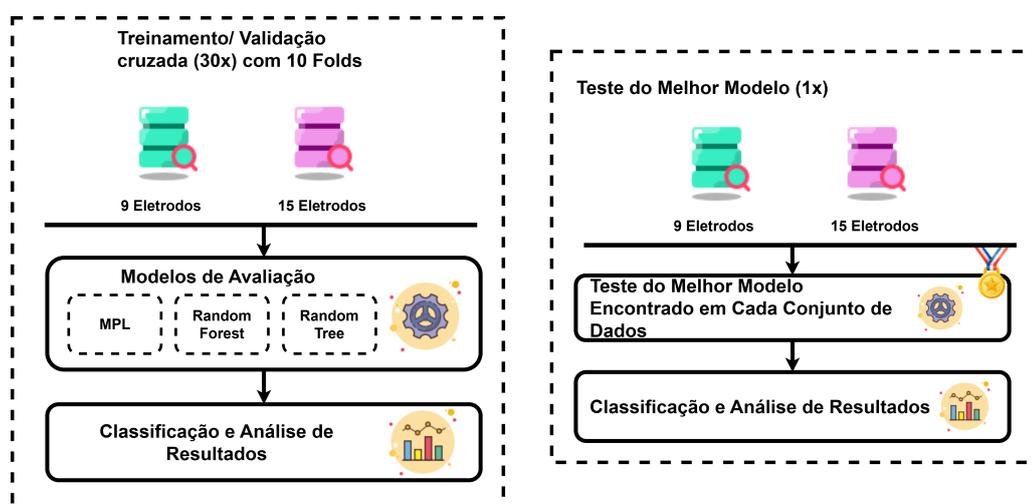
Além disso, ao treinar um modelo com todos os dados disponíveis, existe o risco de que ele aprenda padrões específicos, incluindo ruídos ou particularidades que não se generalizam bem para novos dados, o que caracteriza o sobreajuste. Para mitigar esse problema, a abordagem de validação cruzada é essencial, pois permite avaliar o desempenho real do modelo. Ao utilizar um conjunto de teste, separado do conjunto de treinamento e não envolvido no processo de ajuste do modelo, é possível avaliar como ele se comporta diante de dados não vistos previamente.

Isso oferece uma estimativa realista de seu desempenho em um ambiente do mundo real, onde o modelo precisará lidar com novas amostras.

A separação entre treino e teste também auxilia na detecção de problemas de generalização, assegurando que o modelo não esteja apenas ajustado aos dados de treinamento, mas que tenha capacidade de performar bem em novos dados. Além disso, a prática de validação cruzada, que envolve o uso de diferentes subconjuntos dos dados para treino e teste, permite medir a robustez e consistência do modelo, oferecendo uma avaliação mais confiável sobre sua eficácia e evitando que os bons resultados sejam consequência de um sobreajuste nos dados do teste.

Foram testados diferentes classificadores, incluindo o *Multilayer Perceptron* (MLP) com variações de 5, 10, 15 e 20 neurônios em uma única camada escondida, *Random Forest* com 10, 100 e 500 árvores, além do *Random Tree*. Após a fase de treinamento, o classificador de melhor desempenho foi selecionado para a fase de teste, executada no WEKA com uma única rodada. O diagrama representado na Figura 17 ilustra este processo, evidenciando as etapas de divisão, treinamento e teste, garantindo a confiabilidade dos resultados obtidos.

Figura 17 – A Figura esquematiza de forma detalhada o processo de treinamento/ validação e teste do modelo proposto.



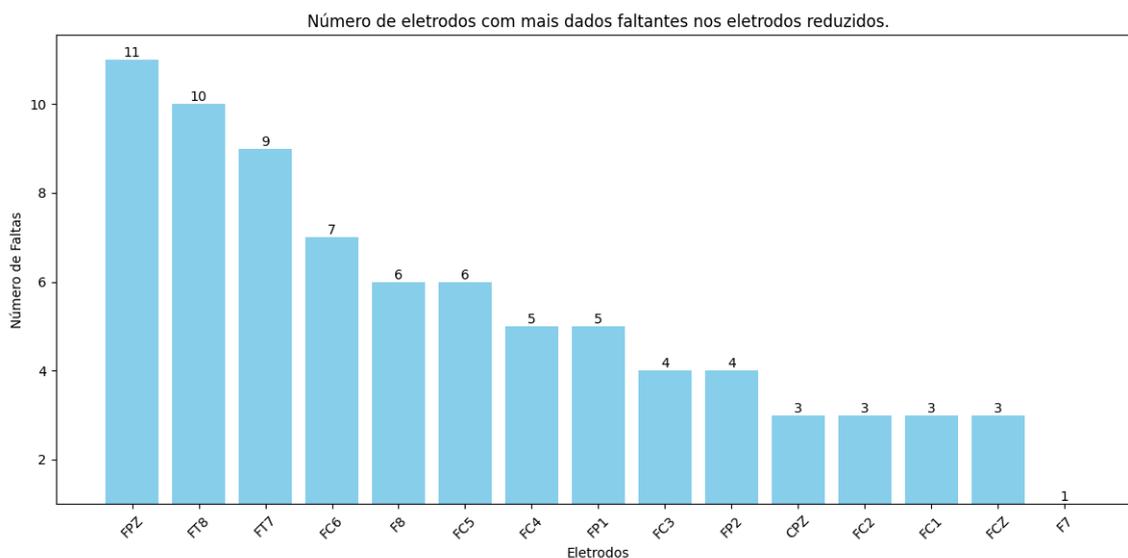
Fonte: A autora (2024).

4.3.1 Análise da base de dados após interpolação

Após a seleção manual dos eletrodos, foi realizada uma análise com o objetivo de identificar quantos dos eletrodos selecionados foram interpolados, o que foi realizado por meio de um *script* em *Python* 3.11.1 (ROSSUM; DRAKE, 2009). A Figura 18 demonstra a quantidade de canais com dados faltantes.

É possível observar que o eletrodo FPz apresenta o maior número de interpolações realizadas, com 11 indivíduos sem sinal nesse eletrodo, em contraste com outros 45 que mantiveram sinal. Esse comportamento pode indicar uma maior suscetibilidade a ruídos ou perda de sinal

Figura 18 – Distribuição dos eletrodos faltantes após a seleção manual.



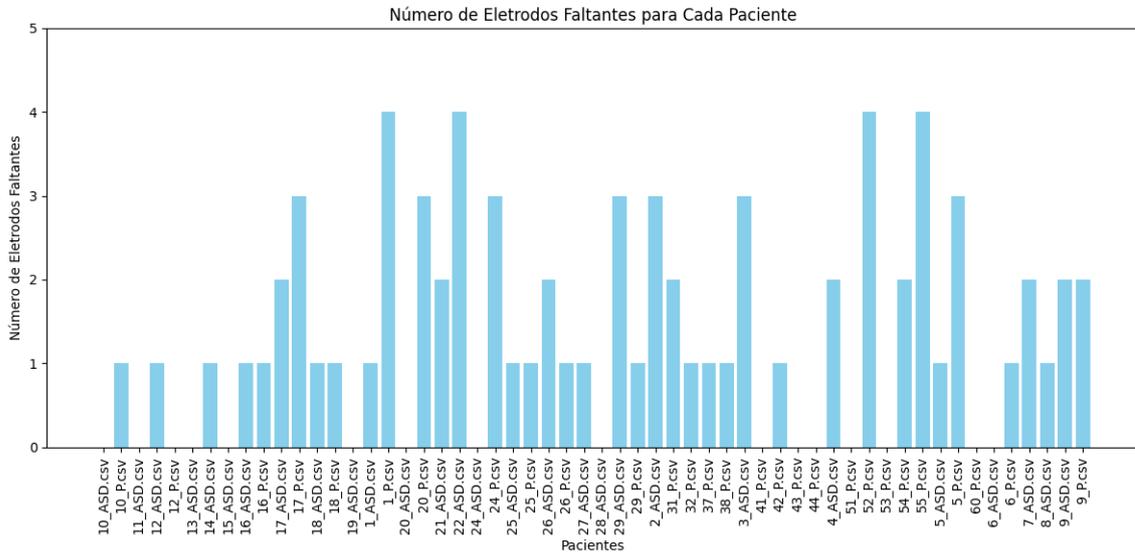
Fonte: A autora (2024).

nessa região específica durante as coletas de EEG. Em contraposição, o eletrodo F7, localizado em uma área lateral do córtex frontal, apresentou apenas uma interpolação, sugerindo que os sinais nessa região foram capturados de maneira mais estável. Essa discrepância significativa entre os dois eletrodos pode ser atribuída a diferentes fatores, como variações nas condições de coleta (movimentos dos pacientes), impedância de contato dos eletrodos ou características específicas do posicionamento no escalpo.

As Figuras 19 e 20 permitem visualizar claramente os indivíduos com maior número de eletrodos interpolados nas bases de 15 e 9 eletrodos, respectivamente, facilitando a identificação desses padrões. Essas visualizações são importantes para destacar possíveis variações nos dados de EEG, que podem impactar o desempenho dos modelos de aprendizado de máquina. A análise comparativa entre as duas bases também pode fornecer uma compreensão mais detalhada sobre a influência da quantidade de eletrodos no processo de interpolação e no comportamento dos sinais capturados.

