



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA ELÉTRICA E BIOMÉDICA

Classificação de Sinais EEG em Indivíduos com TEA Utilizando Redes Neurais Convolucionais e Espectros HHS

MARIA FERNANDA DE LEÃO FAVA

UFPA / ITEC / FEEB
Campus Universitário do Guamá
Belém-Pará-Brasil

2025

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA ELÉTRICA E BIOMÉDICA

MARIA FERNANDA DE LEÃO FAVA

**Classificação de Sinais EEG em Indivíduos com TEA Utilizando
Redes Neurais Convolucionais e Espectros HHSA**

Trabalho de Conclusão de Curso submetido ao
Curso de Graduação em Engenharia Biomédica
da Universidade Federal do Pará (UFPA), como
requisito parcial para a obtenção do grau de
Bacharel em Engenharia Biomédica.

Orientador: Prof^a Me. Suzana Cescon de Souza

UFPA / ITEC / FEEB
Campus Universitário do Guamá
Belém-Pará-Brasil

2025

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

F272c Fava, Maria Fernanda de Leão.
Classificação de Sinais EEG em Indivíduos com TEA
Utilizando Redes Neurais Convolucionais e Espectros HHSA /
Maria Fernanda de Leão Fava. — 2025.
35 f. : il. color.

Orientador(a): Prof^ª. MSc. Suzana Cescon de Souza
Coorientador(a): Prof. Dr. Antônio Pereira Junior
Trabalho de Conclusão (Graduação) - Universidade Federal do
Pará, Instituto de Tecnologia, Faculdade de Engenharia Elétrica,
Belém, 2025.

1. CNN. 2. HHSA. 3. EEG. 4. Redes Neurais. 5.
Classificação TEA. I. Título.

CDD 006.32

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Classificação de Sinais EEG em Indivíduos com TEA Utilizando Redes Neurais Convolucionais e Espectros HNSA

AUTOR: MARIA FERNANDA DE LEÃO FAVA

Trabalho de Conclusão de Curso submetido ao Curso de Graduação em Engenharia Biomédica da Universidade Federal do Pará (UFPA), como requisito parcial para a obtenção do grau de Bacharel em Engenharia Biomédica.

BANCA EXAMINADORA:

Prof^a Me. Suzana Cescon de Souza
(Orientador - FEEB / UFPA)

Prof. Dr. Antônio Pereira Junior
(Coorientador - FEEB / UFPA)

Prof. Dr. Ana Carolina Quintão Siravenha Müller
(Avaliador Interno - FEEB / UFPA)

Prof. Dr. Caio de Oliveira Bastos
(Avaliador Externo - Instituto Tecnológico Vale)

VISTO:

Prof. Dra. Carminda Célia Moura de Moura Carvalho
(Diretora FEEB/ITEC/UFPA)

A todos meus familiares, amigos e entes mais queridos.

Agradecimentos

Agradeço, em primeiro lugar, à minha parceira, melhor amiga e família, **Enayle Rayane Silva Madeira**, por ter sido meu porto seguro ao longo desta trajetória. Sua presença constante, seu acolhimento incondicional e o ambiente de amor e liberdade que proporcionou foram essenciais para que eu me sentisse fortalecida e capaz de continuar, mesmo nos momentos mais desafiadores.

Estendo minha gratidão à minha família e aos amigos que me apoiaram com carinho e compreensão. Em especial, à minha avó, **Maria Lúcia Pinheiro de Leão**, que me criou como uma filha, transmitindo valores fundamentais, amor e dedicação — sendo meu alicerce desde o início.

Registro também meus sinceros agradecimentos aos amigos **Vinícius Eduardo Santos de Souza** e **Ramon Gabriel Conceição de Miranda**, que estiveram ao meu lado como pilares de força durante períodos de dificuldade, compartilhando comigo lutas e conquistas.

