



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS SOBRAL**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO**

**ANTONIA IARA AMANCIO DE SOUSA**

**ANÁLISE DO SINAL DE EEG PARA AUXÍLIO CLÍNICO NA DETECÇÃO DE TDAH  
EM CRIANÇAS**

**SOBRAL**

**2025**

ANTONIA IARA AMANCIO DE SOUSA

ANÁLISE DO SINAL DE EEG PARA AUXÍLIO CLÍNICO NA DETECÇÃO DE TDAH EM  
CRIANÇAS

Trabalho de Conclusão de Curso apresentado  
ao Curso de Graduação em Engenharia de  
Computação do Campus Sobral da Universidade  
Federal do Ceará, como requisito parcial à  
obtenção do grau de bacharel em Engenharia de  
Computação.

Orientador: Prof. Dr. Wendley Souza da  
Silva

SOBRAL

2025

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

A499a Amancio de Sousa, Antonia Iara.  
Análise do sinal de EEG para auxílio clínico na detecção de TDAH em crianças / Antonia Iara Amancio de Sousa. – 2025.  
56 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Sobral, Curso de Engenharia da Computação, Sobral, 2025.  
Orientação: Prof. Dr. Wendley Souza da Silva.

1. TDAH. 2. EEG. 3. SVM. 4. KNN. 5. RF. I. Título.

CDD 621.39

---

ANTONIA IARA AMANCIO DE SOUSA

ANÁLISE DO SINAL DE EEG PARA AUXÍLIO CLÍNICO NA DETECÇÃO DE TDAH EM  
CRIANÇAS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Campus Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Aprovada em: 07 de Agosto de 2025

BANCA EXAMINADORA

---

Prof. Dr. Wendley Souza da Silva (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Me. Erick Aguiar Donato  
Universidade Federal do Ceará (UFC)

---

Prof. Me. David Nascimento Coelho  
Universidade Federal do Ceará (UFC)

Dedico este trabalho à minha família, minha  
base.

## **AGRADECIMENTOS**

Primeiramente, expresso minha gratidão a Deus por ter me dado forças e por ter me guiado até aqui. Agradeço a meu orientador, Professor Dr. Wendley Silva, que esteve disponível para me auxiliar nessa jornada, com conhecimento e também com muito incentivo.

Também agradeço aos amigos de curso Iara Costa, Alan Pires, Gabriel Santiago, Isaac Daniel e Yasmin Gomes, pelo compartilhamento de conhecimento e pelos momentos de descontração.

Por fim, agradeço a minha mãe, minha base, Mazé Amancio e ao meu irmão Sávio Amancio.

Deus nos fez perfeitos e não escolhe os capacitados, capacita os escolhidos.

(Desconhecido)

## RESUMO

O Transtorno do Déficit de Atenção e Hiperatividade (TDAH) é um dos transtornos psiquiátricos mais diagnosticados na infância, afetando significativamente o comportamento e desenvolvimento das crianças. O TDAH não identificado e tratado adequadamente, pode resultar em consequências graves na idade adulta, desde baixo desempenho acadêmico e profissional ao abuso de substâncias. Apesar dos avanços nas pesquisas sobre o tema, o diagnóstico do TDAH ainda apresenta limitações, pois se baseia principalmente na observação de sintomas comportamentais. O eletroencefalograma (EEG) tem se mostrado uma alternativa promissora para a identificação de transtornos mentais, pois permite o monitoramento das ondas cerebrais, fornecendo informações diretas sobre a atividade cognitiva do indivíduo. Neste contexto, este trabalho tem como objetivo analisar a viabilidade do uso auxiliar do EEG na identificação do TDAH em crianças. Para isso, foram aplicadas técnicas de pré-processamento robustas e testadas nos modelos de *machine learning* SVM, KNN e *Random Forest*. Seguindo a metodologia proposta, o presente estudo conclui a superioridade do modelo KNN com 98,91% de acurácia para a classificação das ondas de EEG de crianças com TDAH.

**Palavras-chave:** TDAH; EEG; Aprendizado de máquina; SVM; KNN; RF



## **ABSTRACT**

Attention Deficit Hyperactivity Disorder (ADHD) is one of the most commonly diagnosed psychiatric disorders in childhood, significantly affecting children's behavior and development. If ADHD is not identified and treated appropriately, it can result in serious consequences in adulthood, ranging from poor academic and professional performance to substance abuse. Despite advances in research on the topic, ADHD diagnosis still has limitations, as it relies primarily on the observation of behavioral symptoms. The electroencephalogram (EEG) has proven to be a promising alternative for identifying mental disorders, as it allows for the monitoring of brain waves, providing direct information about an individual's cognitive activity. In this context, this work aims to analyze the feasibility of using EEG to identify ADHD in children. To this end, robust preprocessing techniques were applied and tested using SVM, KNN, and Random Forest machine learning models. Following the proposed methodology, this study concludes the superiority of the KNN model with 98.91% classifying EEG waves of children with ADHD.

**Keywords:** ADHD; EEG; Machine Learning; SVM; KNN; RF

## LISTA DE FIGURAS

Figura 1 – Ondas cerebrais . . . . .	22
Figura 2 – Montagem e representação da vista superior de um EEG. . . . .	23
Figura 3 – Representação do modelo de classificação SVM. . . . .	26
Figura 4 – Representação do modelo de classificação KNN. . . . .	28
Figura 5 – Representação do modelo de classificação RF. . . . .	30
Figura 6 – Etapas da Metodologia. . . . .	34
Figura 7 – Atividade visual utilizada na coleta de Dados . . . . .	35
Figura 8 – Representação da Tabela Verdade. . . . .	42
Figura 9 – Aplicação de filtros no sinal de EEG. . . . .	43

## LISTA DE TABELAS

Tabela 1 – Sintomas característicos de Desatenção e Hiperatividade para o Diagnóstico de Transtorno de Déficit de Atenção e Hiperatividade (TDAH), de acordo com o <i>Diagnostic and Statistical Manual of Mental Disorders, 5ª edition</i> (DSM-5).	19
Tabela 2 – Trabalhos relevantes e suas respectivas metodologias de classificação. . . . .	33
Tabela 3 – Informações sobre os participantes. . . . .	35
Tabela 4 – Quadro comparativo de desempenho dos modelos no treinamento. . . . .	44
Tabela 5 – Quadro comparativo de desempenho dos modelos no treinamento e teste. . .	45
Tabela 6 – Matriz de Confusão do Modelo SVM. . . . .	46
Tabela 7 – Matriz de Confusão do Modelo KNN. . . . .	46
Tabela 8 – Matriz de Confusão do Modelo RF. . . . .	46
Tabela 9 – Top 10 características selecionadas pelo SelectKBest, ordenadas por Score ANOVA. . . . .	47
Tabela 10 – Trabalhos relevantes e suas respectivas metodologias de classificação. . . .	49

## LISTA DE ABREVIATURAS E SIGLAS

CNN	<i>Convolutional Neural Network</i>
DL	<i>Deep Learning</i>
DSM	<i>Diagnostic and Statistical Manual of Mental Disorders</i>
DSM-5	<i>Diagnostic and Statistical Manual of Mental Disorders, 5<sup>a</sup> edition</i>
DSM-5-TR	Diagnostic and Statistical Manual of Mental Disorders, Fifth Edition, Text Revision
DWT	<i>Discrete Wavelet Transform</i>
EEG	Eletroencefalografia
EMD	<i>Empirical Mode Decomposition</i>
FDA	<i>Food and Drug Administration</i>
FFT	<i>Fast Fourier Transform</i>
FN	Falso Negativo
FP	Falso Positivo
Grad-CAM	<i>Gradient-weighted Class Activation Mapping</i>
ICA	<i>Independent Component Analysis</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IMFs	<i>Intrinsic Mode Functions</i>
IRB	<i>Institutional Review Board</i>
IRMf	Imagens de Ressonância Magnética funcional
KNN	<i>K-nearest neighbors</i>
ML	<i>Machine Learning</i>
NEBA	<i>Neuropsychiatric EEG-Based ADHD Assessment Aid</i>
PCA	<i>Principal Component Analysis</i>
RBF	<i>Radial Basis Function</i>
RF	<i>Random Forest</i>
RLMD	Robust Local Mode Decomposition
RM	Ressonância Magnética
RMS	<i>Root Mean Square</i>
SNC	Sistema Nervoso Central
STD	<i>Standard Deviation</i>
SVM	<i>Support Vectors Machine</i>

TBR	<i>Theta/Beta Ratio</i>
TC	Transtorno de Conduta
TDAH	Transtorno de Déficit de Atenção e Hiperatividade
TNDs	Transtornos de Neurodesenvolvimento
VMD	Variational Mode Decomposition
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>15</b>
<b>1.1</b>	<b>Objetivo Geral . . . . .</b>	<b>16</b>
<b>1.2</b>	<b>Objetivos Específicos . . . . .</b>	<b>16</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA . . . . .</b>	<b>17</b>
<b>2.1</b>	<b>Transtorno de Déficit de Atenção e Hiperatividade (TDAH) . . . . .</b>	<b>17</b>
<b>2.2</b>	<b>Neurociência Infantil . . . . .</b>	<b>20</b>
<b>2.3</b>	<b>Eletroencefalografia (EEG) . . . . .</b>	<b>21</b>
<b>2.3.1</b>	<i>Origem dos Sinais . . . . .</i>	<i>21</i>
<b>2.3.2</b>	<i>Bandas de Frequência . . . . .</i>	<i>21</i>
<b>2.3.3</b>	<i>Gravação de EEG . . . . .</i>	<i>22</i>
<b>2.4</b>	<b>Aprendizado de máquina para classificação de EEG . . . . .</b>	<b>23</b>
<b>2.4.1</b>	<i>Processamento de Sinais de EEG . . . . .</i>	<i>24</i>
<b>2.4.2</b>	<i>Classificadores . . . . .</i>	<i>25</i>
<b>2.4.2.1</b>	<i>Support Vector Machines (SVM) . . . . .</i>	<i>26</i>
<b>2.4.2.2</b>	<i>K-Nearest Neighbor (KNN) . . . . .</i>	<i>27</i>
<b>2.4.2.3</b>	<i>Random Forest (RF) . . . . .</i>	<i>29</i>
<b>3</b>	<b>TRABALHOS RELACIONADOS . . . . .</b>	<b>31</b>
<b>3.1</b>	<b>Rede neural profunda baseada em siamês para detecção de TDAH usando sinal de EEG . . . . .</b>	<b>31</b>
<b>3.2</b>	<b>Identificação automática de crianças com TDAH a partir de ondas cere- brais de EEG . . . . .</b>	<b>31</b>
<b>3.3</b>	<b>Detecção de TDAH a partir de sinais de EEG usando novas técnicas de decomposição híbrida e aprendizado profundo . . . . .</b>	<b>32</b>
<b>3.4</b>	<b>Detecção automatizada de transtorno de conduta e transtorno de déficit de atenção e hiperatividade usando técnicas de decomposição e não lineares com sinais de EEG . . . . .</b>	<b>32</b>
<b>4</b>	<b>METODOLOGIA . . . . .</b>	<b>34</b>
<b>4.1</b>	<b>Seleção de Dados . . . . .</b>	<b>35</b>
<b>4.2</b>	<b>Pré-processamento dos dados . . . . .</b>	<b>36</b>
<b>4.2.1</b>	<i>Limpeza de artefatos com EMD e Wavelet Adaptativa . . . . .</i>	<i>36</i>

4.2.2	<i>Segmentação dos dados</i> . . . . .	37
4.3	<b>Extração de características</b> . . . . .	38
4.4	<b>Classificação</b> . . . . .	39
4.5	<b>Métricas de Avaliação</b> . . . . .	40
4.5.1	<i>Acurácia</i> . . . . .	40
4.5.2	<i>Sensibilidade</i> . . . . .	41
4.5.3	<i>Especificidade</i> . . . . .	41
4.5.4	<i>Precisão</i> . . . . .	41
4.5.5	<i>Matriz de confusão</i> . . . . .	41
5	<b>RESULTADOS</b> . . . . .	43
5.1	<b>Resultados experimentais</b> . . . . .	43
5.1.1	<i>Desempenho no conjunto de treinamento</i> . . . . .	44
5.1.2	<i>Desempenho no conjunto de teste</i> . . . . .	45
5.1.3	<i>Matriz de confusão</i> . . . . .	46
5.1.4	<i>Análise das características</i> . . . . .	47
5.2	<b>Análise dos Resultados</b> . . . . .	48
5.2.1	<i>Limitações do estudo</i> . . . . .	49
6	<b>CONCLUSÃO E TRABALHOS FUTUROS</b> . . . . .	50
6.1	<b>Trabalho Futuros</b> . . . . .	50
	<b>REFERÊNCIAS</b> . . . . .	52
	<b>APÊNDICES</b> . . . . .	56
	<b>APÊNDICE A –</b> . . . . .	56
A.1	<b>Código</b> . . . . .	56
	<b>ANEXOS</b> . . . . .	56

## 1 INTRODUÇÃO

O Transtorno de Déficit de Atenção e Hiperatividade (TDAH) é um distúrbio neurodesenvolvimental caracterizado por padrões pertinentes de desatenção, hiperatividade e comportamento impulsivo (AMERICAN PSYCHIATRIC ASSOCIATION, 2013). O TDAH é um dos transtornos psiquiátricos mais comuns entre crianças e adolescentes, com uma taxa de prevalência infantil de 5,29% na população mundial (POLANCZYK *et al.*, 2007). Embora comumente identificado na infância, o TDAH pode trazer, a longo prazo, consequências na vida adulta como dificuldade com relacionamentos pessoais, baixo desempenho acadêmico e profissional, uso e abuso de substâncias e incidência de acidentes e ferimentos não intencionais (KOSHELEFF *et al.*, 2023). Esses impactos evidenciam a importância de um diagnóstico e tratamento precoce.