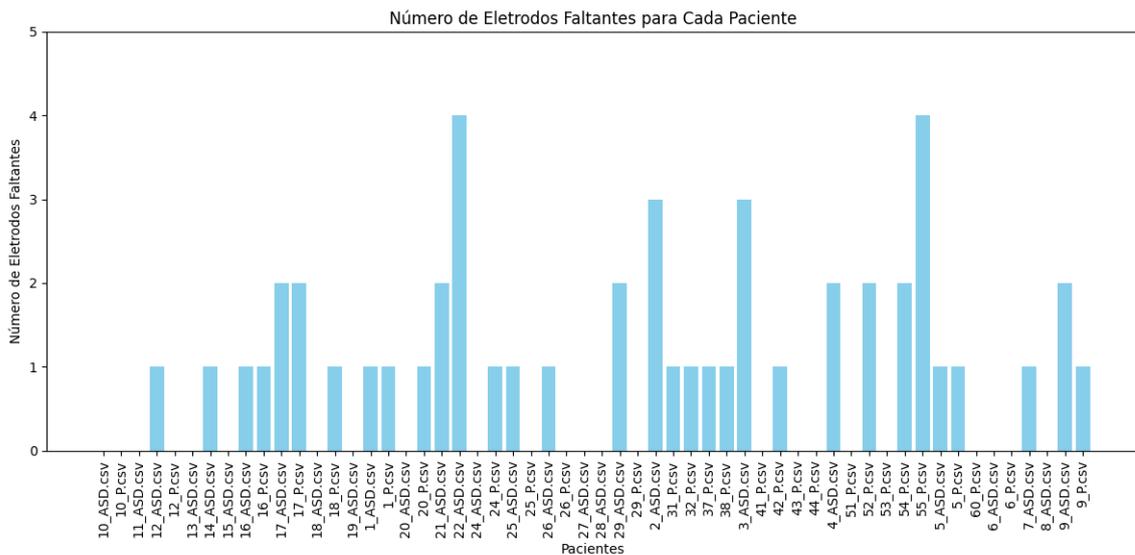
Ambos os gráficos mostram uma faixa de eletrodos faltantes entre 0 e 4, evidenciando que o problema de sinais ausentes persiste, mesmo com a redução no número de eletrodos. Pacientes como 22_ASD e 55_P continuam a apresentar um número elevado de eletrodos faltantes em ambas as configurações. Esses gráficos possibilitam uma comparação clara entre os indivíduos em relação à necessidade de interpolações, facilitando a identificação de padrões que possam influenciar os dados e, conseqüentemente, o desempenho dos modelos de aprendizado de máquina. Dos 56 indivíduos que compõem a base de dados, apenas 15 não apresentaram sinais ausentes na base com 15 eletrodos, enquanto 24 não apresentaram sinais ausentes na base com 9 eletrodos. O número máximo de eletrodos interpolados foi 4, com 3 desses indivíduos pertencentes ao grupo de controle na configuração com 15 eletrodos. A maioria dos arquivos

Figura 19 – Distribuição dos eletrodos faltantes após a seleção manual por indivíduo na base com 15 eletrodos.



Fonte: A autora (2024).

Figura 20 – Distribuição dos eletrodos faltantes após a seleção manual por indivíduo na base com 9 eletrodos.

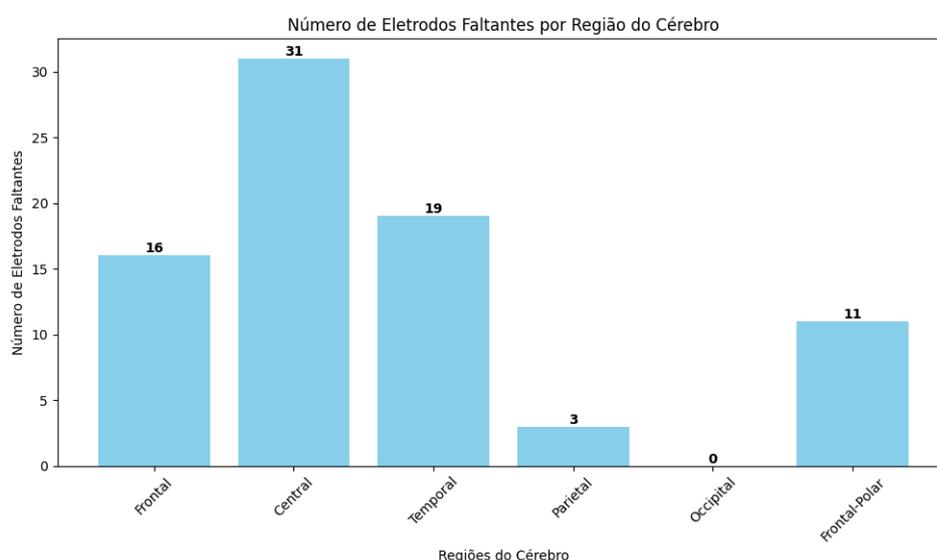


Fonte: A autora (2024).

apresentou apenas um eletrodo interpolado em ambas as bases, o que sugere que, apesar da necessidade de interpolação em alguns casos, a magnitude desse problema foi relativamente baixa, com a maioria dos indivíduos mantendo a integridade dos sinais na maior parte dos eletrodos.

Foi de interesse também analisar, por região do cérebro, quais áreas tiveram maior número de interpolações. Conforme ilustrado na Figura 21, os eletrodos da área central, como FC1, FC3, FC5, FC2, FC4, FC6, e FCz, apresentaram o maior número de interpolações, seguidos pelas regiões temporal, frontal, fronto-polar e parietal. A região occipital, por sua vez, não teve nenhuma interpolação, o que se deve ao fato de que não havia eletrodos selecionados nessa área.

Figura 21 – Distribuição dos eletrodos faltantes por região do cérebro.



Fonte: A autora (2024).

4.4 Métricas de avaliação

Para avaliar o desempenho dos modelos, foram utilizadas diversas métricas que quantificam a eficácia em diferentes aspectos. As métricas e suas fórmulas são as seguintes:

1. Acurácia:

A acurácia é uma métrica que avalia a proporção de previsões corretas, considerando tanto os verdadeiros positivos quanto os verdadeiros negativos, em relação ao total de casos avaliados. Seu valor varia entre 0 e 1, onde 0 significa que o classificador falhou em todas as previsões, e 1 indica que todas as previsões foram corretas. Embora seja uma métrica intuitiva e de fácil compreensão, a acurácia pode ser limitada em contextos de desbalanceamento de classes. Em situações onde uma classe é muito mais prevalente do que a outra, um classificador

que sempre prediz a classe majoritária pode alcançar uma acurácia elevada, mesmo que tenha baixo desempenho na detecção da classe minoritária. Isso pode gerar uma falsa impressão sobre a eficácia real do modelo, especialmente quando o foco é identificar corretamente essa classe menos representada.

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}$$

Aqui, TP refere-se aos verdadeiros positivos, TN aos verdadeiros negativos, FP aos falsos positivos e FN aos falsos negativos.

2. Índice Kappa:

O coeficiente Kappa mede a concordância entre as previsões do modelo e as observações reais, ajustando para a concordância esperada ao acaso. Ele é calculado a partir da acurácia observada (P_o) e da acurácia esperada ao acaso (P_e), utilizando a fórmula $Kappa = \frac{P_o - P_e}{1 - P_e}$. O valor de Kappa varia entre -1 e 1, onde -1 indica desacordo total, sugerindo que o desempenho do classificador é inferior ao acaso. Um valor de 0 significa que o classificador performa de maneira equivalente ao acaso, ou seja, sem utilidade prática, enquanto um valor de 1 representa concordância perfeita entre o classificador e as classes reais. Essa métrica é particularmente relevante em cenários com desbalanceamento de classes, pois ajusta os resultados para penalizar excessos de classificações baseadas em tendências aleatórias, fornecendo assim uma avaliação mais precisa do desempenho do modelo.

3. Sensibilidade:

A sensibilidade, também conhecida como taxa de verdadeiros positivos (TPR), mede a proporção de verdadeiros positivos que o modelo conseguiu identificar corretamente entre todos os casos positivos reais. Sua fórmula é dada pela razão entre o número de verdadeiros positivos (TP) e a soma de verdadeiros positivos (TP) e falsos negativos (FN). Seu valor varia de 0 a 1, onde 0 significa que o classificador não identificou nenhum verdadeiro positivo, e 1 indica que o classificador identificou corretamente todos os verdadeiros positivos.

$$\text{Sensibilidade} = \text{TPR} = \frac{TP}{TP + FN}$$

Essa métrica é especialmente importante em áreas como o diagnóstico médico, onde é crucial detectar todos os casos positivos, mesmo que isso possa resultar em um aumento no número de falsos positivos. Por exemplo, em casos de diagnóstico de doenças graves, uma alta sensibilidade é preferível para garantir que todos os pacientes que precisam de tratamento sejam identificados, minimizando o risco de deixar de diagnosticar alguém que realmente esteja doente.

4. Especificidade:

A especificidade, também conhecida como taxa de verdadeiros negativos, mede a capacidade do classificador de identificar corretamente as instâncias da classe negativa. Ela é calculada pela razão entre o número de verdadeiros negativos (TN) e a soma de verdadeiros negativos (TN) e falsos positivos (FP). Seu valor, assim como o da sensibilidade, varia de 0 a 1:

$$\text{Especificidade} = \frac{TN}{TN + FP}$$

Um valor de 0 significa que o classificador não identificou corretamente nenhum verdadeiro negativo, enquanto 1 indica que todos os verdadeiros negativos foram corretamente identificados. A especificidade é essencial em situações onde os falsos positivos podem ter consequências adversas. Um exemplo típico é a triagem de indivíduos saudáveis em testes de saúde populacional, onde um diagnóstico falso positivo pode resultar em exames adicionais desnecessários, custos elevados e preocupações indevidas para os pacientes.

5. Área sob a Curva ROC:

A Área sob a Curva ROC (AUC) é uma métrica que avalia a capacidade do classificador em discriminar entre classes positiva e negativa, independentemente do limiar de decisão. A AUC é obtida integrando a Taxa de Verdadeiros Positivos (TPR) em função da Taxa de Falsos Positivos (FPR), conforme a equação:

$$\text{Área sob a Curva ROC} = \int_0^1 \text{TPR} d(\text{FPR})$$

Seu valor varia de 0.5 a 1: um valor de 0.5 indica que o classificador não possui habilidade discriminatória, funcionando de forma equivalente a uma escolha aleatória, enquanto um valor de 1 reflete uma separação perfeita entre as classes. A AUC é particularmente útil para comparar o desempenho de diferentes classificadores, especialmente em situações onde há um desbalanceamento entre as classes. Ela permite avaliar a eficácia do modelo em identificar e separar corretamente as classes, independentemente de um limiar fixo de decisão.

Essas métricas, baseadas nas quantidades de Verdadeiros Positivos (TP), Verdadeiros Negativos (TN), Falsos Positivos (FP) e Falsos Negativos (FN), fornecem uma análise detalhada do desempenho do modelo em diferentes aspectos, permitindo uma avaliação robusta e compreensiva de sua eficácia (FONSECA *et al.*, 2022; SANTANA *et al.*, 2023b).