À minha orientadora, **Prof.^a Me. Suzana Cescon de Souza**, expresse meu mais profundo reconhecimento. Sua orientação competente, acolhedora e inspiradora foi determinante para meu crescimento acadêmico e pessoal. Sua dedicação não apenas despertou em mim o interesse por uma nova área de estudo, mas também abriu caminhos no universo da docência e da pesquisa, pelos quais espero seguir e retribuir no futuro.

Ao meu coorientador, **Prof. Dr. Antonio Pereira Junior**, agradeço pela colaboração valiosa, pelas contribuições técnicas e pelo suporte durante a construção deste trabalho.

Agradeço ainda aos meus **filhos felinos (Bernardo, Koda, Rocky, Milo, Kayden, Liz e Calango)**, cuja nem sempre silenciosa companhia trouxe conforto em noites de intenso trabalho.

Por fim, sou grata à **Universidade Federal do Pará (UFPA)**, ao **Instituto de Tecnologia (ITEC)** e à **Faculdade de Engenharia Elétrica e Biomédica (FEEB)** pela formação sólida, pelo ambiente de aprendizado e pela oportunidade de crescimento ao longo da minha graduação.

“A vida é naturalmente difícil, então, se está sendo fácil, você está fazendo errado.”
(UVERworld, 2011)

Resumo

O trabalho investiga a classificação de sinais EEG (eletroencefalograma) de indivíduos com Transtorno do Espectro Autista (TEA) utilizando Redes Neurais Convolucionais (CNN) e Análise Espectral de Holo-Hilbert (HHS). A pesquisa objetiva superar as limitações dos métodos diagnósticos atuais — majoritariamente comportamentais e subjetivos — por meio de uma abordagem computacional não invasiva e objetiva. Os dados, obtidos de 12 participantes (6 TEA e 6 controle), foram convertidos em mapas espectrais tridimensionais representando a modulação de frequência e amplitude em canais cerebrais (P3 e P4). Esses mapas foram utilizados como entrada para uma CNN personalizada, treinada com técnicas de regularização como *Dropout*, *Batch Normalization*, *Data Augmentation* e *Early Stopping*. A CNN apresentou desempenho promissor mesmo com base de dados limitada, com acurácia média de 82,99% e AUC de 0,92 na validação cruzada. Os resultados indicam a viabilidade do uso de representações espectro-temporais avançadas combinadas com aprendizado profundo para auxiliar no diagnóstico precoce e mais preciso do TEA.

Palavras-chave: Transtorno do Espectro Autista, Eletroencefalograma, Análise Holo-Hilbert, Redes Neurais Convolucionais, Classificação automática

Abstract

The work investigates the classification of EEG signals (electroencephalogram) of individuals with autistic spectrum disorder (ASD) using convolutionary neural networks (CNN) and spectral analysis of Holo-Hilbert (HHSA). Research aims to overcome the limitations of current diagnostic methods - mostly behavioral and subjective - through a noninvasive and objective computational approach. The data, obtained from 12 participants (6 ASD and 6 Control), were converted to three -dimensional spectral maps representing the frequency and amplitude modulation in brain channels (P3 and P4). These maps were used as an entry for a personalized CNN, trained with regularization techniques such as Dropout, Batch Normalization, Data Augmentation and Early Stopping. CNN performed promising performance even with limited database, with an average accuracy of 82,99% and AUC of 0,92 in cross validation. The results indicate the viability of the use of advanced spectrum-time representations combined with deep learning to assist in early and more accurate diagnosis of ASD.