O TDAH resulta de uma combinação de fatores genéticos, neurológicos e/ou ambientais, assim os sintomas se apresentam de forma heterogênea nos pacientes. Pela ausência de um marcador biológico diagnóstico, a identificação clínica do TDAH é baseada na avaliação dos critérios do *Diagnostic and Statistical Manual of Mental Disorders* (DSM), relatos comportamentais e testes neuropsicológicos. Ademais, o TDAH tem uma relação frequente de comorbidade com outros Transtornos de Neurodesenvolvimento (TNDs), como o Transtorno do espectro autista ou Transtorno específico da aprendizagem, dificultando sua identificação precisa (AMERICAN PSYCHIATRIC ASSOCIATION, 2013).

Apesar de estudos de neuroimagem já identificarem alterações anatômicas e funcionais em regiões cerebrais importantes, como o aumento de ondas lentas por Eletroencefalografia (EEG), e o volume encefálico total reduzido por Ressonância Magnética (RM), essas descobertas ainda não possuem evidências suficientes e comprobatórias para uso diagnóstico, reforçando a necessidade de pesquisas. O EEG, importante fonte de dados para muitos estudos da neurociência, tem ganhado destaque devido a natureza não invasiva, custo-benefício e segurança. Por meio de eletrodos posicionados no couro cabeludo, o EEG mostra a atividade elétrica cerebral do indivíduo, ajudando na compreensão de aspectos relacionados à cognição e ao comportamento humano, usada por exemplo no diagnóstico de doenças neurológicas como Epilepsia e doença de Alzheimer (CORSI, 2023).

A atual expansão e acessibilidade aos modelos de aprendizado de máquina trouxe o uso crescente dos mesmos na aplicação para fim investigativo de transtornos mentais, bem como o TDAH (UDDIN *et al.*, 2019). Os algoritmos de aprendizado de máquina são capazes de detectar interações complexas e padrões entre múltiplas variáveis com mais facilidade, velocidade e



precisão do que os métodos estatísticos tradicionais. Os padrões detectados podem ser usados para predição em um novo conjunto de dados, podendo situar a qual grupo um novo dado pertence, além de destacar quais variáveis são mais impactantes na criação dessa predição (HARRISON *et al.*, 2023).

Diante dos desafios clínicos para o diagnóstico objetivo do TDAH, este trabalho propõe uma abordagem baseada no uso de aprendizado de máquina para auxiliar de forma automatizada esse processo. Sabendo que diversos fatores influenciam o desempenho de modelos classificadores, como a qualidade do conjunto de dados, as técnicas de pré-processamento e os métodos de extração de características, este estudo busca aplicar técnicas de *machine learning*, analisar os resultados obtidos e compará-los com a literatura. A finalidade é testar e avaliar alternativas que possam aprimorar a precisão dos modelos, contribuindo para avanços na área e promovendo soluções mais eficazes para a identificação do transtorno.

## **1.1 Objetivo Geral**

Este estudo tem como objetivo utilizar novas abordagens de técnicas de aprendizado de máquina já existentes, em busca de aprimorá-los para avaliar a eficácia da análise de sinais de EEG na detecção de TDAH em crianças.

## **1.2 Objetivos Específicos**

- a) Investigar as características do EEG que podem indicar a presença de TDAH.
- b) Avaliar a contribuição do EEG para compreensão do diagnóstico de TDAH.
- c) Avaliar a combinação de métodos de pré-processamento e técnicas de classificação para análise de EEG.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, será reforçada a importância da identificação precoce do TDAH, do uso de exames de EEG como ferramenta de análise do TDAH e da aplicação de *Machine Learning* (ML) com finalidade classificatória. Nas seções 2.1 e 2.2, serão abordados tópicos sobre a definição do TDAH, sua identificação, causas e tratamento. Na seção 2.3 será explicado o funcionamento dos estudos com ondas obtidas por meio do EEG. Por fim, na seção 2.4, será apresentado o uso de ML na classificação de dados.

### 2.1 Transtorno de Déficit de Atenção e Hiperatividade (TDAH)

O (TDAH) é um transtorno do neurodesenvolvimento caracterizado por padrões persistentes de desatenção e hiperatividade/impulsividade, que prejudicam o funcionamento, e o desenvolvimento do sujeito quando criança (AMERICAN PSYCHIATRIC ASSOCIATION, 2013). Assim como outros TNDs, o TDAH resulta de um desenvolvimento neural atípico, afetando processos cerebrais desde as primeiras fases da formação embrionária (ABDELNOUR *et al.*, 2022).

O TDAH começou a ser descrito em publicações científicas em 1957, inicialmente denominado *transtorno do impulso hipercinético*. Naquela época, o termo era utilizado de forma genérica e precipitada para designar crianças com comportamentos inquietos e impulsivos, frequentemente rotuladas como “imperfeitas”. Atualmente, o TDAH é amplamente reconhecido e estudado, especialmente após sua inclusão no Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-5), principal referência para as diretrizes diagnósticas de transtornos mentais. Além disso, pesquisas evidenciam que a prevalência global do TDAH é de aproximadamente 5,29%, o que destaca seu caráter universal, com variações nas taxas explicadas por diferenças metodológicas nos critérios diagnósticos (SMITH, 2017).

Há três subtipos do transtorno: apresentação predominantemente desatento, apresentação predominantemente hiperativo-impulsivo e apresentação combinada. A desatenção é caracterizada por distração, incapacidade de permanecer em tarefas e desorganização. A hiperatividade é reconhecida por inquietação constante e sem controle, incapacidade de aguardar e manter-se sentado. E por último a impulsividade, designada por ações repentinas, inesperadas e sem planejamento. Sintomas esses que são incomuns para a idade ou o nível de desenvolvimento do paciente (AMERICAN PSYCHIATRIC ASSOCIATION, 2013).

A etiologia do TDAH é resultado de uma combinação de fatores ambientais, neurobiológicos e genéticos. Por exemplo, influência nas condições pré-concepcionais, gestacionais e perinatais, como nascimento pré-maturo, nutrição da mãe grávida, exposição a metais pesados durante o desenvolvimento infantil, além de problemas relacionados ao sono estão associadas ao TDAH. Os pacientes não apresentam as mesmas alterações neurofisiológicas, e os sintomas do TDAH no indivíduo são variáveis ao longo do tempo (ABDELNOUR *et al.*, 2022). Além disso, há situações frequentes de condições comórbidas de neurodesenvolvimento. Por exemplo, muitas crianças com TDAH apresentam também um transtorno específico da aprendizagem, dificultando ainda mais a identificação do transtorno (AMERICAN PSYCHIATRIC ASSOCIATION, 2013).

Atualmente, os profissionais de saúde estão utilizando o DSM-5, em sua 5ª edição (2013), e o Diagnostic and Statistical Manual of Mental Disorders, Fifth Edition, Text Revision (DSM-5-TR) (2022) para suas diretrizes. O diagnóstico clínico do TDAH, é realizado por meio de coletas de informações e avaliações detalhadas do paciente. Os neurologistas/neuropediatras utilizam escalas de classificação validadas pelos pais, professores ou pessoas do convívio com a criança, que avaliam o comportamento do paciente em situações cotidianas e em vários ambientes. Já no caso de adultos e adolescentes, o auto-relato é utilizado como referência para o diagnóstico (FELDMAN; REIFF, 2014; FIRST *et al.*, 2022; AMERICAN PSYCHIATRIC ASSOCIATION, 2013).

Os critérios do DSM-5 são válidos quando a criança apresenta seis ou mais dos nove sintomas estabelecidos característicos de desatenção para diagnóstico predominantemente desatento, ou seis ou mais dos nove sintomas de hiperatividade-impulsividade para diagnóstico predominante hiperativo-impulsivo, mostrados na Tabela 1. A apresentação combinada é determinada quando são atendidos ambos os critérios. Já para jovens e adultos pelo menos cinco desses sintomas são suficientes para identificação do transtorno. Vários desses indícios qualificantes devem estar evidentes com idade máxima para início aos 12 anos, e observados em mais de um ambiente há pelo menos 6 meses, seja casa, escola, trabalho, amigos e parentes entre outros (AMERICAN PSYCHIATRIC ASSOCIATION, 2013).

Tabela 1 – Sintomas característicos de Desatenção e Hiperatividade para o Diagnóstico de TDAH, de acordo com o DSM-5.

Sintomas		
Item	Desatenção	Hiperatividade
1	Frequentemente não presta atenção a detalhes ou comete erros por descuido.	Mexe as mãos ou os pés ou se remexe na cadeira.
2	Dificuldade em manter a atenção em tarefas ou atividades recreativas.	Levanta-se em situações em que se espera que permaneça sentado.
3	Parece não escutar quando se fala diretamente com ele/ela.	Corre ou sobe em móveis em situações inadequadas (em adultos, pode haver sensação de inquietação).
4	Não segue instruções e não consegue terminar tarefas escolares, domésticas ou de trabalho.	É incapaz de brincar ou se envolver silenciosamente em atividades recreativas.
5	Tem dificuldade em organizar tarefas e atividades.	Parece estar "sempre em movimento", agindo como se estivesse "a todo vapor".
6	Evita, não gosta ou reluta em envolver-se em tarefas que exigem esforço mental contínuo.	Fala excessivamente.
7	Perde objetos necessários para tarefas ou atividades.	Responde precipitadamente antes que as perguntas sejam concluídas.
8	Distrai-se facilmente com estímulos externos.	Tem dificuldade para esperar a sua vez.
9	Esquece-se de compromissos ou tarefas diárias.	Interrompe ou se intromete nas conversas ou atividades dos outros.

**Fonte:** Adaptado do *DSM-5, 2013*.

É necessário levar em consideração outros fatores do histórico social do paciente, tais como conflitos familiares, *bullying*, privação de sono, sequelas de trauma, etc. Por exemplo, mudanças frequentes de escola podem causar problemas acadêmicos que podem ser confundidos com TDAH (AUSTERMAN, 2015). O TDAH frequentemente se apresenta com outras condições comórbidas, principalmente distúrbios de aprendizagem e linguagem, comportamento oposicional e distúrbio de conduta. O TDAH também pode acompanhar o autismo, a síndrome do X frágil, epilepsia e lesão cerebral traumática. O processo de diagnóstico deve identificar quaisquer condições coexistentes para um diagnóstico assertivo (FELDMAN; REIFF, 2014).

O tratamento do TDAH envolve a combinação de medicamentos e terapia comportamental. O uso de estimulantes como anfetaminas e metilfenidato, tem se mostrado eficaz, apresentando resultados comprovados e eficácia em até 70% dos casos. No entanto, esses medi-

camentos podem causar efeitos colaterais, como insônia e anorexia, como é visto em até 15% dos pacientes (AUSTERMAN, 2015). É importante ressaltar que por ser uma doença crônica, esses tratamentos são temporários e não curam o TDAH. Assim, a compreensão dos mecanismos neurológicos do TDAH é fundamental para o desenvolvimento de abordagens terapêuticas mais eficazes, o que será explorado na próxima seção.