Capítulo 5

Resultados

Neste capítulo, serão apresentados os resultados obtidos a partir dos experimentos realizados com as bases de dados utilizando configurações reduzidas de eletrodos. Neste estudo, foram comparados diversos algoritmos de aprendizado de máquina para avaliar sua eficácia na classificação de um conjunto de dados específico. Os algoritmos analisados incluíram *Random Tree*, *Random Forest* com diferentes números de árvores (10, 100 e 500), e *Multilayer Perceptron* com diferentes quantidades de neurônios em uma única camada escondida (5, 10, 15 e 20). As métricas de desempenho utilizadas para a avaliação foram acurácia, índice *kappa*, sensibilidade, especificidade e a área sob a curva ROC (Área ROC).

5.1 Base com 9 Eletrodos

Na Tabela 4 podemos observar o desempenho do modelo na etapa de treinamento/validação, a análise dos resultados revelou que todos os classificadores exibiram um desempenho geral satisfatório. No entanto, o MLP apresentou um desempenho inferior conforme o número de neurônios na camada oculta foi aumentado. Os modelos MLP, independentemente da quantidade de neurônios, exibiram uma acurácia que variou entre 83,73% e 84,70%, com uma área ROC consistente de 0,93. Apesar de esses valores serem aceitáveis, eles foram inferiores aos resultados obtidos pelos modelos *Random Tree* e *Random Forest*. A inclusão de neurônios adicionais no MLP não resultou em melhorias substanciais no desempenho dos modelos.

O modelo *Random Tree* destacou-se na avaliação dos classificadores ao alcançar uma acurácia de 89,91%, evidenciando uma performance superior comparada aos outros algoritmos analisados. O índice *kappa* de 0,80 reforça essa constatação, indicando uma concordância substancial além do esperado ao acaso. A taxa de sensibilidade e especificidade de 0,90 sugere que o *Random Tree* é igualmente eficaz na identificação de casos positivos e negativos, refletindo um equilíbrio ideal na classificação das amostras. Adicionalmente, a área sob a curva ROC de 0,90 ressalta a habilidade do modelo em distinguir corretamente entre as classes, evidenciando uma excelente capacidade discriminativa. Esse desempenho robusto pode ser atribuído ao método

Tabela 4 – Resultados da etapa de treinamento e validação do conjunto de dados com 9 eletrodos.

Classificador		Acurácia	Kappa	Sensibilidade	Especificidade	Área ROC
Random Tree		89,91% ± 1,70	0,80 ± 0,03	0,90 ± 0,02	0,90 ± 0,02	0,90 ± 0,02
Random Forest	10 árvores	96,14% ± 0,94	0,92 ± 0,02	0,98 ± 0,01	0,95 ± 0,02	0,99 ± 0,00
Random Forest	100 árvores	97,91% ± 0,68	0,96 ± 0,01	0,98 ± 0,01	0,97 ± 0,01	1,00 ± 0,00
Random Forest	500 árvores	98,06% ± 0,66	0,96 ± 0,01	0,99 ± 0,01	0,98 ± 0,01	1,00 ± 0,00
MLP	5 Neurônios	84,70% ± 4,07	0,69 ± 0,08	0,85 ± 0,10	0,85 ± 0,11	0,93 ± 0,02
MLP	10 Neurônios	84,35% ± 4,42	0,69 ± 0,09	0,84 ± 0,11	0,85 ± 0,11	0,93 ± 0,03
MLP	15 Neurônios	83,87% ± 4,89	0,68 ± 0,10	0,84 ± 0,12	0,85 ± 0,12	0,93 ± 0,03
MLP	20 Neurônios	83,73% ± 5,11	0,67 ± 0,10	0,83 ± 0,12	0,85 ± 0,13	0,93 ± 0,03

Fonte: A autora (2024).

de ensemble utilizado pelo *Random Tree*, que combina múltiplas árvores de decisão treinadas em subconjuntos aleatórios dos dados e características, aprimorando a generalização e a precisão do modelo.

Finalmente, o *Random Forest* demonstrou um desempenho superior ao *Random Tree* e ao MLP, destacando-se em termos de acurácia e capacidade discriminativa. O modelo com 10 árvores alcançou uma acurácia de 96,14%, enquanto o modelo com 100 árvores elevou esse valor para 97,91%, e o modelo com 500 árvores atingiu uma acurácia impressionante de 98,06%. Estes resultados demonstram uma melhoria contínua na precisão conforme o número de árvores aumenta, sugerindo que a inclusão de mais árvores contribui significativamente para a robustez e a eficácia do modelo.

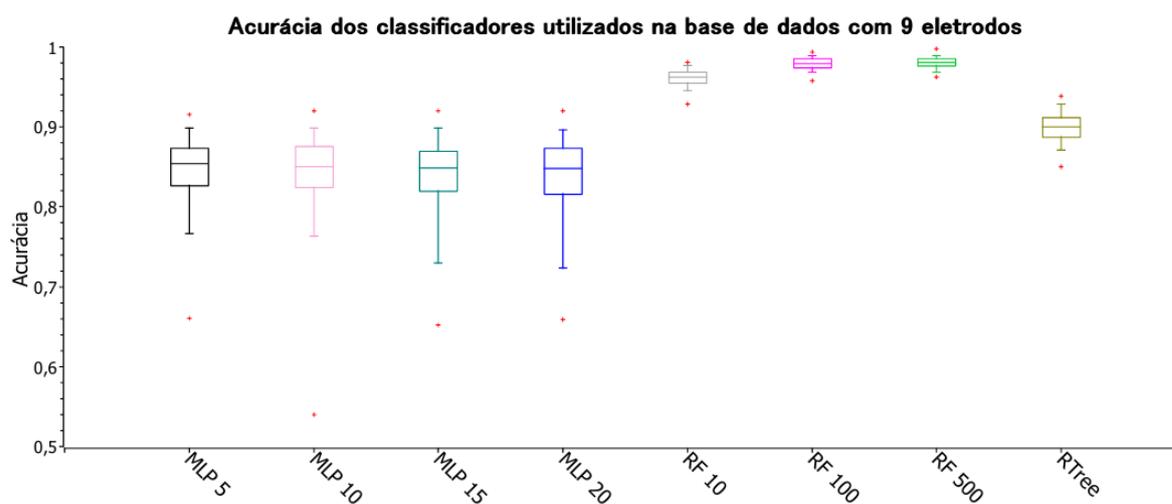
Além disso, a área sob a curva ROC foi excepcionalmente alta para todos os modelos de *Random Forest*, alcançando o valor máximo de 1,00 nos modelos com 100 e 500 árvores. Esse resultado reflete uma capacidade de discriminação quase perfeita, indicando que o modelo é extremamente eficaz em diferenciar entre as classes e identificar corretamente as amostras, tanto positivas quanto negativas.

Esses dados ressaltam a superioridade do *Random Forest* em relação ao *Random Tree* e aos modelos *Multilayer Perceptron* no contexto da classificação dos sinais de EEG para o diagnóstico do Transtorno do Espectro Autista. O desempenho consistente e elevado em termos de acurácia e capacidade discriminativa confirma que o *Random Forest* é a abordagem mais robusta e confiável para a análise dos dados, oferecendo uma precisão quase perfeita e uma capacidade de diferenciação altamente eficaz.

Os boxplots apresentados na Figura 22 ilustram a distribuição da acurácia alcançada com a base de dados utilizando a configuração de 9 eletrodos. Esses gráficos permitem observar a variação nos resultados obtidos pelos diferentes classificadores aplicados e revelam diferenças estatisticamente significativas entre eles. A análise dos *boxplots* possibilitou uma avaliação comparativa do desempenho dos modelos, destacando quais configurações de parâmetros e

classificadores oferecem maior robustez e precisão no contexto da pesquisa. Notou-se que o classificador *Random Forest*, especialmente com 100 e 500 árvores, apresentaram as maiores acurácias, com pouca variabilidade nos resultados. Isso indica que esses modelos são mais consistentes e confiáveis para esta base de dados. Em contraste, os classificadores *Multilayer Perceptron* mostraram maior variabilidade, sugerindo que seu desempenho pode ser menos previsível e depende fortemente das condições de treinamento.

Figura 22 – Os *boxplots* apresentados na Figura ilustram a distribuição da acurácia alcançada com a base de dados utilizando a configuração de 9 eletrodos.



Fonte: A autora (2024).

5.1.1 Base com 9 Eletrodos - Teste do Modelo

A etapa de teste foi realizada com o intuito de avaliar o desempenho do modelo com dados que não foram vistos durante o treinamento. O objetivo é verificar a capacidade do modelo de generalizar para novos dados, em vez de apenas memorizar os dados de treinamento. Enquanto a base de treinamento/validação é utilizada para ajustar hiperparâmetros, a base de teste oferece uma avaliação final do desempenho do modelo ajustado. Isso garante que as escolhas feitas durante o treinamento e validação resultem em um modelo robusto e confiável.

Nesta etapa, foram analisados apenas dois modelos no WEKA devido à semelhança nos resultados obtidos. Os classificadores *Random Forest* com 100 e 500 árvores foram escolhidos para esta avaliação. A Figura 23 ilustra as matrizes de confusão para esses modelos, proporcionando uma visão do desempenho de cada classificador.

É evidente que não houve diferença entre as duas matrizes de confusão. Isso indica que ambas refletem o mesmo desempenho dos modelos, apresentando as mesmas contagens de verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. As métricas derivadas dessas matrizes também são idênticas, como mostrado na Tabela 5. Nessa Tabela, fica claro que os resultados são equivalentes entre as duas configurações do *Random Forest*,

Figura 23 – As matrizes de confusão para os classificadores *Random Forest* com 100 árvores e 500 árvores são apresentadas respectivamente para a base de 9 Eletrodos. Estas matrizes fornecem uma visão do desempenho dos classificadores, mostrando como cada modelo categorizou as instâncias nas classes positiva e negativa.

		Classificado	
		TEA	C
Real	TEA	590	1
	C	2	591

RF 100

		Classificado	
		TEA	C
Real	TEA	590	1
	C	2	591

RF 500

Fonte: A autora (2024).

confirmando a consistência do desempenho dos classificadores, independentemente de terem sido utilizadas 100 ou 500 árvores. Isso sugere que o aumento no número de árvores não trouxe benefícios adicionais em termos de acurácia ou outras métricas avaliadas.

Tabela 5 – Resultados da etapa de teste do conjunto de dados com 9 eletrodos

Classificador		Acurácia	Kappa	Sensibilidade	Especificidade	Área ROC
Random Forest	100 árvores	99,74 %	0,99	0,97	0,99	1,00
Random Forest	500 árvores	99,74%	0,99	0,97	0,99	1,00

Fonte: A autora (2024).