Key-words: Autistic spectrum disorder, Electroencephalogram, Holo-Hilbert analysis, Convolutionary Neural Networks, Automatic Classification

Lista de figuras

Figura 1 – Roda do Autismo. O indivíduo demonstra alta suscetibilidade em apresentar <i>meltdowns</i> , sensibilidade a barulho e textura, ansiedade e interesses restritos.	4
Figura 2 – Posicionamento dos eletrodos no sistema 10-20.	6
Figura 3 – Comparação entre senoide e IMF.	8
Figura 4 – Demonstração do EMD decomposto em 7 IMFs.	9
Figura 5 – Mapa espectral obtido de um indivíduo com TEA do canal P3.	10
Figura 6 – Demonstração do Zero Padding. O <i>kernel</i> aplicado é um vetor com 3 pesos e o volume da entrada é 7.	12
Figura 7 – Demonstração do Max Pooling. A matriz receptiva é uma 4x4 e resulta em uma 2x2.	13
Figura 8 – Demonstração do comportamento das partições no decorrer das iterações.	15
Figura 9 – Setup do experimento.	16
Figura 10 – Apresentação dos elementos utilizados como alvo e distratores de forma randômica.	17
Figura 11 – Fluxograma da aquisição de sinais do EEG.	17
Figura 12 – Leitura do mapa espectral.	18
Figura 13 – Comparação entre um sinal controle à esquerda e TEA à direita.	19
Figura 14 – Imagem original e suas variações geradas artificialmente.	20
Figura 15 – Pipeline geral da programação.	21
Figura 16 – Arquitetura da CNN personalizada.	22
Figura 17 – Gráfico do comportamento da acurácia em função das épocas.	25
Figura 18 – Gráfico do comportamento da função de perda em função das épocas.	26
Figura 19 – Curva ROC gerada pela CNN personalizada.	27
Figura 20 – Matriz de confusão gerada pela CNN personalizada.	28

Lista de tabelas

Tabela 1 – Letras e localizações dos eletrodos no sistema internacional 10–20.	6
Tabela 2 – Resultados de acurácia por fold e métricas finais	26

Lista de abreviaturas e siglas

AM	Modulação em Amplitude
AUC	Área sob a Curva ROC
BN	Normalização em Lote (Batch Normalization)
CNN	Rede Neural Convolucional
EEG	Eletroencefalograma
EMD	Decomposição por Modos Empíricos
FM	Modulação em Frequência
FEEB	Faculdade de Engenharia Elétrica e Biomédica
HHSa	Hilbert-Huang Spectral Analysis
HHT	Transformada de Hilbert-Huang
IMF	Função Intrínseca de Modo
ITEC	Instituto de Tecnologia
ReLU	Unidade Linear Retificada
ROC	Curva Característica de Operação do Receptor
TCLE	Termo de Consentimento Livre e Esclarecido
TDAH	Transtorno de Déficit de Atenção e Hiperatividade
TEA	Transtorno do Espectro Autista
UFPA	Universidade Federal do Pará

Lista de símbolos

$X(t)$	Sinal original em função do tempo
$c_i(t)$	i-ésima Função Intrínseca de Modo (IMF)
$r_n(t)$	Resíduo final da decomposição EMD
$a_i(t)$	Amplitude instantânea do i-ésimo IMF
$\theta_i(t)$	Fase instantânea do i-ésimo IMF
$\omega_i(t)$	Frequência instantânea do i-ésimo IMF
$\Omega_{i,k}(t)$	Frequência instantânea do k-ésimo IMFAM (segunda camada da HHSA)
$a_{i,k}(t)$	Amplitude instantânea do k-ésimo IMFAM
$P(\omega, \Omega)$	Potência espectral no espaço Holo-Hilbert
P_{total}	Potência total integrada no espectro Holo-Hilbert
μ_B	Média do mini-batch (Batch Normalization)
σ_B	Desvio padrão do mini-batch (Batch Normalization)
x_i	Ativação de entrada para normalização
\hat{x}_i	Ativação normalizada
γ	Fator de escala aprendido na normalização
β	Fator de deslocamento aprendido na normalização
P	Quantidade de zeros adicionados no padding (zero-padding)
F	Tamanho do filtro convolucional (kernel)