## 2.2 Neurociência Infantil

A Neurociência é a área de estudo que investiga a estrutura e a função do sistema nervoso, com ênfase no cérebro. A resposta nervosa, fenômeno central da neurociência, refere-se aos sinais elétricos e químicos que ocorrem no cérebro e no sistema nervoso. Esses sinais são a base de funções cognitivas como pensamento, memória, atenção e emoção, permitindo a compreensão e identificação de distúrbios neurológicos, além de contribuir para diagnósticos e tratamentos mais eficientes (ZHANG *et al.*, 2023).

A neuroplasticidade, um dos principais objetos de estudo da neurociência, refere-se à capacidade do Sistema Nervoso Central (SNC) de se adaptar e modificar em resposta a experiências, mudanças estruturais e funcionais ou mesmo lesões. Esse processo ocorre com maior intensidade durante o desenvolvimento cerebral (períodos pré e pós-natal), mas persiste, em menor grau, ao longo da adolescência e da vida adulta. O cérebro infantil apresenta maior plasticidade do que o cérebro adulto, tornando as intervenções na infância potencialmente mais eficazes, pois o sistema nervoso está mais predisposto à formação de novas conexões (ISMAIL *et al.*, 2017). Isso enfatiza a importância da realização precoce de estudos e exames, aumentando as chances de eficácia dos tratamentos.

Padrões anormais de neuroplasticidade são reconhecidos como fatores centrais em distúrbios pediátricos, tanto congênitos quanto adquiridos, que afetam o SNC, como o TDAH. Por exemplo, estudos com EEG indicam que indivíduos com TDAH tendem a apresentar um aumento da atividade de ondas lentas theta (4–7 Hz) e uma redução das ondas rápidas beta (13–21 Hz), conhecida como razão theta/beta ou *Theta/Beta Ratio* (TBR) (CORTESE, 2012).

Essa razão foi utilizada como base para o desenvolvimento do dispositivo *Neuropsychiatric EEG-Based ADHD Assessment Aid* (NEBA), aprovado pela *Food and Drug Administration* (FDA) em 2013 para auxiliar no diagnóstico do TDAH. Entretanto, conforme apontado por Arns Martijn e Loo (2016), há incertezas quanto à utilidade clínica do dispositivo, o que levanta questionamentos sobre sua eficácia e reforça a necessidade de embasamento empírico

sólido antes da comercialização de tecnologias diagnósticas.

Dentre as ferramentas de neuroimagem utilizadas para explorar a função cerebral, o (EEG) destaca-se por sua alta resolução temporal e pelo baixo custo dos equipamentos, tornando-se uma técnica amplamente empregada, como será discutido na próxima seção (ZHANG *et al.*, 2023).

### **2.3 Eletroencefalografia (EEG)**

O (EEG) é um método não invasivo de medição das oscilações elétricas do cérebro. O primeiro registro dessa atividade foi mostrado por Hans Berger em 1929, ao demonstrar que eletrodos em contato com o couro cabeludo, com amplificação do sinal, mostravam mudanças nas tensões resultantes da atividade elétrica no cérebro, e que podiam ser plotadas e medidas (READ; INNIS, 2017). Essas oscilações, provenientes da camada externa do cérebro, é associada aos nossos pensamentos, comportamentos e emoções. Dessa forma, o EEG revela a ação sináptica que está relacionada ao estado cerebral do indivíduo (NUNEZ; SRINIVASAN, 2007).

#### **2.3.1 Origem dos Sinais**

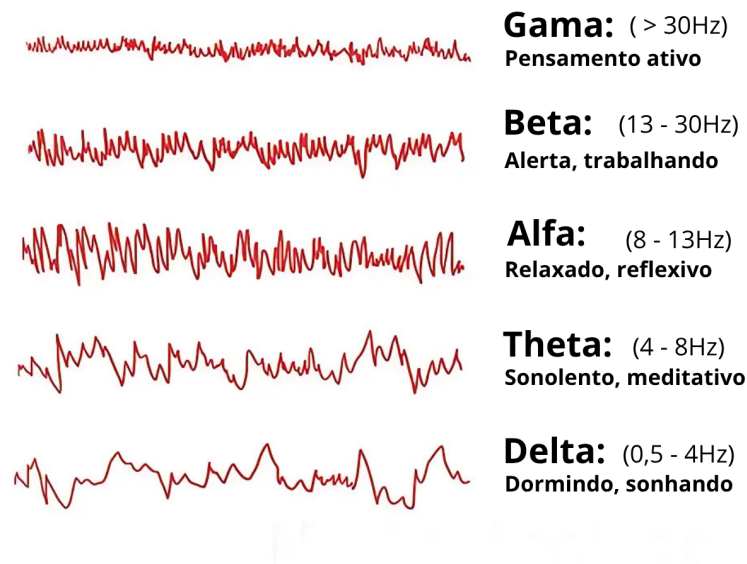
O EEG mede a atividade que acontece quando os neurônios se comunicam entre si. Quando um neurônio envia uma mensagem, ele gera um pequeno impulso elétrico que passa pelo seu "fio"(o axônio), até alcançar outro neurônio. Nesse ponto de encontro, chamado *sinapse*, ele libera substâncias químicas chamadas neurotransmissores. Esses produtos químicos fazem com que o próximo neurônio também gere sinais elétricos. Esses sinais criam pequenas correntes elétricas ao redor dos neurônios. Como a parte de fora da célula é onde a eletricidade se move mais livremente, é isso que o EEG consegue registrar, as correntes que passam por fora das células, indo do cérebro até os sensores colocados na cabeça (CORSI, 2023).

#### **2.3.2 Bandas de Frequência**

As atividades eletrofisiológicas são classificadas por faixa de frequência, como mostrado na Figura 1. As ondas cerebrais são divididas em Delta (0,5 - 3Hz), correspondente a sono profundo, Theta (4 - 8Hz), relaxamento ou estado de sonolência, Alfa (8 - 13Hz) repouso ou olhos fechados, Beta (18 - 30 Hz), estado de vigília ativa e atividades cognitivas com planejamento ou imaginação motora, e *Gama* (30 - 70 Hz ou mais), processamento cognitivo de

alta complexidade, como percepção e atenção.

Figura 1 – Ondas cerebrais



Fonte: Adaptado de Electrical e-Library (2019).


### 2.3.3 Gravação de EEG

Os materiais utilizados para a gravação das ondas cerebrais, são não polarizados como prata/cloreto de prata ou ouro, evitando alterações nos sinais elétricos captados. A superfície de contato é um disco com forma de concha de até 10 mm de diâmetro, preenchido com pasta eletrolítica e um gel condutor para melhorar a condução elétrica e reduzir a resistência. O potencial do eletrodo, é devido a polaridade oposta da superfície metálica do eletrodo e a pasta eletrolítica, devido o fluxo em equilíbrio dos íons. Assim, quando há uma diferença de tensão entre os eletrodos, uma corrente flui entre o tecido biológico ao redor e o eletrodo (BENICZKY; SCHOMER, 2020).

Os eletrodos ou canais de EEG são nomeados de acordo com a sua localização em comparação com a linha média da cabeça e sua distância da testa ou da parte de trás da cabeça, e identificados por uma letra e número. Geralmente os canais ímpares ficam localizados no hemisfério esquerdo e os pares no hemisfério direito. As letras correspondem a área: fronto-polar (Fp), frontal (F), temporal (T), parietal (P), central (C) e occipital (O), já os eletrodos A1 e A2 estão como referências nos lóbulos das orelhas.(SCHAUL, 1998). Na Figura 2 vemos um

exemplo de montagem de EEG, onde cada círculo representa um sensor com sua identificação.

Figura 2 – Montagem e representação da vista superior de um EEG.



Fonte: Marina Pousheva / Shutterstock.

## 2.4 Aprendizado de máquina para classificação de EEG

Os algoritmos de ML surgiram em torno das décadas de 1940 e 1950, em paralelo as evoluções dos computadores, desde então, proporciona avanços recorrentes em diversos campos da ciência (ALAN, 1950). O aprendizado de máquina na área da saúde é satisfatório em previsões promissoras considerando o reconhecimento de padrões e experiências. Como disse o cientista da computação e autor do livro *Machine Learning*, Michell(1997), “Diz-se que um programa de computador aprende com a experiência E em uma certa classe de tarefas T e medida de desempenho P, se seu desempenho nas tarefas em T, conforme medido por P, melhora com a experiência" (ZHOU, 2021).

A aprendizagem de máquina supera limitações de métodos estatísticos tradicionais ao identificar padrões complexos em grandes volumes de dados, permitindo tanto a distinção entre pacientes e controles quanto a identificação de variáveis relevantes. Aplicações incluem o uso de dados clínicos, neuroimagem (como RM e EEG), genética e dados multimodais, com modelos atingindo acurácias de até 96%. Apesar dos avanços, ainda há desafios, como a limitação de amostras, risco de *overfitting*, ou seja, quando o modelo memoriza o conjunto de treinamento de



forma tão próxima que o modelo não consegue fazer previsões corretas em novos dados, e baixa interpretabilidade de alguns modelos (HARRISON *et al.*, 2023).

O uso de técnicas de ML e *Deep Learning* (DL) tem ganhado destaque como ferramenta de apoio ao diagnóstico de transtornos mentais, conforme demonstrado na revisão sistemática apresentada por Iyortsuun *et al.* (2023). Os estudos analisados mostram que modelos como *Support Vectors Machine* (SVM), *Random Forest* (RF) e redes neurais profundas têm alcançado altos níveis de desempenho na identificação de condições como esquizofrenia, depressão, ansiedade, transtorno bipolar, anorexia nervosa e TDAH. Por exemplo, no diagnóstico de esquizofrenia, modelos DL alcançaram até 94,44% de acurácia, superando métodos tradicionais. Para TDAH, abordagens híbridas e redes neurais baseadas em Imagens de Ressonância Magnética funcional (IRMf) mostraram acurácias que variam entre 66% e 95%. Apesar das limitações como tamanhos amostrais reduzidos, os modelos de ML e DL demonstram robustez e precisão, indicando seu potencial como suporte clínico (IYORTSUUN *et al.*, 2023).

O EEG é uma técnica de neuroimagem que se destaca no estudo do TDAH devido às suas características vantajosas e às aplicações promissoras em conjunto com a aprendizagem de máquina. Trata-se de um método acessível, de baixo custo e não invasivo, o que o torna popular na investigação do TDAH. Fatores como o tipo de tarefa experimental, a condição do registro (repouso ou tarefa), a combinação de múltiplas condições e a divisão por faixas etárias mostraram influenciar a acurácia dos modelos. As pesquisas seguem em busca de características, como medidas baseadas em entropia e dimensão fractal, para melhorar ainda mais o desempenho dos algoritmos. A fim de garantir que essas informações extraídas do EEG sejam confiáveis e adequadas para análise por modelos de aprendizagem de máquina, é fundamental realizar um pré-processamento eficiente dos sinais (HARRISON *et al.*, 2023).

#### **2.4.1 Processamento de Sinais de EEG**

A análise do sinal de EEG geralmente é dividida em quatro etapas: coleta de dados brutos, pré-processamento, extração de características e classificação. Os dados brutos de EEG correspondem à atividade neuronal registrada diretamente do couro cabeludo, podendo conter ruídos provenientes do ambiente, como vibrações e interferências da rede elétrica, movimentos oculares, musculares, cardíacos, ou do próprio sistema de aquisição, como sensores defeituosos (PADFIELD *et al.*, 2019). Em muitos casos, os artefatos presentes no sinal de EEG comprometem a identificação da atividade cerebral relevante, tornando essencial a aplicação de técnicas para a

remoção ou correção dessas interferências (KEIL *et al.*, 2014).

O pré-processamento de sinais de EEG visa remover ruídos e artefatos sem comprometer informações relevantes do sinal cerebral. Entre os métodos mais comuns estão os filtros passa-banda, que restringem a análise à faixa de frequência de interesse, e o filtro *notch*, utilizado para eliminar interferências específicas, como o ruído de linha de energia. Técnicas mais avançadas, como *Independent Component Analysis* (ICA) e *Empirical Mode Decomposition* (EMD), também são empregadas para separar artefatos do sinal original. A EMD, por exemplo, é eficaz para lidar com a natureza não linear e não estacionária do EEG, permitindo uma análise mais adaptativa ao tempo. No entanto, esses métodos apresentam limitações, podendo resultar em subcorreção, com artefatos residuais, ou supercorreção, com perda de dados relevantes, o que pode comprometer a precisão das análises (KEIL *et al.*, 2014).