Com base nesses resultados, pode-se concluir que a configuração de *Random Forest* com 100 árvores é suficiente para este conjunto de dados, já que não há melhoria perceptível ao aumentar o número de árvores para 500. O modelo demonstrou robustez, generalizando bem nos dados de teste, e a escolha de 100 árvores se apresenta como a mais adequada, considerando o equilíbrio entre desempenho e eficiência computacional. Isso sugere que, para este caso específico, o aumento do número de árvores não traz ganhos significativos, o que torna a configuração de 100 árvores a opção mais eficiente.

5.2 Base com 15 Eletrodos

Assim como observado na base de dados com 9 eletrodos, o conjunto de dados com 15 eletrodos também apresentou resultados positivos, conforme detalhado na Tabela 6.

Os resultados sugerem que todos os classificadores obtiveram um bom desempenho em todas as métricas. O algoritmo *Random Tree* demonstrou um desempenho razoavelmente bom com uma acurácia de 86,63%, mas foi superado por classificadores mais complexos e robustos, como o *Random Forest*. Por outro lado, ao analisar o desempenho do MLP com diferentes

Tabela 6 – Resultados da etapa de treinamento e validação do conjunto de dados com 15 eletrodos

Classificador		Acurácia	Kappa	Sensibilidade	Especificidade	Área ROC
Random Tree		89,63% ± 1,62	0,79 ± 0,03	0,90 ± 0,02	0,90 ± 0,02	0,90 ± 0,02
Random Forest	10 árvores	96,54% ± 0,86	0,93 ± 0,02	0,98 ± 0,01	0,95 ± 0,01	0,99 ± 0,00
Random Forest	100 árvores	98,34% ± 0,57	0,97 ± 0,01	0,99 ± 0,01	0,98 ± 0,01	0,99 ± 0,00
Random Forest	500 árvores	98,49% ± 0,57	0,97 ± 0,01	0,99 ± 0,01	0,98 ± 0,01	1,00 ± 0,00
MLP	5 Neurônios	85,50% ± 5,26	0,71 ± 0,11	0,85 ± 0,11	0,86 ± 0,13	0,95 ± 0,02
MLP	10 Neurônios	84,84% ± 6,08	0,70 ± 0,12	0,82 ± 0,14	0,87 ± 0,13	0,94 ± 0,03
MLP	15 Neurônios	82,97% ± 6,38	0,66 ± 0,13	0,81 ± 0,14	0,85 ± 0,16	0,92 ± 0,04
MLP	20 Neurônios	82,57% ± 6,07	0,65 ± 0,12	0,82 ± 0,13	0,83 ± 0,16	0,92 ± 0,04

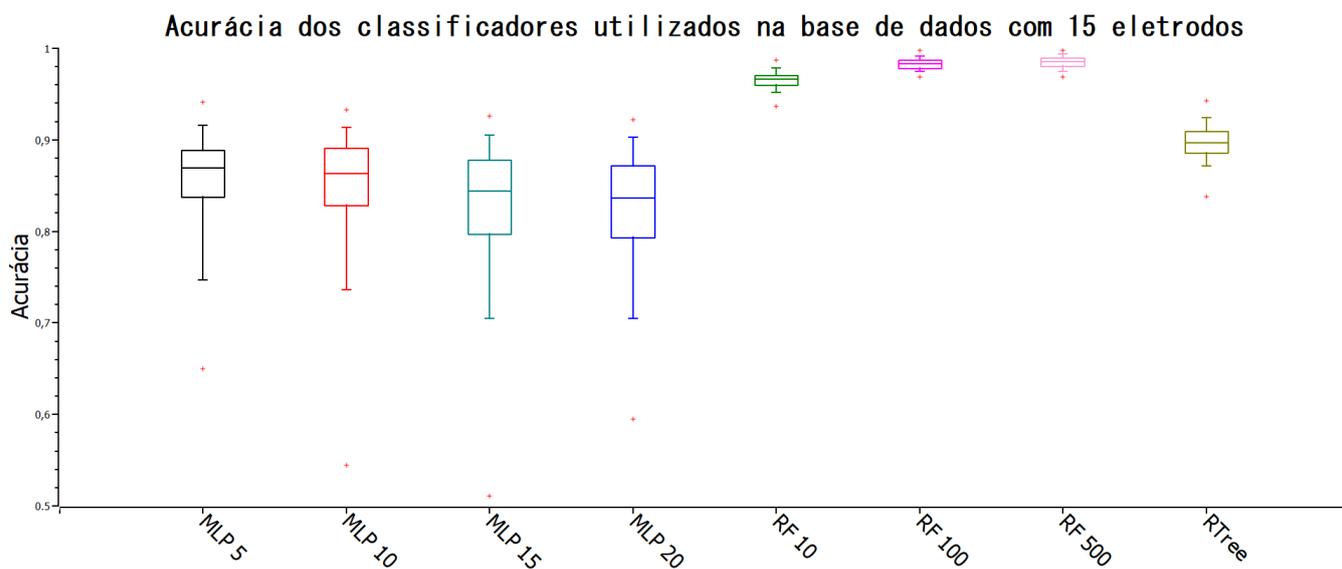
Fonte: A autora (2024).

quantidades de neurônios na camada oculta, que variam de 5 a 20, observa-se uma sensibilidade significativa à configuração do modelo. A acurácia do MLP apresenta uma tendência de declínio à medida que o número de neurônios aumenta, indicando que, para este conjunto de dados específico, a configuração mais eficiente é o MLP com 5 camadas, que alcança uma acurácia de 85,50%. Essa tendência sugere que, para a classificação de sinais eletroencefalográficos associados ao Transtorno do Espectro Autista, a complexidade adicional proporcionada por um maior número de neurônios pode não contribuir de forma benéfica e, em alguns casos, pode até prejudicar o desempenho do modelo.

A tendência de aprimoramento do classificador *Random Forest* é evidente à medida que o número de árvores é incrementado. Especificamente, a configuração com 500 árvores demonstrou ser a mais eficiente neste cenário, destacando-se em termos de acurácia e área ROC. Esses resultados sugerem uma relação positiva entre a complexidade do modelo, medida pelo número de árvores, e a capacidade de generalização do algoritmo para a classificação de sinais eletroencefalográficos relacionados ao Transtorno do Espectro Autista.

A Figura 24 apresenta os *boxplots* da acurácia obtida por diversos classificadores na configuração com 15 eletrodos. Nota-se que a acurácia do classificador *Random Forest* melhora progressivamente conforme o número de árvores aumenta. A comparação entre os modelos testados revela uma maior dispersão no desempenho do MLP em relação ao *Random Forest* e ao *Random Tree*. Essa maior variação no MLP pode ser explicada pela sua arquitetura mais complexa, que o torna mais sensível a variações nos parâmetros e nos dados de entrada. Em contraste, os classificadores *Random Forest* e *Random Tree*, ambos baseados em árvores de decisão, exibem um comportamento mais estável e resultados com menor variabilidade. Embora o MLP tenha potencial para captar padrões mais sofisticados, a maior dispersão sugere que ajustes finos nos hiperparâmetros são necessários para obter resultados consistentes. O ganho de acurácia observado no *Random Forest* pode ser atribuído à sua capacidade de integrar múltiplas árvores de decisão, o que permite uma captura mais abrangente de padrões complexos nos dados, além de reduzir o risco de *overfitting*.

Figura 24 – Os *boxplots* apresentados na Figura ilustram a distribuição da acurácia alcançada com a base de dados utilizando a configuração de 15 eletrodos.



Fonte: A autora (2024).

A inclusão de mais árvores parece aumentar a capacidade do modelo de aprender e generalizar a partir dos dados complexos e variados, proporcionando uma classificação mais precisa e confiável dos sinais de EEG. No entanto, é importante considerar o custo computacional associado ao treinamento e à execução de modelos com um grande número de árvores. Embora a configuração com 500 árvores apresente a maior acurácia, a configuração com 100 árvores pode oferecer um equilíbrio mais vantajoso entre desempenho e eficiência computacional, especialmente em ambientes com recursos limitados.

Essa observação ressalta a importância da seleção criteriosa dos parâmetros na construção e ajuste de modelos de aprendizado de máquina. A escolha inadequada do número de camadas pode levar a um sobreajuste ou a um desempenho inferior, evidenciando a necessidade de um equilíbrio entre a complexidade do modelo e a capacidade de generalização.

5.2.1 Base com 15 Eletrodos - Teste do Modelo

Assim como na base de dados com 9 eletrodos, este conjunto de dados também passou pela etapa de teste com o mesmo objetivo: avaliar a capacidade de generalização do modelo, assegurando que ele pudesse lidar com dados não observados previamente. As métricas de desempenho foram aplicadas para comparar os classificadores e verificar a robustez e consistência dos resultados obtidos, garantindo que o modelo selecionado mantivesse um desempenho estável e confiável em novos cenários. Foram testados os modelos de *Random Forest* com 100 e 500 árvores, e as métricas atribuídas a esses modelos podem ser visualizadas na Tabela 7.

Os dois modelos apresentaram desempenhos praticamente idênticos. A leve diferença de

Tabela 7 – Resultados da etapa de teste do conjunto de dados com 15 eletrodos

Classificador		Acurácia	Kappa	Sensibilidade	Especificidade	Área ROC
Random Forest	100 árvores	99,84%	0,99	0,99	0,99	1,00
Random Forest	500 árvores	99,74%	0,99	0,99	0,99	1,00

Fonte: A autora (2024).

0,10% na acurácia entre os classificadores com 100 e 500 árvores não é significativa o suficiente para justificar o uso do modelo mais complexo, com 500 árvores. Além disso, as outras métricas são praticamente iguais, reforçando que o aumento do número de árvores não trouxe melhorias substanciais neste caso. Embora ambos os modelos tenham alcançado resultados semelhantes, o classificador com 100 árvores tem uma menor demanda computacional, tanto em termos de tempo de processamento quanto de uso de memória, em comparação com o classificador com 500 árvores. Dessa forma, o modelo com 100 árvores oferece o mesmo nível de desempenho com um custo computacional mais baixo.