Sumário

1	CONSIDERAÇÕES INICIAIS	1
1.0.1	INTRODUÇÃO	1
1.1	Objetivos do Trabalho	2
1.1.1	Objetivo Geral	2
1.1.2	Objetivos Específicos	2
1.2	Estrutura do Documento	2
2	REFERENCIAL TEÓRICO	3
2.1	Transtorno do Espectro Autista	3
2.2	Eletroencefalograma (EEG)	5
2.3	Análise Espectral de Holo-Hilbert	7
2.4	Arquitetura da Rede Neural Convolutacional (CNN)	10
2.4.1	Camada de Convolução	10
2.4.2	Camada de Normalização em Lote (<i>Batch Normalization</i>)	12
2.4.3	Camada de Subamostragem (<i>Max Pooling</i>)	13
2.4.4	Camada Totalmente Conectada (<i>Fully Connected Layers</i>)	13
2.4.5	Camada de Regularização (<i>Data Augmentation</i>)	14
2.4.6	Camada de Regularização (<i>Dropout Layer</i>)	14
2.4.7	Regra de Parada (<i>Early Stopping</i>)	14
2.4.8	Algoritmo de Otimização (<i>ADAM</i>)	14
2.4.9	Validação Cruzada <i>K Fold</i>	15
3	METODOLOGIA	16
3.1	Participantes	16
3.2	Setup Experimental	16
3.3	Aquisição de Sinais	16
3.4	Análise Espectral de Holo-Hilbert	18
3.5	Banco de Dados	19
3.6	Rede Neural Convolutacional	20
3.7	Métricas de Desempenho	23
4	RESULTADOS	25
4.1	Monitoramento do treinamento	25
4.2	Validação Cruzada com Aumento de Dados	26
4.3	Curva ROC e AUC	26
4.4	Matriz de Confusão	27
5	DISCUSSÃO	29
6	CONCLUSÃO	31

Referências 32

1 CONSIDERAÇÕES INICIAIS

1.0.1 INTRODUÇÃO

O Transtorno do Espectro Autista (TEA) é um distúrbio do neurodesenvolvimento que afeta a comunicação, a interação social e apresenta comportamentos restritos e repetitivos. A complexidade do TEA, associada à sua variabilidade entre indivíduos, torna o diagnóstico e a intervenção desafiadores, sendo fundamental a utilização de ferramentas que permitam a análise detalhada do funcionamento cerebral.

Entre essas ferramentas, o eletroencefalograma (EEG) destaca-se por sua capacidade de registrar a atividade elétrica do cérebro de maneira não invasiva, oferecendo informações valiosas sobre padrões neurais que podem diferir significativamente entre indivíduos com TEA e grupos controle. Técnicas avançadas de análise de sinais, como a Análise do Espectro Holo-Hilbert (HESA), possibilitam a extração de características não lineares e não estacionárias, enriquecendo a interpretação dos dados de EEG.

Além disso, métodos de inteligência artificial, em particular as Redes Neurais Convolucionais (CNNs), têm se mostrado promissores na classificação automática de padrões complexos, permitindo uma abordagem inovadora no estudo do TEA. A combinação de sinais de EEG com técnicas de processamento avançado e aprendizado de máquina oferece a possibilidade de desenvolver modelos capazes de auxiliar no diagnóstico e na compreensão das diferenças neurofisiológicas associadas ao espectro autista.

Diante disso, este trabalho busca integrar conhecimentos de neurociência, análise de sinais e inteligência artificial, com o objetivo de propor uma abordagem metodológica robusta para a investigação de padrões cerebrais em indivíduos com TEA.

Este estudo justifica-se pela necessidade de:

- Desenvolver ferramentas computacionais auxiliares ao diagnóstico clínico
- Explorar padrões neuroelétricos como biomarcadores potenciais do TEA
- Superar limitações de técnicas tradicionais para avaliação e diagnóstico de TEA
- Aplicar um método de classificação automática mesmo com conjuntos de dados limitados

1.1 Objetivos do Trabalho

1.1.1 Objetivo Geral

Aplicar e avaliar um modelo de classificação do Transtorno do Espectro Autista (TEA) utilizando Redes Neurais Convolucionais (CNN) aplicado a dados extraídos por meio da HHSA.