As características extraídas do EEG podem ser divididas em duas principais categorias: domínio do tempo e domínio da frequência. No domínio do tempo, são usadas séries temporais que mostram respostas rápidas do cérebro a estímulos. No domínio da frequência, analisam-se as potências em diferentes bandas (alfa, beta, delta, theta, gama), que refletem aos ritmos cerebrais. Além disso, características espaciais combinam sinais de vários eletrodos para melhorar a qualidade do dado, e métricas de conectividade avaliam como diferentes regiões do cérebro se comunicam. Juntas, essas características ajudam a capturar várias informações importantes para análises e classificações com ML (CORSI, 2023).


#### **2.4.2 Classificadores**

Não existe um modelo de ML que seja ideal para todos os tipos de dados. Por isso, é necessário realizar testes para avaliar qual modelo apresenta o melhor desempenho em cada situação-problema. Diversos estudos mostraram que o SVM, por exemplo, é eficaz na classificação de EEG (TASPINAR; OZKURT, 2024). Já o *K-nearest neighbors* (KNN), por sua vez, é um dos classificadores mais simples de implementar e de fácil compreensão, ainda sendo capaz de apresentar bons resultados, dependendo da aplicação (ZHANG, 2022). E o modelo RF possui sua abordagem baseada na combinação de múltiplos modelos (árvores de decisão), o que geralmente resulta em melhor desempenho com grandes volumes de dados, embora com maior custo computacional (BIAU; SCORNET, 2016).

### 2.4.2.1 Support Vector Machines (SVM)

O modelo Máquina de Vetores de Suporte, do inglês *Support Vector Machines*, é um modelo computacional de aprendizado supervisionado voltado para classificação linear binária e regressão. O SVM realiza a classificação construindo hiperplanos que buscam uma margem ótima entre dados de diferentes classes (CHAUHAN *et al.*, 2019). A Figura 3, representa a visão geométrica do SVM, na qual os dados pertencentes a cada classe são representados por diferentes marcadores: cruzeiros (x) para uma classe e círculos (o) para a outra.

Figura 3 – Representação do modelo de classificação SVM.



Fonte: Elaborado pela Autora.

O SVM tem base lógica, matemática e estatística, e pode ser considerado uma extensão matemática das redes neurais (CORTES; VAPNIK, 1995). Para dados que não são linearmente separáveis, utilizam-se os *kernels*. Os *kernels* são funções matemáticas que transformam os dados de treinamento em um espaço multidimensional. Dessa forma, dados que não podem ser separados por uma linha reta (ou plano) no espaço original podem, ao serem projetados em um espaço de maior dimensão, tornar-se linearmente separáveis. Isso facilita a definição de um hiperplano linear que separe as classes de forma eficaz (CHAUHAN *et al.*, 2019).

Algumas das principais funções utilizadas para o *kernel* do SVM são a linear, a polinomial e a radial ou *Radial Basis Function* (RBF) (PATLE ARTI E CHOUHAN, 2013). O RBF geralmente é a função mais utilizada em problemas não lineares. As Equações

$$K_{\text{linear}}(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^\top \mathbf{x}_j \quad (2.1)$$

$$K_{\text{polinomial}}(\mathbf{x}_i, \mathbf{x}_j) = \left( \gamma \mathbf{x}_i^\top \mathbf{x}_j + r \right)^d \quad (2.2)$$

$$K_{\text{RBF}}(\mathbf{x}_i, \mathbf{x}_j) = \exp \left( -\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2 \right) \quad (2.3)$$

representam as funções linear, polinomial e RBF respectivamente. Os vetores  $\mathbf{x}_i$  e  $\mathbf{x}_j$  representam amostras de entrada que estão sendo comparadas. O termo  $\mathbf{x}_i^\top \mathbf{x}_j$  indica o produto escalar entre esses vetores, servindo como medida de similaridade. O parâmetro  $\gamma$  controla a influência de cada ponto de dado no modelo, assim, valores maiores tornam a separação mais sensível às variações locais. No *kernel* polinomial, o termo  $r$  atua como um ajuste adicional (bias), enquanto  $d$  define o grau do polinômio e, conseqüentemente, a complexidade da função de separação. A expressão  $\|\mathbf{x}_i - \mathbf{x}_j\|$  representa a distância euclidiana entre as amostras, utilizada no *kernel* RBF (PATLE ARTI E CHOUHAN, 2013).

De acordo com Patle Arti e Chouhan (2013), o SVM possui algumas limitações. A mais notável é a escolha da função *kernel*, pois encontrar a mais adequada para o problema não é uma decisão simples. Outra limitação do modelo é seu custo computacional que requer grande quantidade de memória e processamento, no treinamento e classificação.

#### 2.4.2.2 *K-Nearest Neighbor (KNN)*

O método K-vizinhos mais próximos, do inglês *K-Nearest Neighbors*, é um algoritmo de ML supervisionado amplamente utilizado em tarefas de classificação, regressão e na previsão de valores faltantes. A classificação de um novo dado é feita com base na votação da maioria entre os  $k$  vizinhos mais próximos, ou seja, os mais semelhantes (ZHANG, 2022).

A classificação KNN é dividida em duas fases principais. Na fase de treinamento, o objetivo é encontrar um valor adequado de K para o conjunto de dados, sendo a validação cruzada o método mais utilizado para essa escolha. Já na fase de predição, para cada nova amostra (dado de teste), o algoritmo identifica os K pontos mais próximos no conjunto de treinamento e realiza

a classificação com base na classe mais frequente entre esses vizinhos, aplicando a chamada regra da maioria.


O KNN realiza essa classificação com base no cálculo de similaridade entre a nova amostra e as instâncias previamente rotuladas. Essa similaridade geralmente é medida por distâncias matemáticas, sendo a distância Euclidiana a mais utilizada. A Equação

$$d(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (2.4)$$

descreve matematicamente o cálculo da distância Euclidiana. Onde  $d(\mathbf{x}_i, \mathbf{x}_j)$  representa a distância Euclidiana entre as duas instâncias,  $\mathbf{x}_i$  e  $\mathbf{x}_j$  são vetores com  $n$  atributos, e  $x_{ik}$  e  $x_{jk}$  representam os valores do  $k$ -ésimo atributo das instâncias  $i$  e  $j$ , respectivamente.

A Figura 4 ilustra a visão geométrica do KNN. O novo dado, representado por um círculo (o) destacado preenchido por tom escuro, pode pertencer à classe das cruzes (x) ou à classe dos círculos (o). Considerando  $k = 3$ , o algoritmo analisa os três vizinhos mais próximos e atribui o dado à classe predominante, neste exemplo, a classe das cruzes (x).

Figura 4 – Representação do modelo de classificação KNN.



Fonte: Elaborado pela Autora.

O KNN, sob condições bastante leves, demonstra que sua taxa de erro tende ao erro ótimo de *Bayes* à medida que o tamanho da amostra tende ao infinito. Um classificador é considerado *Bayes ótimo* quando nenhum outro classificador consegue atingir uma taxa de erro

de classificação esperada menor. Basicamente, isso significa que todo o erro de classificação se deve ao ruído genuíno presente nos dados (ZHANG, 2022).

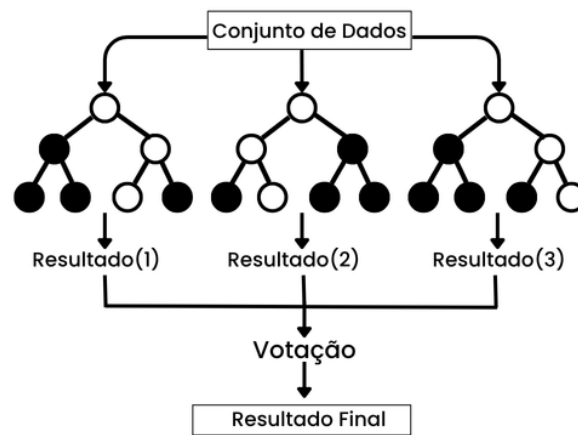
#### 2.4.2.3 *Random Forest (RF)*

O modelo Floresta Aleatória, do inglês *Random Forest*, é uma técnica de classificação que utiliza como classificador um conjunto de árvores de decisão. A abordagem combina várias árvores de decisão randomizadas e agrega suas previsões por meio de votação ou média.

O RF opera com base no princípio simples, porém eficaz, de "dividir para conquistar". Inicialmente, múltiplas amostras aleatórias dos dados de treinamento são geradas, por meio do método conhecido por *bootstrap*). Para cada uma dessas amostras, é construída uma árvore de decisão de forma independente, utilizando apenas um subconjunto aleatório das variáveis disponíveis em cada divisão do nó. Esse processo reduz a correlação entre as árvores individuais, tornando o conjunto mais robusto (BIAU; SCORNET, 2016).

Após todas as árvores serem treinadas, suas previsões são combinadas, no caso de classificação, por votação majoritária, e em regressão, por média. Essa agregação final resulta em um modelo mais estável, preciso e menos suscetível ao *overfitting* do que uma única árvore de decisão. Um dos fatores que mais contribuíram para a popularidade do RF é sua capacidade de lidar com uma ampla variedade de problemas preditivos, exigindo poucos ajustes de parâmetros e funcionando bem mesmo com conjuntos de dados de alta dimensionalidade (BIAU; SCORNET, 2016). A Figura 5 representa uma visão esquemática do funcionamento do RF. O modelo conta com três árvores de decisão. Cada árvore é treinada a partir de um subconjunto aleatório dos dados e das variáveis preditoras, produzindo uma classificação individual para a nova amostra. A decisão final do modelo é obtida por meio de votação majoritária entre as classificações fornecidas pelas três árvores.

Figura 5 – Representação do modelo de classificação RF.



Fonte: Elaborado pela Autora.

O RF é reconhecido por sua eficácia em diferentes tipos de dados e em conjuntos com grande número de características. O RF também demonstrou excelente desempenho em cenários onde o número de variáveis é muito maior do que o número de observações (BIAU; SCORNET, 2016).

### 3 TRABALHOS RELACIONADOS

Neste capítulo são apresentados alguns trabalhos que servirão como base para comparação com o presente trabalho.

#### 3.1 Rede neural profunda baseada em siamês para detecção de TDAH usando sinal de EEG

Em Alajmi *et al.* (2024) foi proposto uma *Convolutional Neural Network* (CNN) Siamesa para analisar mapas cerebrais de EEG. A CNN siamesa consiste em processar duas entradas por vez, para gerar uma única saída representando a métrica de similaridade com base na distância euclidiana.

O conjunto de dados utilizado é disponibilizado livremente pela *Institute of Electrical and Electronic Engineers (IEEE)*. Para a coleta de dados de EEG, foi apresentada atividades de atenção visual para um grupo de 121 crianças, sendo 60 crianças controle e 61 crianças diagnosticadas com TDAH. Contudo, o estudo enfatizou a necessidade de técnicas de aumento de dados, afim de melhorar a generalização e a robustez do modelo. A técnica apresentada utilizada consiste em embaralhar sub-bandas de frequência de dados TDAH e Controle em minilotes, e substituindo os dados de uma sub-banda pelos de outro sujeito da mesma classe.

O estudo apresentou resultados significativos com o uso de *Gradient-weighted Class Activation Mapping (Grad-CAM)*, técnica de visualização que aponta quais partes dos dados de entrada são mais influentes nos resultados da previsão do modelo. Então, foi mostrado que a potência de banda theta nos lobos frontal e occipital entre indivíduos saudáveis e com TDAH apresentam contraste, confirmando indicações já feitas por pesquisas anteriores. Como resultado, o modelo indicou uma precisão de 99,17% em detecção de crianças com TDAH.

#### 3.2 Identificação automática de crianças com TDAH a partir de ondas cerebrais de EEG

Em Jalilpour *et al.* (2024), um modelo de SVM gaussiano foi treinado para classificar sinais de EEG, utilizando como diferencial a extração de características no domínio do tempo e da frequência, considerando apenas as quatro primeiras sub-bandas (alfa, beta, delta e teta). O estudo também se destacou pelo uso de dados lineares simples.