Como o aumento no número de árvores não resultou em uma melhoria significativa no desempenho, o classificador com 100 árvores se mostra a opção mais eficiente e adequada para essa tarefa, fornecendo resultados comparáveis ao modelo com 500 árvores, mas com maior eficiência em termos de recursos computacionais. A matriz de confusão do modelo reflete essa eficiência, como ilustrado na Figura 25. Embora as diferenças sejam mínimas, a matriz do classificador *Random Forest* com 100 árvores mostra um desempenho ligeiramente superior na classificação da classe C1, com uma taxa de erro marginalmente menor. Embora a diferença seja sutil, ela pode ser relevante em cenários onde a detecção correta da classe positiva (C1) é fundamental. Nesse contexto, o modelo que demonstrou melhor desempenho na matriz de confusão seria preferido em aplicações onde a identificação correta de instâncias da classe C1 tenha maior prioridade.

Figura 25 – As matrizes de confusão para os classificadores *Random Forest* com 100 árvores e 500 árvores são apresentadas respectivamente para a base de 15 Eletrodos. Estas matrizes fornecem uma visão do desempenho dos classificadores, mostrando como cada modelo categorizou as instâncias nas classes positiva e negativa.

		Classificado	
		TEA	C
Real	TEA	590	1
	C	1	592

RF 100

		Classificado	
		TEA	C
Real	TEA	589	2
	C	1	592

RF 500

Fonte: A autora (2024).

A escolha de um modelo com 100 árvores, que apresenta desempenho semelhante ao de 500 árvores, pode ser especialmente relevante em contextos onde a eficiência de recursos é crucial, como no Sistema Único de Saúde (SUS). No SUS, a disponibilidade de recursos computacionais pode ser limitada, e a otimização de tempo de processamento e uso de memória é fundamental para garantir que as tecnologias possam ser implementadas de forma eficiente em larga escala. O uso de um classificador com 100 árvores oferece um equilíbrio ideal entre precisão e eficiência computacional, permitindo que sistemas de diagnóstico assistido por computador sejam integrados ao SUS de maneira mais acessível e viável, sem comprometer a qualidade dos resultados. Dessa forma, a aplicação de soluções otimizadas como essa pode acelerar o diagnóstico e a triagem de pacientes, proporcionando suporte valioso para os profissionais de saúde dentro da realidade operacional do sistema público.

5.3 Discussões

Os resultados obtidos são sugestivos que é possível identificar o Transtorno do Espectro Autista a partir da análise de sinais de eletroencefalograma em combinação com técnicas de Inteligência Artificial. A capacidade dos algoritmos de IA de extrair e analisar padrões complexos nos sinais de EEG demonstra seu potencial para contribuir significativamente no diagnóstico precoce e preciso do TEA. Este avanço tecnológico pode revolucionar as abordagens clínicas, oferecendo uma ferramenta complementar para os profissionais de saúde na identificação e monitoramento de indivíduos com autismo.

Os resultados corroboram as evidências já estabelecidas na literatura sobre os padrões de ativação na região frontotemporal do cérebro, uma área frequentemente associada ao Transtorno do Espectro Autista. A análise focada nessa região foi suficiente para alcançar alta precisão na classificação, reforçando a relevância dos padrões de atividade frontotemporal como potenciais biomarcadores para o diagnóstico do TEA. A consistência com achados prévios valida a metodologia empregada e destaca a importância de estudos futuros que investiguem mais detalhadamente as características neurais dessa região no contexto do autismo.

Por exemplo, um estudo conduzido por [ABDULHAY *et al.* \(2023\)](#) explorou canais específicos do EEG e observou diferenças significativas na entropia de indivíduos com TEA. Enquanto indivíduos neurotípicos exibem um padrão estável, os canais em pessoas com TEA, como F8 e FC6, apresentaram variações acentuadas, corroborando os achados desta pesquisa, que também incluiu esses canais. Além disso, [Abdulhay et al. \(2023\)](#) notaram que as oscilações de alta frequência são marcadamente irregulares em indivíduos com TEA, contrastando com o espectro de potência em neurotípicos, onde há uma diminuição suave de potência com o aumento da frequência. [RADHAKRISHNAN; BORUAH; RAMAMURTHY \(2022\)](#), por sua vez, identificaram anomalias nos sinais de EEG de pessoas com TEA nas áreas frontotemporal, temporal e parietal, que também foram exploradas neste estudo. Essas evidências sugerem que

as regiões escolhidas podem servir como potenciais biomarcadores no diagnóstico do TEA.

A utilização de um número reduzido de eletrodos na aquisição de sinais de EEG é especialmente relevante em cenários como o do Sistema Único de Saúde, onde o acesso a equipamentos sofisticados, com um grande número de eletrodos, pode ser limitado. Essa abordagem simplificada não apenas torna o procedimento mais acessível, mas também otimiza a aplicação prática, uma vez que envolve a colocação de um número menor de eletrodos, o que reduz significativamente o tempo de preparação e minimiza o desconforto para o paciente. Em ambientes clínicos com recursos restritos, onde a eficiência e a rapidez são importantes, essa estratégia se destaca como uma solução viável e eficaz para diagnósticos em larga escala. Ao simplificar o processo com menos eletrodos, a metodologia não só se adapta melhor às limitações tecnológicas e logísticas desses contextos, como também melhora a aplicabilidade prática, garantindo que o diagnóstico possa ser implementado de maneira mais ágil e acessível.

O bom desempenho dos modelos com um número reduzido de eletrodos mostrou-se competitivo quando comparado a estudos que utilizam um maior número de eletrodos. Por exemplo, (TAWHID *et al.* (2021) utilizaram o algoritmo *Random Forest* em uma configuração com mais eletrodos e obtiveram uma acurácia inferior, de 90,59%, em relação ao modelo proposto. Isso evidencia a eficácia da abordagem desenvolvida neste estudo, que conseguiu alcançar resultados superiores utilizando uma configuração otimizada de eletrodos. Essa eficiência sugere que é possível reduzir a complexidade e os custos associados à coleta de dados de EEG, sem comprometer a precisão do diagnóstico de TEA, tornando a técnica mais acessível e aplicável em contextos clínicos reais.

A metodologia proposta, que combina a extração de atributos explícitos com o uso do classificador *Random Forest*, destaca-se por seu baixo custo computacional, o que a torna particularmente vantajosa para o desenvolvimento de dispositivos destinados à prática clínica. Essa característica é especialmente relevante, pois permite a criação de soluções diagnósticas acessíveis e eficientes, mesmo em ambientes clínicos onde os recursos computacionais são limitados. Ao reduzir as demandas de processamento, a metodologia proposta facilita a implementação de sistemas de diagnóstico assistidos por inteligência artificial, ampliando significativamente seu potencial de aplicação em larga escala e em contextos com restrições tecnológicas, como hospitais públicos ou clínicas com recursos reduzidos. Dessa forma, a proposta não só contribui para a precisão diagnóstica, mas também para a viabilidade de adoção em diferentes cenários clínicos.

É relevante destacar que, embora o *Random Forest* com 500 árvores tenha atingido a melhor acurácia média nos dois conjuntos de treinamento de dados, o uso de um *Random Forest* com 100 árvores também seria uma escolha viável para o desenvolvimento de soluções práticas. Isso se deve ao fato de que, ao considerar o desvio padrão, ambos os modelos apresentaram desempenho equivalente. Optar pelo modelo com 100 árvores oferece a vantagem adicional de uma estrutura mais simples, resultando em um menor custo computacional, o que pode

ser particularmente benéfico em cenários onde a eficiência computacional e a agilidade são essenciais.

Os resultados obtidos utilizando 9 e 15 eletrodos demonstraram equivalência em termos de eficácia, o que sugere que o uso de 9 eletrodos pode ser uma opção mais prática para a aplicação clínica, considerando o menor número de sensores e a facilidade de manuseio. No entanto, é importante destacar que, embora os eletrodos localizados nas regiões frontal, fronto-central e frontotemporal, pareçam ser suficientes para o diagnóstico, os resultados podem ter sido influenciados pelo maior número de interpolações nessas regiões. Dessa forma, em estudos futuros, seria recomendável aplicar a metodologia em bases de dados mais completas, com menor necessidade de interpolação, a fim de validar ainda mais esses achados e garantir que o desempenho dos classificadores não seja enviesado pela qualidade dos dados. Isso permitiria uma avaliação mais precisa da viabilidade de um número reduzido de eletrodos no diagnóstico de TEA, especialmente em contextos clínicos.

Embora a abordagem proposta tenha demonstrado resultados promissores na identificação do Transtorno do Espectro Autista a partir de sinais de EEG, é essencial reconhecer que o método ainda requer validação adicional. Idealmente, para aumentar a robustez dos achados, seria necessário testar o modelo em uma base de dados mais extensa, incluindo um número maior de sujeitos e, preferencialmente, crianças na primeira infância, uma vez que o diagnóstico precoce é crucial para intervenções eficazes. Além disso, a inclusão de informações mais detalhadas sobre o nível de suporte e a gravidade dos sintomas de TEA dos sujeitos poderia enriquecer a análise, permitindo uma melhor personalização dos modelos e aumentando a generalização dos resultados. Essa abordagem mais aprofundada poderia identificar padrões mais específicos nos sinais de EEG e melhorar ainda mais a precisão dos algoritmos de aprendizado de máquina, contribuindo para a criação de soluções diagnósticas mais eficazes e acessíveis no contexto clínico.

Em síntese, a integração de técnicas de IA com a análise de sinais de EEG desponta como uma abordagem promissora para o diagnóstico precoce e preciso do TEA. A capacidade dessas tecnologias de detectar e interpretar padrões cerebrais complexos, aliada à sua viabilidade em contextos clínicos com recursos limitados, sugere um futuro em que o diagnóstico do TEA seja mais acessível, eficiente e personalizado. No entanto, para que essa abordagem seja amplamente adotada, é essencial que estudos adicionais validem e aperfeiçoem esses métodos, garantindo sua robustez e aplicabilidade em diversos contextos clínicos. A continuidade dessa pesquisa é necessária para transformar esses avanços em ferramentas práticas que melhorem a qualidade de vida de indivíduos com TEA e suas famílias.

Capítulo 6

Conclusão

A pesquisa demonstrou que os algoritmos de IA têm a capacidade de extrair e analisar padrões complexos nos sinais de EEG, evidenciando seu potencial para melhorar o diagnóstico precoce do TEA. A análise focalizada na região frontotemporal do cérebro, área frequentemente associada a esse transtorno, revelou-se eficaz, corroborando as evidências já estabelecidas na literatura científica. As descobertas de estudos anteriores, reforçaram a importância dos padrões de atividade neural nessa região como possíveis biomarcadores para o diagnóstico do TEA.