1.1.2 Objetivos Específicos

1. Revisar e selecionar bases de dados neurofisiológicos relevantes (EEG) contendo registros de indivíduos com TEA e controles típicos
2. Aplicar a HHSA para decompor e extrair características espectrais e temporais dos sinais neurofisiológicos
3. Aplicar e treinar uma Rede Neural Convolucional (CNN) utilizando as características extraídas via HHSA como entradas do modelo
4. Avaliar o desempenho do modelo CNN em termos de acurácia, sensibilidade, especificidade e área sob a curva ROC na classificação binária
5. Discutir as implicações clínicas e computacionais dos resultados obtidos para apoio diagnóstico do TEA

1.2 Estrutura do Documento

Este documento organiza-se em seis capítulos fundamentais:

- **Capítulo 1:** Apresenta o contexto, justificativa e objetivos da pesquisa
- **Capítulo 2:** Fundamentação teórica sobre TEA, EEG, HHSA e arquiteturas CNN
- **Capítulo 3:** Detalhamento metodológico do banco de dados e arquitetura da CNN
- **Capítulo 4:** Apresentação dos dados obtidos
- **Capítulo 5:** Discussão dos dados obtidos
- **Capítulo 6:** Conclusões e perspectivas futuras
- **Referências:** Bibliografia consultada e fundamentação científica


2 REFERENCIAL TEÓRICO

2.1 Transtorno do Espectro Autista

O Transtorno do Espectro Autista (TEA) é um transtorno do neurodesenvolvimento caracterizado por déficits na comunicação, na interação social e pela presença de comportamentos restritos e repetitivos relacionados a interesses ou atividades ([MAROTTA et al., 2020](#); [LORD et al., 2020](#)). Do ponto de vista clínico, a manifestação desse transtorno pode gerar diferentes graus de comprometimento pessoal e social, variando de acordo com a posição do indivíduo dentro do espectro ([BRIHADISWARAN et al., 2019](#); [BOSETTI et al., 2024](#)).

Dentro desse espectro, baseado no Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-5), a severidade do autismo desdobra-se entre requer pouco apoio (nível 1, leve), necessita de apoio substancial (nível 2, moderado) e requer suporte muito substancial (nível 3, severo), classificados conforme dois domínios: déficits sociais e comunicativos e presença de padrões repetitivos e restritos. O primeiro domínio diz respeito a, por exemplo, a incapacidade de realizar contato visual ou alguma forma de comunicação de forma natural. O segundo domínio refere-se a movimentos repetitivos, como bater palmas, até intensa preocupação com fatos ou objetos. A presença desses traços em um indivíduo podem limitar sua experiência individual e, por isso, podem ser considerados uma deficiência. Ademais, outras condições desfavoráveis como ansiedade, insônia e depressão acabam por impactar na qualidade de vida do autista ([WAIZBARD-BARTOV et al., 2023](#)). Outros especialistas da área demonstraram como o comportamento de um autista pode diferir dentro do mesmo nível de suporte ([JACK, 2022](#)) ao utilizar a roda do autismo (*autism wheel*), o qual destaca a suscetibilidade que aquele indivíduo tem ao manifestar determinado sintoma. Na Figura 1 é possível perceber o perfil de um indivíduo arbitrário.

Figura 1 – Roda do Autismo. O indivíduo demonstra alta suscetibilidade em apresentar *melt-downs*, sensibilidade a barulho e textura, ansiedade e interesses restritos.