Os experimentos foram realizados com a mesma base de dados descrita no trabalho anterior, composto por uma amostra de 121 crianças. Para a seleção das características mais



relevantes, foi empregado o método não supervisionado *Principal Component Analysis* (PCA). A classificação foi realizada com um modelo de SVM e avaliada por meio de validação cruzada *holdout* e *k-fold*, resultando em uma precisão média de 93%.

### **3.3 Detecção de TDAH a partir de sinais de EEG usando novas técnicas de decomposição híbrida e aprendizado profundo**

Em Esas e Latifoğlu (2023), foi utilizada uma CNN com o diferencial da aplicação das técnicas de decomposição Robust Local Mode Decomposition (RLMD) e Variational Mode Decomposition (VMD), empregadas para lidar com sinais não estacionários e variáveis no tempo, como o EEG, facilitando sua análise e interpretação. O RLMD é um método que separa um sinal modulado em frequência (FM) de um sinal de envelope modulado em amplitude (AM). Já o VMD separa diferentes padrões dentro do sinal, dividindo séries temporais em submodos reproduzíveis com largura de banda limitada.

Os experimentos com a mesma base de dados usada anteriormente mostraram que, ao utilizar apenas o canal Fp1 com um algoritmo de aprendizado profundo, a precisão foi de 65,82%. No entanto, ao combinar RLMD e VMD, a taxa aumentou para 87,38%. Quando as técnicas foram aplicadas separadamente, a precisão foi de 80% para RLMD e 77,08% para VMD.

Além disso, o estudo identificou os canais de EEG mais eficazes para a detecção de TDAH, utilizando-os como entrada para um algoritmo de aprendizado profundo. A região frontal (Fp1 e Fz) apresentou maior precisão na classificação em comparação com os demais canais. Com o aprimoramento do algoritmo, estima-se que uma taxa de sucesso superior a 95% possa ser alcançada utilizando um único canal de EEG com VMD e RLMD.

### **3.4 Detecção automatizada de transtorno de conduta e transtorno de déficit de atenção e hiperatividade usando técnicas de decomposição e não lineares com sinais de EEG**

Em Tor *et al.* (2021), foi desenvolvido um sistema automatizado para a classificação das classes TDAH, Transtorno de Conduta (TC) e ambos, utilizando sinais de EEG. Para isso, foram empregados os métodos EMD e *Discrete Wavelet Transform* (DWT) na decomposição dos sinais.

A técnica EMD permite decompor os sinais em funções de modo intrínseco, co-

nhecidas por *Intrinsic Mode Functions* (IMFs), enquanto a DWT é uma abordagem popular para decomposição de sinais, destacando-se por sua capacidade de capturar simultaneamente informações de frequência e localização.

A base de dados utilizada na pesquisa, de domínio público, é composta por sinais de EEG de 123 crianças, recrutadas de uma clínica psiquiátrica infantil em Singapura (*Child Guidance Clinic*), distribuídas nas seguintes classes: TDAH 45 participantes, TDAH + TC 62 participantes, TC apenas 16 participantes. O modelo de *machine learning* utilizado foi o KNN, que obteve a maior precisão no estudo, atingindo uma taxa de acerto de 97,88%.

Na Tabela 2 temos um resumo dos modelos de aprendizado de máquina, quantidade pessoas nas amostras, e as métricas de desempenho utilizados.

Tabela 2 – Trabalhos relevantes e suas respectivas metodologias de classificação.

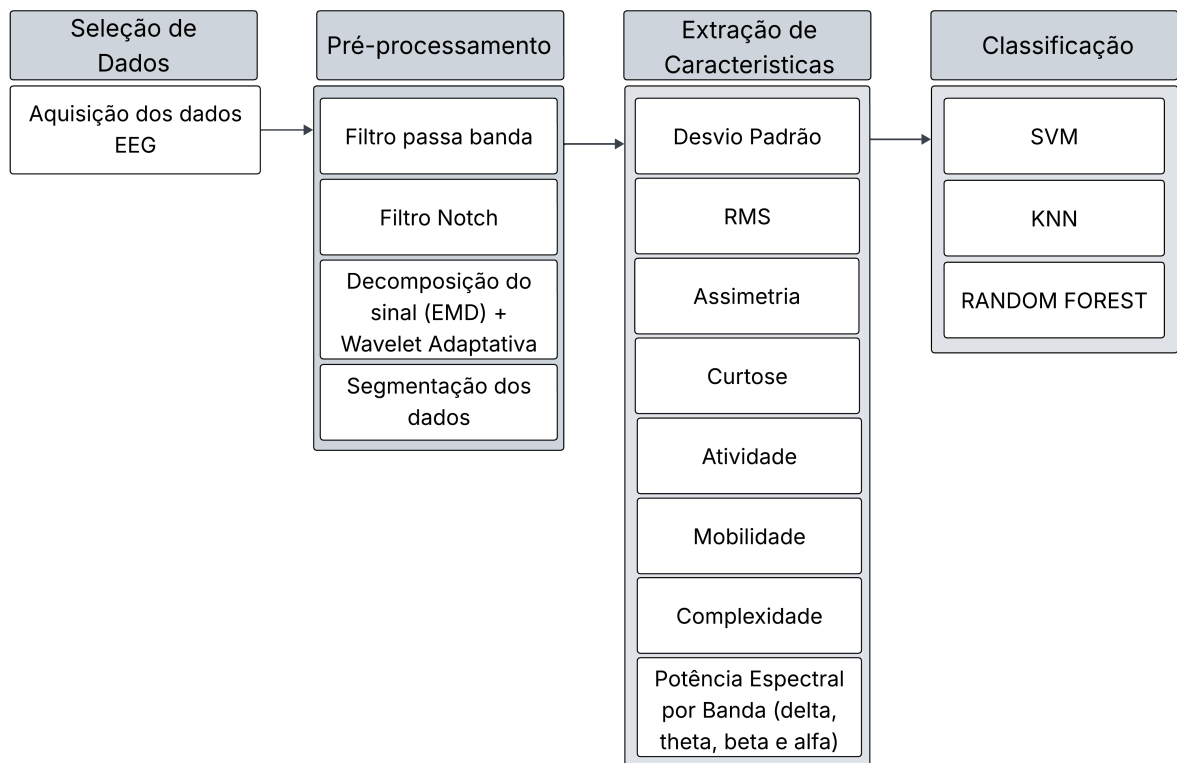
Trabalhos	Métodos de classificação	Extração de recursos	Precisão(%)
Alajmi <i>et al.</i> (2024)	CNN Siamesa	Mapas cerebrais derivados da Densidade Espectral de Potência (PSD)	99,17%
Jalilpour <i>et al.</i> (2024)	SVM gaussiana	Extração de características estatísticas, de domínio de tempo e de domínio de frequência dos dados	94,2%
Esas e Latifoğlu (2023)	CNN	Decomposição por Modo Variacional (VMD) e Decomposição por Média Local Robusta (RLMD)	95,24%
Tor <i>et al.</i> (2021)	KNN	Decomposição por Modo Empírico (EMD) e Transformada Wavelet Discreta (DWT)	97,88%

**Fonte:** Elaborado pela Autora.

## 4 METODOLOGIA

Neste capítulo, são abordadas as etapas de seleção do conjunto de dados, pré-processamento, extração de características, classificação e as métricas de avaliação adotadas, cujas etapas serão descritas nas seções a seguir. A Figura 6 apresenta um resumo da metodologia proposta.

Figura 6 – Etapas da Metodologia.



Fonte: Elaborado pela Autora.

Para a implementação e teste da análise do EEG, foi utilizada a linguagem *Python* versão 3.12.6, na *IDE Visual Studio Code* versão 1.101.2, juntamente com a biblioteca MNE. A MNE é uma biblioteca de código aberta específica para o processamento de dados eletrofisiológicos, como o EEG, oferecendo ferramentas robustas para leitura, visualização, pré-processamento, análise e extração de características dos sinais. Os *scripts* desenvolvidos para este trabalho estão disponíveis no Apêndice A para mais detalhes.

#### 4.1 Seleção de Dados

A base de dados eeg-data-adhd-control-children é de acesso público e é disponibilizada pela IEEE <sup>1</sup>. Os arquivos contém registros de EEG de 121 crianças entre 7 e 12 anos. As crianças diagnosticadas com TDAH foram identificadas por profissionais de saúde de acordo com as normas do DSM-5 e usaram Ritalina por até seis meses. Foi constatado que nenhuma das crianças do grupo de controle tinha histórico de transtorno psiquiátrico, epilepsia ou comportamento de alto risco. A Tabela 3 resume as informações sobre os participantes.


Tabela 3 – Informações sobre os participantes.

	Meninos	Meninas	Idade
Crianças Saudáveis	50	10	7–10
Crianças com TDAH	48	13	7–12

**Fonte:** Elaborado pela Autora.

A coleta do sinal de EEG foi obtido por 19 canais no sistema 10-20 á uma frequência de amostragem de 128 Hz. O protocolo de gravação foi baseado em atividades de atenção visual, ao estimulá-los a contar o número de personagens animados que apareciam em tela, como mostrado em exemplo da Figura 7. Como a duração de cada sessão individual era de acordo com o tempo de resposta da criança, o período geral das gravações de EEG diferiu em todo o conjunto de dados.

Figura 7 – Atividade visual utilizada na coleta de Dados



Fonte: (ALAJMI *et al.*, 2024).

<sup>1</sup> <<https://iee-dataport.org/open-access/eeg-data-adhd-control-children>>

Todos os procedimentos para obtenção desse conjunto de dados foram aprovados pelo *Institutional Review Board (IRB)* e pelo Comitê de Ética da Universidade de Ciências Médicas de Teerã. Além disso, os dados foram coletados em duas sessões distintas e em dois locais diferentes, reduzindo o viés de medição na coleta.

## 4.2 Pré-processamento dos dados

Como mencionado anteriormente, o sinal do EEG é muito sensível a ruídos, como os causados por movimentos oculares, do pescoço e pela rede elétrica do local. Para mitigar esses ruídos, foram aplicados os filtros passa-banda e *notch*.

O filtro passa-banda tem a função de eliminar ou atenuar os componentes de alta e baixa frequência de um espectro, permitindo apenas a passagem de uma faixa específica de frequências. Neste estudo, será utilizado um filtro passa-banda para atenuar os sinais fora da faixa de 0,5 – 30 Hz, intervalo escolhido por abranger as bandas de maior interesse (delta, theta, alfa e beta), devido à relação TBR.

Já o filtro *notch* será utilizado para eliminar a interferência do ruído de linha (*Power Line Noise*), causado pela interferência eletromagnética da rede elétrica. O local de registro está situado em uma região onde a frequência da rede é de 50 Hz (JANAPATI *et al.*, 2023).

### 4.2.1 Limpeza de artefatos com EMD e Wavelet Adaptativa

A decomposição de sinais busca desmembrar um sinal complexo em componentes mais simples, permitindo uma melhor compreensão e análise de suas características e padrões. O EMD realiza a decomposição intrínseca do sinal em componentes oscilatórios, resultando nas chamadas IMFs através de um processo repetitivo de peneiramento. O intuito do peneiramento é eliminar ondas superpostas e suavizar amplitudes irregulares (BOUDRAA *et al.*, 2004).

Para cada canal do EEG, o sinal é decomposto em várias funções intrínsecas usando o algoritmo EMD. Essas IMFs representam diferentes componentes oscilatórios do sinal, e o número de componentes é controlado por um parâmetro definido. Caso o número de IMFs obtidas seja muito pequeno, o processamento sofisticado é ignorado e o sinal original é mantido para aquele canal.

Para que haja uma separação entre sinal limpo e artefato, precisa-se estimar um limiar, e neste estudo, a curtose, a entropia e desvio padrão, serão usados com esse propósito.

A curtose é uma medida da cauda ou achatamento de uma distribuição. Em EEG, artefatos (como piscadas, movimentos musculares, etc.) frequentemente se manifestam como eventos de alta amplitude e curta duração, o que tende a resultar em IMFs com alta curtose. Sinais neurais, por outro lado, tendem a ter uma curtose menor, ou mais próxima de uma distribuição normal. Portanto, a ideia de usar a curtose para identificar e remover IMFs com artefatos é válida. A entropia, mede o grau de desordem, sabendo que artefatos tendem a deixar o sinal desorganizado ou irregular, o que pode aumentar a entropia em certas regiões do tempo ou canais. Já o desvio padrão mostra a variabilidade do sinal, sabendo que movimentos oculares ou musculares geralmente com amplitude alta causam um aumento abrupto no desvio padrão. Com base na distribuição dessas métricas, é definido um limite adaptativo para identificar quais IMFs provavelmente contêm ruído.