Além disso, a adoção de um número reduzido de eletrodos na aquisição de sinais de EEG mostrou-se particularmente relevante em contextos clínicos com recursos limitados, como os do Sistema Único de Saúde. Essa abordagem não apenas torna o procedimento mais acessível, mas também minimiza o desconforto para os pacientes e otimiza a logística de aplicação clínica. A utilização de um número reduzido de eletrodos pode facilitar a implementação de exames de EEG em ambientes onde a infraestrutura é limitada, sem comprometer significativamente a qualidade dos dados coletados. Dessa forma, essa estratégia pode contribuir para um diagnóstico mais eficiente e abrangente, beneficiando um maior número de pacientes em diferentes contextos.

A metodologia proposta destaca-se por seu baixo custo computacional, o que a torna especialmente vantajosa para o desenvolvimento de soluções diagnósticas que podem ser implementadas em ambientes clínicos. O fato de que modelos com um número reduzido de árvores ainda apresentaram desempenho equivalente ao de modelos mais complexos indica que há flexibilidade e viabilidade em optar por soluções que priorizam eficiência e acessibilidade. Essa característica é particularmente relevante em contextos onde recursos financeiros e tecnológicos são limitados, permitindo que instituições de saúde adotem ferramentas eficazes para o diagnóstico precoce do TEA sem a necessidade de investimentos exorbitantes em infraestrutura. Assim, a metodologia não só promove a inclusão de tecnologias avançadas na prática clínica, mas também contribui para um atendimento mais equitativo aos pacientes.

6.1 Dificuldades Encontradas

Apesar das descobertas promissoras, este estudo enfrentou desafios significativos que precisam ser abordados em investigações futuras. Um dos principais obstáculos foi a presença de dados faltantes na base de sinais de EEG. Embora essa lacuna nas informações não tenha comprometido a análise, o ideal seria que todos os eletrodos tivessem sinal, pois isso poderia proporcionar uma compreensão mais abrangente dos padrões de EEG em indivíduos com TEA. Além disso, a falta de informações sobre o grau de autismo dos sujeitos na base de dados limitou a capacidade de realizar uma análise mais detalhada e significativa. A ausência de categorização sobre a gravidade dos sintomas impede a correlação entre as características neurais observadas e as manifestações clínicas do transtorno.

Adicionalmente, a dificuldade em encontrar bases de dados com informações específicas sobre sinais de EEG e suas respectivas classificações de TEA é um desafio recorrente na área. Isso ressalta a importância de desenvolver e manter uma base de dados própria que contenha informações abrangentes e bem documentadas sobre os sujeitos estudados. A criação de uma base de dados robusta permitiria não apenas a validação das metodologias propostas, mas também a possibilidade de aprofundar o conhecimento sobre as relações entre os sinais de EEG e as características do TEA.

Além disso, é fundamental que, ao aplicar o modelo em contextos reais, ele seja treinado com dados de diversas faixas etárias. A atividade cerebral apresenta diferenças significativas entre as idades, e a inclusão de uma amostra representativa de diferentes grupos etários é essencial para garantir a precisão e a eficácia do diagnóstico.

6.2 Contribuições

Os resultados desta pesquisa proporcionaram várias contribuições para a academia, com um grande potencial de expansão e aprimoramento. Dentre elas, destacam-se:

- Revisão Sistemática da Literatura sobre Inteligência Artificial para Diagnóstico Precoce do Transtorno do Espectro Autista (TEA).
- Proposta de um Método Inovador para Diagnóstico Precoce de TEA.
- Premiação no 29º Congresso Nacional de Pós-Graduandos.
- Publicação de um Capítulo em Livro Internacional (em andamento).

A Tabela 8 detalha as principais publicações resultantes deste trabalho.

Tabela 8 – Contribuições derivadas dos resultados desta pesquisa.

Título do Artigo\Capítulo	Evento\Livro	Ano
Eletroencefalograma e Aprendizado de Máquina: Uma Avaliação de Diferentes Abordagens para o Diagnóstico de Autismo	Coletânea de Estudos Teórico-práticos na Engenharia Biomédica, vol. 1	2024
Diminuição da Dimensionalidade do EEG para Diagnóstico do TEA Usando Aprendizado de Máquina	VIII Simpósio de inovação em Engenharia Biomédica	2024
Avanços na Estimulação Cerebral Profunda para o Tratamento do Transtorno Obsessivo-Compulsivo: Uma Revisão Narrativa	VIII Simpósio de inovação em Engenharia Biomédica	2024
Aplicação de Inteligência Artificial na Detecção de Características Neuroelétricas por Meio de Eletroencefalograma: Uma Revisão Sistemática da Literatura	VIII Simpósio de inovação em Engenharia Biomédica	2024
Enhancing ASD diagnosis with low-density EEG and machine learning	XXIX Congresso Brasileiro de Engenharia Biomédica (CBEB)	2024
Inteligência Artificial no Diagnóstico Precoce do TEA: Uma Revisão Sistemática	29° Congresso Nacional de Pós-Graduandos	2024

Fonte: A autora (2024).

6.3 Trabalhos Futuros

Com base nas limitações encontradas, os próximos passos para melhorar os resultados desta pesquisa incluem a construção de uma base de dados com um maior número de sujeitos, preferencialmente crianças na primeira infância, além de distinguir os diferentes níveis de suporte que os indivíduos com TEA demandam. Outro aspecto fundamental será a minimização dos dados faltantes, visando garantir análises mais robustas e confiáveis. Como o TEA pode ser confundido ou coexistir com outros transtornos, como o Transtorno de Déficit de Atenção e Hiperatividade (TDAH) e depressão, por exemplo, uma abordagem de classificação multiclases, em vez da binária, pode ser explorada para incluir múltiplos transtornos no diagnóstico e aprimorar a precisão dos resultados.

O papel das regiões cerebrais como biomarcadores do TEA também deve ser investigado com mais profundidade, buscando entender como suas atividades se relacionam com os diferentes graus e manifestações do transtorno. Entre os biomarcadores que podem ser explorados, as características dos sinais de EEG, como séries temporais e aspectos não lineares, mostram-se promissoras. Por exemplo, a análise de padrões de sincronização entre regiões cerebrais pode revelar disfunções de conectividade em indivíduos com TEA. Além disso, medidas não lineares, como a entropia, que avalia a aleatoriedade nos sinais de EEG, podem diferenciar indivíduos com TEA de neurotípicos, uma vez que esses indivíduos frequentemente apresentam padrões de atividade cerebral mais caóticos. A análise da dimensão fractal e da variabilidade da frequência também pode ajudar a capturar nuances nas séries temporais e nos aspectos não lineares dos sinais cerebrais. Essa abordagem integrada poderá permitir uma compreensão mais abrangente das características neurofisiológicas associadas ao TEA.

Sugere-se também o desenvolvimento de um dispositivo de EEG no formato de uma tiara, focando nas regiões de interesse, frontotemporal e frontal. Um design lúdico e colorido facilitaria a aceitação por crianças, especialmente no diagnóstico precoce, e tornaria a coleta de dados mais simples e confortável. Futuras pesquisas também poderão explorar quais atributos dos sinais de EEG são mais relevantes para o diagnóstico e testar outros modelos de aprendizado de máquina, visando otimizar o desempenho das classificações.

Por fim, a combinação de diferentes modalidades de dados pode ser uma abordagem promissora. Além do EEG, a integração de outros tipos de sinais, como dados comportamentais, de imagem e rastreamento ocular, poderá fornecer uma análise mais completa e rica do TEA.

Referências

ABDULHAY, E. *et al.* Emd-based analysis of complexity with dissociated eeg amplitude and frequency information: a data-driven robust tool-for autism diagnosis-compared to multi-scale entropy approach. **Mathematical Biosciences and Engineering**, v. 19, n. 5, p. 5031–5054, 2022.

ABDULHAY, E. *et al.* A 64-channel scheme for autism detection via scaled conjugate gradient-based neural network classification of electroencephalogram ripples' complexity. **Expert Systems**, Wiley Online Library, v. 40, n. 4, p. e13000, 2023.

ABUBAKAR, A.; KIPKEMOI, P. Early intervention in autism spectrum disorder: The need for an international approach. **Developmental medicine and child neurology**, v. 64, p. 1051–1058, 2022.

AKILA, N. *et al.* A review of human graphology analysis and brainwaves. **IOP Conference Series: Materials Science and Engineering**, v. 917, 2020.

ALI, N. A. *et al.* Convnet bilstm for asd classification on eeg brain signal. **International Journal of Online & Biomedical Engineering**, v. 18, n. 11, 2022.

ALVI, A. M.; SIULY, S.; WANG, H. Neurological abnormality detection from electroencephalography data: a review. **Artificial Intelligence Review**, v. 55, p. 2275–2312, 2021.

ALVI, A. M.; SIULY, S.; WANG, H. Neurological abnormality detection from electroencephalography data: a review. **Artificial Intelligence Review**, Springer, v. 55, n. 3, p. 2275–2312, 2022.

ANDERSON, M. L.; KINNISON, J.; PESSOA, L. Describing functional diversity of brain regions and brain networks. **NeuroImage**, v. 73, p. 50–58, 2013.

ARARIPE, B. L. *et al.* Profile of service use and barriers to access to care among brazilian children and adolescents with autism spectrum disorders. **Brain Sciences**, v. 12, 2022.

ASLAM, A. R. *et al.* An 8.62 w processor for autism spectrum disorder classification using shallow neural network. In: **2021 IEEE 3rd International Conference on Artificial Intelligence Circuits and Systems (AICAS)**. [S.l.: s.n.], 2021. p. 1–4.

ASSOCIATION, A. P. *et al.* **Manual diagnóstico e estatístico de transtornos mentais**. [S.l.: s.n.], 2002. 880–880 p.

ATTAR, E. T. A review of mental stress and eeg band power. **International Journal of Nanotechnology and Nanomedicine**, 2022.