Fonte: Psychology Today, 2022

Dessa forma, é possível perceber a severidade dos sintomas divergindo de acordo com o tipo de perfil analisado. Além disso, a depender das alterações no tronco cerebral, no córtex pré-frontal, na amígdala, no sistema límbico e no hipotálamo, o sono, ansiedade, hipersensibilidade sensorial, flexibilidade cognitiva, reconhecimento de expressões faciais, regulação emocional podem ser afetados e, por isso, o autismo está associado a outras comorbidades como atraso e déficits cognitivos, epilepsia ou anomalias eletroencefalográficas, distúrbios do sono, neuropatias, síndrome de Tourette, ansiedade, transtorno do déficit de atenção hiperatividade (TDAH) e até expandir para outros sistemas se manifestando na forma de distúrbios imunológicos ou doenças gastrointestinais (BHARATH et al., 2019).

O Censo Demográfico de 2022 identificou aproximadamente 2,4 milhões de pessoas com diagnóstico de TEA, correspondendo a cerca de 1,2% da população brasileira. Entre os grupos etários, a maior prevalência foi observada entre crianças de 5 a 9 anos (2,6%). O diagnóstico precoce do TEA está fortemente associado à melhoria da qualidade de vida, ao permitir intervenções direcionadas para dificuldades comportamentais e cognitivas, conduzidas por profissionais especializados (SANTARONE et al., 2023), e também contribui para a redução de custos no sistema de saúde (NEO et al., 2023).

A origem do TEA ainda não está totalmente esclarecida, sendo considerada multifatorial. Avanços recentes em neurogenética têm apontado que mutações em genes relacionados ao controle da tradução de proteínas, à síntese proteica e ao funcionamento sináptico poderiam contribuir para alterações na poda e na homeostase sináptica, o que sustentaria a hipótese de que a disfunção sináptica estaria entre os mecanismos centrais do TEA (PAGANI et al., 2021).

Por outro lado, outros autores (UPADHYAY et al., 2021) defendem uma perspectiva mais abrangente, ressaltando a interação entre fatores genéticos e ambientais, como a exposição a fármacos durante a gestação, além de evidências de alterações neuroanatômicas e funcionais observadas em exames de imagem, especialmente em estruturas do sistema límbico, como a amígdala. Dessa forma, observa-se que, embora existam hipóteses consistentes, ainda não há um consenso definitivo sobre a etiologia do TEA, sendo mais aceita atualmente a ideia de que sua origem decorre da interação entre predisposição genética e influências ambientais.

Evidências na literatura (SANTARONE et al., 2023) indicam que, diante de alterações nas funções fisiológicas, as respostas cerebrais desses indivíduos tendem a divergir significativamente em comparação com aqueles fora do espectro. Ao analisar atividades elétricas cerebrais de indivíduos no espectro é possível detectar comportamentos não-epileptiformes e epileptiformes anormais como picos rápidos de atividade elétrica (*spikes*), picos mais largos e lentos (*sharp waves*), atividade elétrica em baixa frequência (*slow-waves*) e descargas generalizadas (*generalized spiked-waves*) e tais sinais podem ser utilizados pelo EEG para classificar grupos controle e TEA (BRIHADISWARAN et al., 2019; NICOTERA et al., 2019).

2.2 Eletroencefalograma (EEG)


O eletroencefalograma (EEG) é um exame que mede a atividade elétrica do córtex cerebral em diversas regiões do cérebro, utilizando eletrodos dispostos no couro cabeludo e abrangendo desde regiões centrais até occipitais. Esses eletrodos são pequenos dispositivos organizados conforme sistemas de posicionamento, como o sistema 10-20, os quais são responsáveis pela captação da atividade elétrica (BISSARO et al., 2021; PLAIN; PLAIN, 2021).

O sistema de organização mais utilizado é o 10-20, que estabelece intervalos de 10% e 20% entre cada eletrodo posicionado. Os eletrodos localizados no hemisfério esquerdo do escalpo possuem numeração ímpar, enquanto os do hemisfério direito apresentam numeração par, sendo suas iniciais diretamente relacionadas à localização do eletrodo. A Tabela 1 apresenta as letras e localizações mais comuns no sistema 10-20, enquanto que a Figura 2 explana a disposição dos eletrodos no couro cabeludo.

Tabela 1 – Letras e localizações dos eletrodos no sistema internacional 10–20.