As IMFs consideradas ruidosas passam por um processo de filtragem por *wavelets*. A Transformada *Wavelet* decompõe o sinal das IMFs em coeficientes que representam sua informação em diferentes escalas de tempo e frequência. Artefatos, que frequentemente se manifestam como picos de alta frequência e curta duração, tendem a gerar coeficientes de maior magnitude em determinadas escalas. Com base em um limiar adaptativo, esses coeficientes ruidosos são identificados e atenuados ou zerados. Por fim, o sinal das IMFs são reconstruídos a partir dos coeficientes filtrados, resultando em uma versão mais limpa e livre de ruídos. As IMFs consideradas limpas, com base nas métricas de curtose, entropia e desvio padrão, não sofrem essa etapa de filtragem por *wavelets*, preservando sua integridade.

Em resumo, o método de limpeza de artefatos utilizado neste trabalho combina análise adaptativa do sinal com técnicas matemáticas sofisticadas para limpar o EEG de forma eficiente, preservando as informações importantes e reduzindo ruídos indesejados.

#### **4.2.2 Segmentação dos dados**

Após a limpeza de ruídos, é proposta uma segmentação em janelas, assim o sinal de EEG da série temporal foi dividido em segmentos de tamanho de 2 segundos para cada canal e com sobreposição de 50%. Dessa forma cada janela de EEG tem 2 segundos, com 1 segundo da janela anterior e 1 segundo da janela atual. Na obtenção do sinal, a duração mínimo de sessões para crianças saudáveis era de 50 segundos e para uma criança com TDAH o mínimo foi de 258 segundos. Como o tempo de cada tarefa diferiu em cada sujeito, o número de segmentos variou pra cada criança.

### 4.3 Extração de características

Para representar de forma eficaz os sinais de EEG no processo de classificação, foram selecionadas 11 características estatísticas que capturam diferentes aspectos do comportamento do sinal. Essas métricas abrangem desde medidas de dispersão (como desvio padrão e *Root Mean Square* (RMS)), forma da distribuição (assimetria e curtose), até indicadores de complexidade e desordem (atividade, mobilidade e complexidade de *Hjorth*). Além disso, foi incluída a potência relativa nas bandas de frequência delta, theta, alfa e beta, que refletem padrões rítmicos relevantes da atividade cerebral. Juntas, essas características fornecem uma representação abrangente dos dados de EEG, contribuindo para uma análise mais robusta e informativa. Abaixo temos uma breve descrição dessas características.

- STD (Desvio Padrão): Mede a dispersão dos valores do sinal em torno da média.
- RMS (Raiz Quadrada Média ou *Root Mean Square*): Uma medida da magnitude média do sinal ao longo do tempo.
- Assimetria ou *Skewness*: Mede o grau de assimetria na distribuição de amplitude do sinal.
- Curtose ou *Kurtosis*: Mede o achatamento ou o pico da distribuição de amplitude do sinal.
- Atividade ou *Activity* (Parâmetro de *Hjorth*): É a variância da amplitude do sinal, como mostrado na Equação

$$\text{Atividade} = \text{Var}(x(t)), \quad (4.1)$$

a atividade reflete a potência ou energia média do sinal.

- Mobilidade ou *Mobility* (Parâmetro de *Hjorth*): É a raiz quadrada da razão entre a variância da primeira derivada do sinal e a variância do próprio sinal, como mostrado na Equação

$$\text{Mobilidade} = \sqrt{\frac{\text{Var}(\Delta x(t))}{\text{Var}(x(t))}}, \quad (4.2)$$

a mobilidade retorna a frequência média do sinal ou a proporção de mudanças de amplitude.

- Complexidade ou *Complexity* (Parâmetro de *Hjorth*): É a razão entre a mobilidade da primeira derivada do sinal e a mobilidade do próprio sinal, como mostrado na Equação

$$\text{Complexidade} = \frac{\sqrt{\frac{\text{Var}(\Delta^2 x(t))}{\text{Var}(\Delta x(t))}}}{\text{Mobilidade}}, \quad (4.3)$$

a complexidade reflete a mudança na frequência do sinal.

Já para as características no domínio da frequência, o sinal de cada canal individual é transformado para o domínio da frequência utilizando a Transformada Rápida de Fourier (*Fast Fourier Transform* (FFT)), sendo então obtida a potência total nas quatro bandas de frequência do EEG (delta, theta, alfa e beta). Isso resulta em 11 características ( 7 no domínio do tempo e 4 no domínio da frequência ) por canal, totalizando em uma matriz de  $19 \times 11 = 209$  *features* por indivíduo.

O pré-processamento das características incluiu as etapas de imputação de valores ausentes, padronização, seleção de características e redução de dimensionalidade. Essas etapas são fundamentais para garantir que os dados estejam em condições adequadas para o treinamento dos modelos de aprendizado de máquina.

A imputação de valores ausentes foi realizada substituindo os valores faltantes pela mediana de cada característica, o que é especialmente útil em dados com *outliers*, por ser uma medida robusta.

Em seguida, foi aplicada a padronização dos dados, transformando as características para que tenham média zero e desvio padrão igual a um. Esse processo é importante porque muitos algoritmos de aprendizado de máquina são sensíveis à escala dos dados, especialmente aqueles baseados em distância como o KNN.

Na etapa de seleção de características, utilizou-se o método *SelectKBest* com o método estatístico ANOVA F-value, selecionando as 40 características mais discriminativas. Esse método avalia a relação entre cada *feature* e a variável alvo, mantendo apenas aquelas que apresentam maior relevância estatística.

Por fim, foi aplicada a Análise de Componentes Principais PCA, com o parâmetro número de componentes de variância explicada em 0,95. Isso significa que foram mantidos os componentes principais suficientes para explicar 95% da variância total dos dados, reduzindo a dimensionalidade sem perder informações relevantes.

#### 4.4 Classificação

Este estudo utilizou os algoritmos SVM, KNN e RF, cujas características principais foram apresentadas explicitamente nas seções anteriores. A divisão do conjunto de dados foi realizada em 70% para treino e 30% para teste. Também foi aplicada validação cruzada com 5 partes (5-fold cross-validation).



Os parâmetros definidos para o classificador SVM foram:  $kernel = 'rbf'$ ,  $C = 10$ , o que representa um controle maior sobre a penalização dos erros, e  $gamma = 'scale'$ , que ajusta automaticamente o parâmetro com base nas variáveis de entrada. Para o algoritmo KNN, utilizou-se o número de vizinhos igual a 5 (valor intermediário), com a métrica de distância Euclidiana. Já para o *Random Forest*, foram utilizados 100 estimadores, profundidade máxima das árvores (*max depth*) igual a 5, e *random state* igual a 42, a fim de garantir a reprodutibilidade dos resultados.

## 4.5 Métricas de Avaliação

As métricas de avaliação mais comumente utilizadas para classificação binária são acurácia, sensibilidade, especificidade, precisão e matriz de confusão, como assim será feito neste experimento.

### 4.5.1 Acurácia

A acurácia é uma das métricas mais comuns de desempenho de modelos de ML. Refere-se à qualidade ou exatidão a qual um modelo estatístico prediz uma resposta ou se ajusta aos dados. Essa taxa de acerto é medida dividindo o número de acertos verdadeiros nos testes pelo número total de testes, como mostrado na Equação

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.4)$$

onde Verdadeiro Positivo (VP) é o número de amostras em que a classe positiva é predita de forma verdadeira pelo modelo, Verdadeiro Negativo (VN) é o número de amostras em que a classe negativa é predita de forma verdadeira pelo modelo, Falso Positivo (FP) é o número de amostras em que a classe positiva é prevista de forma falsa pelo modelo e Falso Negativo (FN) é o número de amostras em que a classe negativa é predita de forma falsa pelo modelo (JAMES *et al.*, 2023).

É importante ressaltar que a acurácia pode não ser suficiente em casos de conjuntos de dados desbalanceados, onde as classes têm tamanhos significativamente diferentes.

### 4.5.2 Sensibilidade

A sensibilidade ou *recall* também é conhecida como taxa de verdadeiros positivos. É importante em situações em que a identificação correta de positivos é crítica, e é calculada conforme mostra a Equação 4.5 (RAINIO *et al.*, 2024):

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (4.5)$$

### 4.5.3 Especificidade

A especificidade ou taxa de verdadeiros negativos, mostra a porcentagem de amostras verdadeiramente negativas que foram corretamente classificadas (RAINIO *et al.*, 2024). Essa métrica é útil em situações em que falsos positivos devem ser evitados. O cálculo da especificidade é mostrado na Equação 4.6.

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (4.6)$$

### 4.5.4 Precisão

A precisão mostra a proporção entre as predições verdadeiras positivas e o total de predições verdadeiras (RAINIO *et al.*, 2024). O cálculo da precisão é mostrado na Equação 4.7

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (4.7)$$

### 4.5.5 Matriz de confusão

A matriz de confusão é uma ferramenta essencial para a avaliação detalhada do desempenho de algoritmos de classificação. Ela apresenta as taxas de acertos e erros entre diferentes classes e serve como base para o cálculo de diversas métricas de avaliação. A matriz exibe as contagens de Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN). Em classificadores multiclasse, os resultados podem ser organizados em uma matriz de confusão de dimensão  $k \times k$ , onde  $k$  representa o número de classes (RAINIO *et al.*, 2024). A representação de uma matriz de confusão é apresentada na Figura 8.

Figura 8 – Representação da Tabela Verdade.

		VALOR PREDITO	
		SIM	NÃO
REAL	SIM	VERDADEIRO POSITIVO (VP)	FALSO NEGATIVO (FN)
	NÃO	FALSO POSITIVO (FP)	VERDADEIRO NEGATIVO (VN)

Fonte: Adaptado de (NOGARE, 2020).


## 5 RESULTADOS

Neste capítulo serão mostrados os resultados dos testes aplicados, seguindo a metodologia proposta. Este capítulo está organizado da seguinte forma: a Seção 5.1 trata dos resultados experimentais dos modelos e a Seção 5.2 discorre sobre os resultados obtidos, realizando uma análise e comparação com os trabalhos encontrados na literatura para análise de desempenho.

### 5.1 Resultados experimentais

Após a aquisição e leitura dos sinais de EEG, iniciou-se o processo de remoção de ruídos e artefatos. A Figura 9 apresenta o espectro de potência, evidenciando a eficácia da aplicação do filtro passa-banda (0,5–30 Hz) e do filtro *notch* (50 Hz) nos sinais de todos os canais do EEG.

Figura 9 – Aplicação de filtros no sinal de EEG.



Fonte: Elaborado pela Autora.

A Figura 9 apresenta dois quadros com o espectro de potência dos sinais de EEG. O primeiro (superior) mostra o sinal bruto, no qual é possível observar a presença de ruídos,

evidenciados por picos acentuados, especialmente em torno de 50 Hz, frequência característica de interferência da rede elétrica. No segundo quadro (inferior), nota-se o efeito da aplicação dos filtros, onde os picos foram significativamente atenuados, com destaque para a redução do ruído em 50 Hz e a queda progressiva da potência a partir de aproximadamente 33 Hz, resultado do filtro passa-banda adotado para a análise mais específica dos dados.

### 5.1.1 Desempenho no conjunto de treinamento

Para os três modelos foi calculado a margem de erro, calculada através do desvio padrão e verificado a quantidade de acertos dos valores preditos pra cada um dos modelos no treinamento, utilizando um grau de confiança de 95%. Os resultados desta aplicação são apresentados na Tabela 4.

Tabela 4 – Quadro comparativo de desempenho dos modelos no treinamento.

Modelo	Margem de Erro	% de Acertos (Acurácia)
SVM	0,29%	97,90%
KNN	0,27%	98,62%
RF	1,21%	78,45%

**Fonte:** Elaborado pela Autora.

A análise comparativa dos três modelos no conjunto de treinamento indica que tanto o SVM quanto o KNN apresentaram ótimos resultados, com acurácia acima de 97% e baixos erros médios absolutos (0,29% e 0,27%, respectivamente), demonstrando consistência e confiabilidade nas previsões. O KNN obteve os melhores resultados em termos de precisão e menor margem de erro, o que sugere que ele foi o mais eficaz para os dados utilizados. Em contrapartida, o *Random Forest* apresentou desempenho significativamente inferior (acurácia de 78,45% e maior margem de erro, 1,21%), indicando que o modelo pode não ter se ajustado bem às características do conjunto de treinamento ou que sofreu com *overfitting* em relação à complexidade dos dados.