- BAJESTANI, G. S. *et al.* Diagnosis of autism spectrum disorder based on complex network features. **Computer methods and programs in biomedicine**, v. 177, p. 277–283, 2019.
- BARBOSA, V. A. de F. *et al.* Heg. ia: An intelligent system to support diagnosis of covid-19 based on blood tests. **Research on Biomedical Engineering**, Springer, p. 1–18, 2021.
- BARROS, J. V. d. **Uso de dados administrativos hospitalares para o desenvolvimento de modelos preditivos de readmissão hospitalar não planejadas de pacientes idosos em um hospital público terciário na cidade de São Paulo, Brasil.** Tese (Doutorado) — Universidade de São Paulo, 2023.
- BERNSTEIN, A.; BURNAEV, E. V. Reinforcement learning in computer vision. In: SPIE. **Tenth International Conference on Machine Vision (ICMV 2017)**. [S.l.], 2018. v. 10696, p. 458–464.
- BIVARCHI, F. A.; KEHYAYAN, V.; AL-KOHJI, S. M. Barriers to the early detection and intervention of children with autism spectrum disorders: A literature. **Journal of Nursing Education and Practice**, v. 11, n. 11, p. 72–80, 2021.
- BLINOWSKA, K.; DURKA, P. Electroencephalography (eeg). **Wiley encyclopedia of biomedical engineering**, Citeseer, v. 10, p. 9780471740360, 2006.
- BLUDAU, S. *et al.* Cytoarchitecture, probability maps and functions of the human frontal pole. **NeuroImage**, v. 93, p. 260–275, 2014.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, p. 5–32, 2001.
- CATANI, M. *et al.* Short frontal lobe connections of the human brain. **Cortex**, v. 48, p. 273–291, 2012.
- CHEN, H.; GAOXIANG, O.; LI, X. Extracting temporal-spectral-spatial representation of eeg using self-supervised learning for the identification of children with asd. In: IEEE. **2023 IEEE 13th International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)**. [S.l.], 2023. p. 1263–1266.
- CHIANG, H.-M.; WINEMAN, I. Factors associated with quality of life in individuals with autism spectrum disorders: A review of literature. **Research in Autism Spectrum Disorders**, v. 8, p. 974–986, 2014.
- CHOU, K. *et al.* Quality improvement in neurology. **Neurology**, v. 97, p. 239 – 245, 2021.
- CHOUDHARY, R.; GIANEY, H. K. Comprehensive review on supervised machine learning algorithms. In: IEEE. **2017 International Conference on Machine Learning and Data Science (MLDS)**. [S.l.], 2017. p. 37–43.
- CULHAM, J.; VALYEAR, K. F. Human parietal cortex in action. **Current Opinion in Neurobiology**, v. 16, p. 205–212, 2006.
- DAS, R. K. *et al.* A survey on eeg data analysis software. **Sci**, MDPI, v. 5, n. 2, p. 23, 2023.
- DELORME, A.; MAKEIG, S. Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. **Journal of neuroscience methods**, Elsevier, v. 134, n. 1, p. 9–21, 2004.

- DIAS, V. M.; CLÁUDIA, A. Diagnostic practices of autism spectrum disorders in brazil. 2019.
- DICKINSON, A.; JESTE, S.; MILNE, E. Electrophysiological signatures of brain aging in autism spectrum disorder. **Cortex**, v. 148, p. 139–151, 2022.
- DIN, Q. Mohi-ud; JAYANTHY, A. Detection of autism spectrum disorder from eeg signals using pre-trained deep convolution neural networks. In: IEEE. **2021 Seventh International conference on Bio Signals, Images, and Instrumentation (ICBSII)**. [S.l.], 2021. p. 1–5.
- DIN, Q. Mohi ud; JAYANTHY, A. Detection of autism spectrum disorder by feature extraction of eeg signals and machine learning classifiers. **Biomedical Engineering: Applications, Basis and Communications**, World Scientific, v. 35, n. 01, p. 2250046, 2023.
- DUPONT, P. *et al.* The kinetic occipital region in human visual cortex. **Cerebral cortex**, v. 7 3, p. 283–92, 1997.
- EATON, J. W. *et al.* **GNU Octave version 8.4.0 manual: a high-level interactive language for numerical computations**. [s.n.], 2023. Disponível em: <<https://octave.org/doc/v8.4.0/>>.
- EIBE, F. *et al.* The weka workbench. **Online appendix for data mining: practical machine learning tools and techniques**, Morgan Kaufmann Publishers Inc. San Francisco, CA, USA, v. 4, 2016.
- ELDER, J. *et al.* Clinical impact of early diagnosis of autism on the prognosis and parent–child relationships. **Psychology Research and Behavior Management**, v. 10, p. 283–292, 2017.
- ELSABBAGH, M. *et al.* Global prevalence of autism and other pervasive developmental disorders. **Autism research**, Wiley Online Library, v. 5, n. 3, p. 160–179, 2012.
- ESPINOLA, C. W. *et al.* Detection of major depressive disorder using vocal acoustic analysis and machine learning—an exploratory study. **Research on Biomedical Engineering**, Springer, v. 37, p. 53–64, 2021.
- ESPINOLA, C. W. *et al.* Vocal acoustic analysis and machine learning for the identification of schizophrenia. **Research on Biomedical Engineering**, Springer, v. 37, p. 33–46, 2021.
- FARRENS, J. L. *et al.* **Electroencephalogram (EEG) recording protocol for cognitive and affective human neuroscience research**. [S.l.: s.n.], 2021.
- FLUMERI, G. D. *et al.* The dry revolution: Evaluation of three different eeg dry electrode types in terms of signal spectral features, mental states classification and usability. **Sensors (Basel, Switzerland)**, v. 19, 2019.
- FONSECA, F. S. *et al.* Early prediction of generalized infection in intensive care units from clinical data: a committee-based machine learning approach. In: IEEE. **2022 IEEE Latin American Conference on Computational Intelligence (LA-CCI)**. [S.l.], 2022. p. 1–6.
- GARDNER, L. M. *et al.* Correlates of dsm-5 autism spectrum disorder levels of support ratings in a clinical sample. **Journal of Autism and Developmental Disorders**, v. 48, p. 3513–3523, 2018.
- GARETH, J. *et al.* **An introduction to statistical learning: with applications in R**. [S.l.]: Springer, 2013.

- GOMES, J. C. *et al.* Ikonos: an intelligent tool to support diagnosis of covid-19 by texture analysis of x-ray images. **Research on Biomedical Engineering**, Springer, p. 1–14, 2020.
- GOMES, J. C. *et al.* Machine learning for detection and classification of motor imagery in electroencephalographic signals. In: **Biomedical Signal Processing**. [S.l.]: CRC Press, 2023. p. 149–171.
- GOPU, G.; NEELAVENI, R.; KARANTHARAJ, P. Analysis of egg signals for digestive system disorders using neural networks. p. 101–104, 2009.
- GOTTLIEB, J.; SNYDER, L. Spatial and non-spatial functions of the parietal cortex. **Current Opinion in Neurobiology**, v. 20, p. 731–740, 2010.
- GUPTA, N.; SINGH, G. P. Electroencephalography-based monitors. **Journal of Neuroanaesthesiology and Critical Care**, Thieme Medical and Scientific Publishers Private Ltd., v. 2, n. 03, p. 168–178, 2015.
- HAHN, P. Artificial intelligence and machine learning. **Handchirurgie, Mikrochirurgie, Plastische Chirurgie: Organ der Deutschsprachigen Arbeitsgemeinschaft für Handchirurgie: Organ der Deutschsprachigen Arbeitsgemeinschaft für Mikrochirurgie der Peripheren Nerven und Gefässe: Organ der V...**, v. 51, n. 1, p. 62–67, 2019.
- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001.
- HEINSFELD, A. S. *et al.* Identification of autism spectrum disorder using deep learning and the abide dataset. **NeuroImage: Clinical**, Elsevier, v. 17, p. 16–23, 2018.
- HIRATA, K. S. *et al.* Differences in frontotemporal dysfunction during social and non-social cognition tasks between patients with autism spectrum disorder and schizophrenia. **Scientific Reports**, v. 8, 2018.
- HUS, Y.; SEGAL, O. Challenges surrounding the diagnosis of autism in children. **Neuropsychiatric Disease and Treatment**, v. 17, p. 3509–3529, 2021.
- JHAVERI, R. *et al.* A review on machine learning strategies for real-world engineering applications. **Mobile Information Systems**, 2022.
- JIANG, T.; GRADUS, J. L.; ROSELLINI, A. J. Supervised machine learning: a brief primer. **Behavior therapy**, Elsevier, v. 51, n. 5, p. 675–687, 2020.
- JOSEPH, V. R.; KANG, L. Regression-based inverse distance weighting with applications to computer experiments. **Technometrics**, v. 53, p. 254 – 265, 2011.
- KANSARA, N. *et al.* Enhancing autism spectrum disorder recognition in eeg data through filtering-driven cnn approach. In: IEEE. **2024 IEEE International Conference on Consumer Electronics (ICCE)**. [S.l.], 2024. p. 1–7.
- KHODATARS, M. *et al.* Deep learning for neuroimaging-based diagnosis and rehabilitation of autism spectrum disorder: a review. **Computers in Biology and Medicine**, Elsevier, v. 139, p. 104949, 2021.
- KONG, X.; LI, J.; OUYANG, G. Eeg microstate analysis for diagnosis of children with asd. In: IEEE. **2023 42nd Chinese Control Conference (CCC)**. [S.l.], 2023. p. 3390–3395.

- KOVÁCS, Z. L. **Redes neurais artificiais**. [S.l.]: Editora Livraria da Física, 2006.
- KULAGE, K. M.; SMALDONE, A. M.; COHN, E. G. How will dsm-5 affect autism diagnosis? a systematic literature review and meta-analysis. **Journal of autism and developmental disorders**, Springer, v. 44, p. 1918–1932, 2014.
- LARGET, B. Logistic regression. **Exploring Concepts of Child Well-being**, 2008.
- LIU, J. *et al.* A novel dry-contact electrode for measuring electroencephalography signals. **Sensors and Actuators A: Physical**, Elsevier, v. 294, p. 73–80, 2019.
- LORD, C. *et al.* Autism spectrum disorder. **Nature Reviews Disease Primers**, v. 6, p. 1–23, 2020.
- LORD, C. *et al.* Autism spectrum disorder. **The lancet**, Elsevier, v. 392, n. 10146, p. 508–520, 2018.
- LOUBERSAC, J. *et al.* Predictors of an earlier diagnosis of autism spectrum disorder in children and adolescents: a systematic review (1987–2017). **European Child & Adolescent Psychiatry**, v. 32, p. 375–393, 2021.
- MACHADO, G. A. *et al.* Aprendizado não supervisionado para o mapeamento do comportamento temporal de sinais cerebrais em epilepsia. **Tekhne e Logos**, v. 12, n. 1, p. 116–129, 2021.
- MAENNER, M. J. *et al.* Prevalence of autism spectrum disorder among children aged 8 years – autism and developmental disabilities monitoring network, 11 sites, united states, 2016. **Morbidity and Mortality Weekly Report**, v. 70, n. 11, p. 1–12, 2021.
- MAESTRO, S. *et al.* Course of autism signs in the first year of life. **Psychopathology**, v. 38, p. 26–31, 2005.
- MAHAJAN, S. Reinforcement learning: A review from a machine learning perspective. **International Journal**, v. 4, n. 8, 2014.
- MAOR, E. The pythagorean theorem: A 4,000-year history. **Statistics and Computing**, Princeton University Press, 2019.
- MARCUS, E. M.; JACOBSON, S. An overview of the central nervous system. In: . [s.n.], 2003. Disponível em: <<https://api.semanticscholar.org/CorpusID:81162446>>.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943.
- MCLANE, H. C. *et al.* Availability, accessibility, and affordability of neurodiagnostic tests in 37 countries. **Neurology**, AAN Enterprises, v. 85, n. 18, p. 1614–1622, 2015.
- MELINDA, M. *et al.* Classification of eeg signal using independent component analysis and discrete wavelet transform based on linear discriminant analysis. **JOIV: International Journal on Informatics Visualization**, v. 7, n. 3, p. 830–838, 2023.
- MENAKA, R. *et al.* An improved alexnet model and cepstral coefficient-based classification of autism using eeg. **Clinical EEG and Neuroscience**, SAGE Publications Sage CA: Los Angeles, CA, v. 55, n. 1, p. 43–51, 2024.

- MOLINI-AVEJONAS, D.; MANDAJ, V. Psychosocial care network for children with autism spectrum disorder in brazil. **European Psychiatry**, v. 64, p. S218–S218, 2021.
- NAPOLITANO, A. *et al.* Sex differences in autism spectrum disorder: Diagnostic, neurobiological, and behavioral features. **Frontiers in Psychiatry**, v. 13, 2022.
- NAQA, I. E.; MURPHY, M. J. **What is machine learning?** [S.l.]: Springer, 2015.
- NAYDENOV, K.; YORDANOVA, A.; MANCHEVA, V. Methodology for eeg and reference values of the software analysis. **Open Access Macedonian Journal of Medical Sciences**, 2022.
- NG, C. R. *et al.* Multi-center evaluation of gel-based and dry multipin eeg caps. **Sensors (Basel, Switzerland)**, v. 22, 2022.
- OH, S. L. *et al.* A novel automated autism spectrum disorder detection system. **Complex & Intelligent Systems**, Springer, v. 7, n. 5, p. 2399–2413, 2021.
- OLIVER, E. *et al.* **The Software Architecture of the GIMP**. [S.l.]: Citeseer, 2006.
- PALEJWALA, A. H. *et al.* Anatomy and white matter connections of the lingual gyrus and cuneus. **World neurosurgery**, 2021.
- PARELLADA, M. *et al.* The neurobiology of autism spectrum disorders. **European Psychiatry**, v. 29, p. 11–19, 2014.
- PASZKIEL, S. Data acquisition methods for human brain activity. **Analysis and Classification of EEG Signals for Brain–Computer Interfaces**, 2019.
- PENG, S. *et al.* Early screening of children with autism spectrum disorder based on electroencephalogram signal feature selection with l1-norm regularization. **Frontiers in Human Neuroscience**, Frontiers Media SA, v. 15, p. 656578, 2021.
- PEREIRA, J. M. *et al.* Feature selection based on dialectics to support breast cancer diagnosis using thermographic images. **Research on Biomedical Engineering**, Springer, v. 37, p. 485–506, 2021.
- PINHEIRO, R. F. **O problema de Lurie e aplicações às redes neurais**. Tese (Doutorado) — Universidade de São Paulo, 2014.
- PRODANOV, M. *et al.* Software module for processing eeg signals in a biofeedback based system. In: IEEE. **2018 Zooming Innovation in Consumer Technologies Conference (ZINC)**. [S.l.], 2018. p. 158–161.
- QUINLAN, J. R. Generating production rules from decision trees. In: CITeseer. **ijcai**. [S.l.], 1987. v. 87, p. 304–307.
- RADHAKRISHNAN, M.; BORUAH, S.; RAMAMURTHY, K. Eeg-based anomaly detection for autistic kids-a pilot study. **Traitement du Signal**, v. 39, n. 3, 2022.
- RANA, A. Q. *et al.* Neurophysiology in clinical practice. Springer, 2017.
- RECHAL, T. R.; KUMAR, P. R.; KHALEELULLA, S. E. A feasibility approach in diagnosing asd with pie via machine learning classification approach using bci. In: IEEE. **2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)**. [S.l.], 2021. p. 557–562.

- RICE, G. *et al.* The roles of left versus right anterior temporal lobes in semantic memory: A neuropsychological comparison of postsurgical temporal lobe epilepsy patients. **Cerebral Cortex (New York, NY)**, v. 28, p. 1487 – 1501, 2018.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain [j]. **Psychological review**, v. 65, n. 6, p. 386–408, 1958.
- ROSSUM, G. V.; DRAKE, F. L. **Python 3 Reference Manual**. Scotts Valley, CA: CreateSpace, 2009. ISBN 1441412697.
- SANABRIA-BARRADAS, B.; SANEI, S.; GRANADOS-RAMOS, D. E. A hybrid tensor factorization-singular spectrum analysis approach for erp-based assessment of autism in children. In: IEEE. **2022 30th European Signal Processing Conference (EUSIPCO)**. [S.l.], 2022. p. 1193–1197.
- SANTANA, M. A. *et al.* Emotion recognition from electroencephalographic and peripheral physiological signals using artificial intelligence with explicit features. In: **Biomedical Signal Processing**. [S.l.]: CRC Press, 2022. p. 172–197.
- SANTANA, M. A. de *et al.* Emotion recognition from multimodal data: a machine learning approach combining classical and hybrid deep architectures. **Research on Biomedical Engineering**, v. 39, p. 613–639, 2023.
- SANTANA, M. A. de *et al.* Emotion recognition from multimodal data: a machine learning approach combining classical and hybrid deep architectures. **Research on Biomedical Engineering**, Springer, v. 39, n. 3, p. 613–638, 2023.
- SANTANA, M. A. de *et al.* An intelligent tool to support diagnosis of covid-19 by texture analysis of computerized tomography x-ray images and machine learning. **Assessing COVID-19 and other pandemics and epidemics using computational modelling and data analysis**, Springer, p. 259–282, 2022.
- SARRETT, J. C.; ROMMELFANGER, K. Commentary: Attention to eyes is present but in decline in 2–6-month-old infants later diagnosed with autism. **Frontiers in Public Health**, v. 3, 2015.
- SILVA, A. F. da *et al.* Detection and classification of breast lesions in thermographic images by deep transfer learning hybrid architectures. **Research on Biomedical Engineering**, Springer, p. 1–22, 2024.
- SILVA, A. S. de O. *et al.* Enhancing asd diagnosis with low-density eeg and machine learning. 2024.
- SILVA, C. C. da *et al.* Covid-19 dynamic monitoring and real-time spatio-temporal forecasting. **Frontiers in public health**, Frontiers Media SA, v. 9, p. 641253, 2021.
- SINGH, P. Supervised machine learning. **Learn PySpark: Build Python-Based Machine Learning and Deep Learning Models**, Springer, p. 117–159, 2019.
- SIQUEIRA, B.; PRAZERES, Á.; MAIA, A. The challenges of autism spectrum disorder: from suspicion to diagnosis. **Resid Pediatr [Internet]**, v. 12, n. 1, 2022.
- STUSS, D. Functions of the frontal lobes: Relation to executive functions. **Journal of the International Neuropsychological Society**, v. 17, p. 759 – 765, 2011.

TANNER, A.; DOUNAVI, K. The emergence of autism symptoms prior to 18 months of age: A systematic literature review. **Journal of Autism and Developmental Disorders**, v. 51, p. 973–993, 2020.

TASNIM, N. *et al.* An approach for analyzing cognitive behavior of autism spectrum disorder using p300 bci data. In: IEEE. **2022 IEEE Region 10 Symposium (TENSYP)**. [S.l.], 2022. p. 1–6.

TAWHID, M. N. A. *et al.* A spectrogram image based intelligent technique for automatic detection of autism spectrum disorder from eeg. **Plos one**, Public Library of Science San Francisco, CA USA, v. 16, n. 6, p. e0253094, 2021.

TORRE-UBIETA, L. *et al.* Advancing the understanding of autism disease mechanisms through genetics. **Nature Medicine**, v. 22, p. 345–361, 2016.

VANDEKAR, S. N. *et al.* Topologically dissociable patterns of development of the human cerebral cortex. **Journal of Neuroscience**, Soc Neuroscience, v. 35, n. 2, p. 599–609, 2015.

VERMEULEN, A. F. Unsupervised learning: using unlabeled data. **Industrial Machine Learning: Using Artificial Intelligence as a Transformational Disruptor**, Springer, p. 181–206, 2020.

VOLKMAR, F. R.; REICHOW, B. Autism in dsm-5: progress and challenges. **Molecular autism**, Springer, v. 4, p. 1–6, 2013.

WADHERA, T.; BEDI, J.; SHARMA, S. Autism spectrum disorder prediction using bidirectional stacked gated recurrent unit with time-distributor wrapper: an eeg study. **Neural Computing and Applications**, Springer, v. 35, n. 13, p. 9803–9818, 2023.

WANG, J. *et al.* Global prevalence of autism spectrum disorder and its gastrointestinal symptoms: A systematic review and meta-analysis. **Frontiers in Psychiatry**, v. 13, 2022.

YOON, S. *et al.* Genetic and epigenetic etiology underlying autism spectrum disorder. **Journal of Clinical Medicine**, v. 9, 2020.

ZARIFI, T.; PENG, C.-C.; ZARIFI, M. H. Low-power amplifier for in-vivo eeg signal recording. In: IEEE. **2011 1st Middle East Conference on Biomedical Engineering**. [S.l.], 2011. p. 19–22.

ZWAIGENBAUM, L. *et al.* Stability of diagnostic assessment for autism spectrum disorder between 18 and 36 months in a high-risk cohort. **Autism Research**, v. 9, 2016.