Portanto, conclui-se que, para este cenário específico e com as características extraídas, o KNN foi o modelo mais eficiente, seguido de perto pelo SVM, sendo o *Random Forest* o menos adequado entre os três.

### 5.1.2 Desempenho no conjunto de teste

Para os três modelos foi especificado a sensibilidade, especificidade, precisão e acurácia no conjunto de teste. Os resultados desta aplicação são apresentados na Tabela 5.

Tabela 5 – Quadro comparativo de desempenho dos modelos no treinamento e teste.

Modelo	Precisão	Sensibilidade	Especificidade	Acurácia
SVM	98,04%	98,29%	97,52%	97,95%
KNN	99,03%	99,00%	98,78%	98,91%
RF	73,67%	90,87%	59,05%	76,80%

**Fonte:** Elaborado pela Autora.

O modelo KNN apresentou o melhor desempenho entre os três algoritmos avaliados, com acurácia de 98,91%, além de valores equilibrados e altos de precisão, sensibilidade e especificidade. A precisão de 99,03% indica baixo índice de falsos positivos. A sensibilidade de 99,00% indica excelente capacidade de identificar corretamente os casos de TDAH. E a especificidade de 98,78% mostra o ótimo desempenho também na detecção de controles. Esse equilíbrio mostra que o KNN foi eficaz tanto para detecção quanto para exclusão da condição (TDAH), o que é extremamente importante em contextos clínicos, onde erros de classificação podem ter consequências significativas.

O SVM também apresentou alto desempenho, com acurácia de 97,95% e métricas levemente inferiores às do KNN. O SVM obteve uma precisão de 98,04%, sensibilidade de 98,29% e especificidade de 97,52%. Embora tenha ficado um pouco abaixo do KNN, o SVM se mostra uma alternativa confiável, com ótima capacidade de generalização e bom desempenho em ambas as classes.

E por último o *Random Forest*, mostrou um desempenho inferior e desigual. O modelo *Random Forest* teve a acurácia de apenas 76,80%. A especificidade baixa (59,05%), indica alto número de falsos positivos (ex: controles classificados incorretamente como TDAH). E a sensibilidade alta de 90,87%, sugere que o modelo acerta muitos casos de TDAH, mas erra demais os negativos. Esse comportamento indica um viés do modelo em favorecer uma classe (neste caso o TDAH), o que pode ser um reflexo de parâmetros incorretos.

### 5.1.3 Matriz de confusão

Na matriz de confusão do modelo SVM, expressa na Tabela 6, é possível observar que o modelo teve 103 (48 + 55) classificações errôneas e 4.922 (2167 + 2755) classificações assertivas, de no total 5.025 *features*.

Tabela 6 – Matriz de Confusão do Modelo SVM.

Classe Real	Predito: <b>Controle</b>	Predito: <b>TDAH</b>
<b>Controle</b>	2167 (VN)	55 (FP)
<b>TDAH</b>	48 (FN)	2755 (VP)

**Fonte:** Elaborado pela Autora.

Na matriz de confusão do modelo KNN, expressa na Tabela 7, é possível observar que o modelo teve 55 (28 + 27) classificações errôneas e 4.970 (2195 + 2755) classificações assertivas, de no total 5.025 *features*.

Tabela 7 – Matriz de Confusão do Modelo KNN.

Classe Real	Predito: <b>Controle</b>	Predito: <b>TDAH</b>
<b>Controle</b>	2195 (VN)	27 (FP)
<b>TDAH</b>	28 (FN)	2755 (VP)

**Fonte:** Elaborado pela Autora.

E na matriz de confusão do modelo RF, expressa na Tabela 8, é possível observar que o modelo teve 1.166 (256 + 910) classificações errôneas e 3859 (1312 + 2547) classificações assertivas, de no total 5.025 *features*.

Tabela 8 – Matriz de Confusão do Modelo RF.

Classe Real	Predito: <b>Controle</b>	Predito: <b>TDAH</b>
<b>Controle</b>	1312 (VN)	910 (FP)
<b>TDAH</b>	256 (FN)	2547 (VP)

**Fonte:** Elaborado pela Autora.

O modelo KNN se destacou como o mais eficiente, tanto na classificação correta geral quanto em equilíbrio entre as classes, sendo o mais indicado para aplicação prática no

contexto estudado. O SVM também se mostrou eficaz, com desempenho semelhante, podendo ser preferido em cenários que exijam mais estabilidade ou escalabilidade. Já o *Random Forest* não apresentou desempenho satisfatório, sugerindo que sua estrutura ou parametrização não foi ideal para os dados utilizados.

#### 5.1.4 Análise das características

O uso do *SelectKBest* selecionou 40 características para irem pro treinamento, mas para uma análise das melhores características envolvidas, será dissertado sobre as 10 melhores características com seus canais em relação ao Score ANOVA que estão mostradas na Tabela 9.

Tabela 9 – Top 10 características selecionadas pelo SelectKBest, ordenadas por Score ANOVA.

Característica	Score ANOVA
Mobilidade no canal F8	591,20
RMS no canal P4	575,78
STD no canal P4	571,81
Complexidade no canal F8	560,10
Mobilidade no canal C3	469,03
Potência Beta no canal C3	432,72
Mobilidade no canal P3	379,31
RMS no canal F8	363,49
STD no canal F8	357,65
Mobilidade no canal Fp1	275,75

**Fonte:** Resultados do SelectKBest com teste ANOVA.

Como mencionado anteriormente, na análise de sinais, a mobilidade é uma medida de dispersão espectral, relacionada à taxa de variação da frequência do sinal. Variações nessa métrica podem refletir a agilidade ou rigidez do funcionamento neural, características que podem ser atípicas em indivíduos com TDAH.

O valor RMS mede a magnitude ou a amplitude total do EEG ao longo do tempo, representando o nível de energia do sinal. Dessa forma, um RMS alterado pode indicar regiões com hiperatividade em comparação a um cérebro neurologicamente típico. Já o (*Standard Deviation* (STD)), expressa a variabilidade ou dispersão dos valores do sinal EEG em torno da média. Um STD elevado indica que os valores do sinal flutuam significativamente, o que pode sugerir menor estabilidade na atividade neural.

A complexidade, por sua vez, capta a dinâmica e a previsibilidade do sinal EEG. A



perda de complexidade pode indicar perturbações nas redes neurais, e sua redução pode refletir um funcionamento menos adaptativo dessas redes.

Dessa forma, as características que se mostraram mais discriminativas segundo o método ANOVA apresentam correlação com padrões típicos do TDAH.

Já em relação aos canais, F8 (Frontal Direita), parte do lobo frontal, esta envolvido em funções executivas, como atenção, planejamento e controle de impulsos. Disfunções nesta área são indicadores para o TDAH. O canal P4 (Parietal Direita) faz parte do lobo parietal, que desempenham um papel crucial na atenção espacial, integração sensorial e processamento de informações. Embora associada principalmente ao controle motor, esta área também está envolvida na integração sensório-motora. A inquietação e o movimento excessivo observados no TDAH podem ter correlações com a atividade nesta região.

## 5.2 Análise dos Resultados

A Tabela 10 apresenta uma comparação entre os resultados deste experimento e aqueles reportados na literatura. Para representar este experimento na comparação, foi selecionado o classificador com o melhor desempenho em acurácia.

Os resultados demonstram que a utilização da Transformada *Wavelet*, combinada com métodos tradicionais de decomposição (EMD), pode alcançar um bom desempenho na remoção de artefatos em sinais de EEG, mesmo em modelos já aplicados anteriormente. No entanto, essa abordagem apresenta limitações em relação à acurácia quando comparada a técnicas mais modernas. Em Jalilpour *et al.* (2024), por exemplo, foi utilizado o mesmo método de extração de características, porém sem uma limpeza aprofundada dos dados, e apenas o classificador SVM foi testado, obtendo uma acurácia de 94,2%. Já neste estudo, utilizando as mesmas características, mas com uma etapa mais robusta de limpeza de artefatos e a avaliação de três modelos de classificação distintos, foi possível atingir uma acurácia superior, de 98,91%. Em Tor *et al.* (2021), foram aplicadas a Transformada *Wavelet* discreta e o EMD, de forma semelhante ao presente trabalho, mas com foco na extração de recursos, e também obtiveram resultados satisfatórios com acurácia de 97,88%. Apesar disso, técnicas mais recentes utilizadas no estado da arte, como a aplicação de mapas cerebrais por Alajmi *et al.* (2024), têm alcançado desempenhos ainda mais elevados, atingindo acurácia de até 99,17%.

Tabela 10 – Trabalhos relevantes e suas respectivas metodologias de classificação.

Trabalhos	Métodos de classificação	Extração de recursos	Precisão(%)
Alajmi <i>et al.</i> (2024)	CNN Siamesa	Mapas cerebrais derivados da Densidade Espectral de Potência (PSD)	99,17%
Jalilpour <i>et al.</i> (2024)	SVM gaussiana	Extração de características estatísticas, de domínio de tempo e de domínio de frequência dos dados	94,2%
Esas e Latifoğlu (2023)	CNN	Decomposição por Modo Variacional (VMD ) e Decomposição por Média Local Robusta (RLMD )	95,24%
Tor <i>et al.</i> (2021)	KNN	Decomposição por Modo Empírico (EMD) e Transformada Wavelet Discreta (DWT)	97,88%
<b>Este Trabalho (2025)</b>	KNN	Extração de características estatísticas, de domínio de tempo e de domínio de frequência dos dados	98,91%

**Fonte:** Elaborado pela Autora.

### 5.2.1 Limitações do estudo

Uma das limitações deste estudo refere-se ao tamanho da amostra utilizada. Embora os dados tenham permitido a obtenção de resultados relevantes, uma amostra maior poderia ampliar a generalização dos achados, especialmente no que diz respeito à diversidade das características dos participantes. Além disso, o uso de dados provenientes de uma única base restringe a comparação com estudos que utilizam conjuntos de dados distintos. Outro fator limitante foi o desempenho da máquina utilizada para as análises, pois algumas execuções chegavam a levar cerca de três horas e, em determinados casos, o computador travava, dificultando a realização de testes mais complexos ou demorados.

## 6 CONCLUSÃO E TRABALHOS FUTUROS

O presente trabalho demonstrou que o uso de sinais de EEG como ferramenta para a classificação do TDAH apresenta grande potencial, embora ainda esteja em processo de aprofundamento na literatura científica. Foi proposta uma abordagem baseada em pré-processamento eficiente, com a decomposição de sinais com EMD em conjunto com a Transformada *Wavelet*, e extração de características nos domínios do tempo e da frequência.

Os resultados obtidos indicam que a extração de características como mobilidade, RMS e desvio padrão se destaca na representação das informações relevantes do sinal de EEG, evidenciando aspectos tempo-frequência associados ao transtorno. Além disso, os classificadores avaliados SVM, KNN e RF, apresentaram desempenhos satisfatórios, com destaque para o SVM e o KNN, que alcançaram acurácias de 97,95% e 98,45%, respectivamente. Já o RF obteve desempenho inferior, com acurácia de 76,80%.

Esses resultados reforçam a efetividade das métricas extraídas e indicam que métodos baseados em distância, como o KNN, podem ser especialmente adequados para a tarefa de classificação dos sinais de EEG. Também indicam que a implementação do modelo KNN pode ter obtido resultados ótimos devido à sua simplicidade de implementação, ao contrário do SVM e do RF, que exigem a definição de um número maior de hiperparâmetros. Além disso, a natureza dos dados favorecia mais fronteiras de decisão como as do SVM e do KNN, ou seja, estavam mais linearmente separáveis, o que não seria o ideal para o RF. Mesmo com a heterogeneidade dos sinais associados ao TDAH, o KNN apresentou o melhor desempenho, possivelmente por tomar decisões com base nas amostras mais próximas no conjunto de dados, conseguindo identificar padrões locais mesmo em cenários com sobreposição entre as classes.

Em comparação com o Estado da Arte, os modelos desenvolvidos alcançaram resultados compatíveis com estudos anteriores, embora mais investigações sejam necessárias para validar a eficácia dos métodos de processamento utilizados e sua generalização em diferentes bases de dados.

### 6.1 Trabalho Futuros

No sentido de dar continuidade a esta pesquisa, é possível pensar em algumas abordagens a serem exploradas:

- Realizar outras combinações de extração de *features*, como o uso de diferentes característi-

cas estatísticas ou da Densidade Espectral de Potência de apenas duas faixas de frequência, analisando seu impacto na classificação final;

- Adaptar o modelo desenvolvido para aplicação em outras bases de dados;
- Testar outros classificadores, como arquiteturas de Redes Neurais Artificiais (RNA);
- Aplicar o modelo a outros problemas de classificação de sinais de EEG, como a detecção de TDAH com comorbidades, ou de epilepsia.

## REFERÊNCIAS

- ABDELNOUR, E.; JANSEN, M. O.; GOLD, J. A. Adhd diagnostic trends: Increased recognition or overdiagnosis? **Missouri Medicine (Mo Med)**, v. 119, n. 5, p. 467–473, September-October 2022.
- ALAJMI, L.; ALOTAIBI, A.; KAMEL, M. Siamese deep neural network for adhd detection using eeg signal. **Computers in Biology and Medicine**, Elsevier, v. 168, n. 10, p. 104593, 2024. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482524011776>>.
- ALAN, M. Turing. **Computing machinery and intelligence**. **Mind**, v. 59, n. 236, p. 433–460, 1950.
- AMERICAN PSYCHIATRIC ASSOCIATION. **Diagnostic and Statistical Manual of Mental Disorders: DSM-5**. 5th. ed. Arlington, VA: American Psychiatric Publishing, 2013. ISBN 978-0-89042-555-8.
- ARNS MARTIJN E LOO, S. K. e. S. M. B. e. H. H. e. K. J. e. A. P. e. B. T. e. B. D. Perspectiva editorial: Como psicólogos e psiquiatras infantis devem interpretar a aprovação do dispositivo pela fda? caveat emptor. **Jornal de Psicologia Infantil e Psiquiatria**, v. 57, n. 5, p. 656–658, 2016. Disponível em: <<https://acamh.onlinelibrary.wiley.com/doi/abs/10.1111/jcpp.12524>>.
- AUSTERMAN, J. Adhd and behavioral disorders: Assessment, management, and an update from dsm-5. **Cleveland Clinic Journal of Medicine**, Cleveland Clinic Foundation, v. 82, n. 11 suppl 1, p. S2–S7, 2015.
- BENICZKY, S.; SCHOMER, D. L. Eletroencefalografia: aspectos biofísicos e tecnológicos básicos importantes para aplicações clínicas. **Epileptic Disorders**, v. 22, p. 697–715, 2020. Disponível em: <<https://doi.org/10.1684/epd.2020.1217>>.
- BIAU, G.; SCORNET, E. A random forest guided tour. **TEST**, v. 25, n. 2, p. 197–227, June 2016. ISSN 1863-8260. Disponível em: <<https://doi.org/10.1007/s11749-016-0481-7>>.
- BOUDRAA, A.; CEXUS, J.; SAIDI, Z. Emd-based signal noise reduction. **International Journal of Signal Processing**, v. 1, n. 1, 2004.
- CHAUHAN, V. K.; DAHIYA, K.; SHARMA, A. Formulações e solucionadores de problemas em svm linear: uma revisão. **Artificial Intelligence Review**, v. 52, p. 803–855, 2019. Disponível em: <<https://doi.org/10.1007/s10462-018-9614-6>>.
- CORSI, M. C. Eletroencefalografia e magnetoencefalografia. In: COLLIOT, O. (Ed.). **Aprendizado de Máquina para Distúrbios Cerebrais**. Nova York, NY: Humana, 2023, (Neuromethods, v. 197). Disponível em: <[https://doi.org/10.1007/978-1-0716-3195-9\\_9](https://doi.org/10.1007/978-1-0716-3195-9_9)>.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, Springer, v. 20, n. 3, p. 273–297, 1995.
- CORTESE, S. The neurobiology and genetics of attention-deficit/hyperactivity disorder (adhd): What every clinician should know. **European Journal of Paediatric Neurology**, v. 16, n. 5, p. 422–433, 2012. ISSN 1090-3798. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S109037981200013X>>.

Electrical e-Library. **Como funciona o eletroencefalograma**. 2019. Acesso em: 28 fev. 2025. Disponível em: <<https://www.electricalibrary.com/2019/03/06/como-funciona-o-eletroencefalograma/>>.

ESAS, M. Y.; LATIFOĞLU, F. Detection of adhd from eeg signals using new hybrid decomposition and deep learning techniques. **Journal of Neural Engineering**, IOP Publishing, v. 20, n. 3, p. 036028, jun 2023. Disponível em: <<https://dx.doi.org/10.1088/1741-2552/acc902>>.

FELDMAN, H. M.; REIFF, M. I. Attention deficit–hyperactivity disorder in children and adolescents. **New England Journal of Medicine**, v. 370, n. 9, p. 838–846, 2014. Disponível em: <<https://www.nejm.org/doi/full/10.1056/NEJMcp1307215>>.

FIRST, M. B.; YOUSIF, L. H.; CLARKE, D. E.; WANG, P. S.; GOGTAY, N.; APPELBAUM, P. S. DSM-5-TR: overview of what’s new and what’s changed. **World Psychiatry**, World Psychiatric Association (WPA), Italy, v. 21, n. 2, p. 218–219, June 2022. ISSN 1723-8617.

HARRISON, P.; BROWN, M.; DAVIS, S. Machine learning in attention deficit/hyperactivity disorder: novel approaches to understanding neural mechanisms. **Translational Psychiatry**, Nature Publishing Group, v. 13, n. 1, p. 536, 2023. Disponível em: <<https://www.nature.com/articles/s41398-023-02536-w>>.

ISMAIL, F. Y.; FATEMI, A.; JOHNSTON, M. V. Cerebral plasticity: Windows of opportunity in the developing brain. **European Journal of Paediatric Neurology**, v. 21, n. 1, p. 23–48, 2017. ISSN 1090-3798. Advances in Neuromodulation in Children. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1090379816300964>>.

IYORTSUUN, N. K.; KIM, S.-H.; JHON, M.; YANG, H.-J.; PANT, S. A review of machine learning and deep learning approaches on mental health diagnosis. **Healthcare**, v. 11, n. 3, 2023. ISSN 2227-9032. Disponível em: <<https://www.mdpi.com/2227-9032/11/3/285>>.

JALILPOUR, M.; ZAREI, A.; MORADI, S. Automatic identification of children with adhd from eeg brainwaves. **Brain Sciences**, MDPI, v. 4, n. 1, p. 10, 2024. Disponível em: <<https://www.mdpi.com/2624-6120/4/1/10>>.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R.; TAYLOR, J. Statistical learning. In: **An introduction to statistical learning: With applications in Python**. [S.l.]: Springer, 2023. p. 15–67.

JANAPATI, R.; DALAL, V.; SENGUPTA, R. Advances in modern eeg-bci signal processing: A review. **Materials Today: Proceedings**, v. 80, p. 2563–2566, 2023. ISSN 2214-7853. SI:5 NANO 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785321048033>>.

KEIL, A.; DEBENER, S.; GRATTON, G.; JUNGHÖFER, M.; KAPPENMAN, E. S.; LUCK, S. J.; LUU, P.; MILLER, G. A.; YEE, C. M. Guidelines for eeg and meg. **Psychophysiology**, v. 51, n. 1, p. 1–21, 2014. Disponível em: <<https://doi.org/10.1111/psyp.12147>>.

KOSHELEFF, A. R.; MASON, O.; JAIN, R.; KOCH, J.; RUBIN, J. Functional impairments associated with adhd in adulthood and the impact of pharmacological treatment. **Journal of Attention Disorders**, v. 27, n. 7, p. 669–697, 2023. PMID: 36876491. Disponível em: <<https://doi.org/10.1177/10870547231158572>>.

NOGARE, D. **Performance de Machine Learning: Matriz de Confusão**. 2020. Acesso em: 22 jul. 2025. Disponível em: <<https://diegonogare.net/2020/04/performance-de-machine-learning-matriz-de-confusao>>.

NUNEZ, P. L.; SRINIVASAN, R. Eletroencefalograma. **Scholarpedia**, Scholarpedia, v. 2, n. 2, p. 1348, 2007. Disponível em: <<https://doi.org/10.4249/scholarpedia.1348>>.

PADFIELD, N.; ZABALZA, J.; ZHAO, H.; MASERO, V.; REN, J. Eeg-based brain-computer interfaces using motor-imagery: Techniques and challenges. **Sensors**, v. 19, n. 6, 2019. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/19/6/1423>>.

PATLE ARTI E CHOUHAN, D. S. Funções do kernel svm para classificação. In: **Conferência Internacional de 2013 sobre Avanços em Tecnologia e Engenharia (ICATE)**. [S.l.: s.n.], 2013. p. 1–9.

POLANCZYK, G.; LIMA, M. S. de; HORTA, B. L.; BIEDERMAN, J.; ROHDE, L. A. The worldwide prevalence of adhd: A systematic review and metaregression analysis. **American Journal of Psychiatry**, v. 164, n. 6, p. 942–948, 2007. PMID: 17541055. Disponível em: <<https://doi.org/10.1176/ajp.2007.164.6.942>>.

RAINIO, O.; TEUHO, J.; KLEN, R. Evaluation metrics and statistical tests for machine learning. **Scientific Reports**, 2024.

READ, G. L.; INNIS, I. J. Eletroencefalografia (eeg). In: MATTHES, J.; DAVIS, C. S.; POTTER, R. F. (Ed.). **Enciclopédia Internacional de Métodos de Pesquisa em Comunicação**. Wiley, 2017. Disponível em: <<https://doi.org/10.1002/9781118901731.iecrm0080>>.

SCHAUL, N. The fundamental neural mechanisms of electroencephalography. **Electroencephalography and Clinical Neurophysiology**, v. 106, n. 2, p. 101–107, 1998. ISSN 0013-4694. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0013469497001119>>.

SMITH, M. Hyperactive around the world? the history of adhd in global perspective. **Social History of Medicine**, Oxford University Press, v. 30, n. 4, p. 767–787, 2017.

TASPINAR, G.; OZKURT, N. A review of adhd detection studies with machine learning methods using rsfmri data. **NMR in Biomedicine**, v. 37, n. 8, p. e5138, 2024. Disponível em: <<https://analyticalsciencejournals.onlinelibrary.wiley.com/doi/abs/10.1002/nbm.5138>>.

TOR, H. T.; OOI, C. P.; LIM-ASHWORTH, N. S.; WEI, J. K. E.; JAHMUNAH, V.; OH, S. L.; ACHARYA, U. R.; FUNG, D. S. S. Automated detection of conduct disorder and attention deficit hyperactivity disorder using decomposition and nonlinear techniques with eeg signals. **Computer Methods and Programs in Biomedicine**, v. 200, p. 105941, 2021. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260721000158>>.

UDDIN, M.; WANG, Y.; WOODBURY-SMITH, M. Artificial intelligence for precision medicine in neurodevelopmental disorders. **npj Digital Medicine**, Nature Publishing Group, v. 2, n. 1, p. 112, 2019. ISSN 2398-6352. Disponível em: <<https://doi.org/10.1038/s41746-019-0191-0>>.

ZHANG, H.; ZHOU, Q. Q.; CHEN, H. *et al.* Os princípios aplicados dos métodos de análise de eeg em neurociência e neurologia clínica. **Military Medical Research**, v. 10, p. 67, 2023. Disponível em: <<https://doi.org/10.1186/s40779-023-00502-7>>.

ZHANG, S. Challenges in knn classification. **IEEE Transactions on Knowledge and Data Engineering**, v. 34, n. 10, p. 4663–4675, 2022.

ZHOU, Z.-H. **Machine learning**. [S.l.]: Springer nature, 2021.



## APÊNDICE A –

### A.1 Código

Os *scripts* implementados em plataforma Visual Studio Code®, versão 1.101.2, Linguagem Python versão 3.12.6 estão disponíveis no GitHub. O repositório pode ser acessado através do QR CODE abaixo e do link <<https://github.com/IaraAmancio/AnaliseEEG>>.