Letra	Localização	Observação
Fp	Frontal polar (testa)	Próximo à linha do cabelo, acima da testa
F	Frontal	Relacionado ao lobo frontal
C	Central	Linha central do crânio (não corresponde a uma estrutura anatômica específica)
P	Parietal	Região parietal do córtex
T	Temporal	Região temporal (lateral da cabeça)
O	Occipital	Região occipital (posterior da cabeça)
A / M	Auricular / Mastoide	Usado próximo à orelha, muitas vezes como eletrodo de referência
G	Ground (Terra)	Eletrodo de aterramento, não registra atividade cerebral, apenas completa o circuito do EEG

Figura 2 – Posicionamento dos eletrodos no sistema 10-20.



o que tange aos eletrodos e seus posicionamentos, cada um traduz uma área diferente do cérebro e tem o potencial de demonstrar anomalias nos sinais de EEG originado de distúrbios neurológicos. Os canais P3 e P4, em especial, são amplamente utilizados devido a sua representação: são importantes marcadores de doenças psiquiátricas (BORRA; MAGOSSO et al., 2021). A escolha dos canais também pode ser explicada pela sua localização sobre o córtex parietal, região diretamente associada a processos de atenção visual, integração espacial e controle da exploração visuo-motora. Essas funções são fundamentais para tarefas de cancelamento visual, que exigem a detecção de alvos entre múltiplos distratores. Estudos recentes apontam que indivíduos com TEA apresentam alterações significativas na ativação parietal e na conectividade funcional envolvendo esses eletrodos, sobretudo em bandas de frequência como teta e delta, além de diferenças na amplitude de potenciais relacionados a eventos (ERPs) (TSENG et al., 2024). Dessa forma, os canais P3 e P4 revelam-se particularmente informativos para investigar padrões de processamento atencional em indivíduos com TEA.

Os sinais de EEG têm sido amplamente utilizados na literatura para rastrear anormalidades cerebrais, sendo este um método não-invasivo, barato e portátil em comparação com outros métodos associados a neuroimagens. Além disso, sua flexibilidade permite a coleta em diversos estados e idades, podendo desempenhar um papel primordial no diagnóstico de autismo na infância (NEO et al., 2023).

O neurônio é a menor unidade funcional do sistema nervoso e a base para compreender o comportamento elétrico cerebral. É composto por um núcleo (soma) e uma parte alongada, o axônio, responsável por transmitir informações a outros neurônios, que recebem os estímulos por meio dos dendritos (ALMEIDA et al., 2023). A atividade elétrica registrada pelo EEG resulta da somação sincrônica dos potenciais pós-sinápticos gerados predominantemente pelas células piramidais do córtex cerebral. Quando um número suficiente dessas células é ativado simultaneamente (atingindo o limiar), ocorrem campos elétricos extracelulares com amplitude suficiente para serem detectados por eletrodos na superfície do couro cabeludo, com sinais geralmente na ordem de microvolts (NEO et al., 2023; SOUZA et al., 2022; MICHEL; HE, 2019).

2.3 Análise Espectral de Holo-Hilbert

Holo-Hilbert Spectrum Analyses ou HHSa é uma técnica de análise de sinais capaz de separar um sinal em modulações de frequência (FM) e modulações de amplitude (AM), mostrando como a frequência varia (FM) ou como a intensidade muda (AM) ao longo do tempo. Trata-se de um método analítico derivado da Transformada de Hilbert-Huang (HHT), utilizado para analisar sistemas complexos e não lineares (HUANG et al., 1998; HUANG et al., 2016), e é aplicado após a decomposição adaptativa do sinal pelo *Empirical Mode Decomposition* (EMD). Sua aplicação permite a análise detalhada de sinais não lineares e não estacionários, representando de forma completa as variações de amplitude e frequência. Esse potencial torna a HHSa especialmente eficaz para revelar características dimensionais e não lineares de sinais de EEG, oferecendo vantagens em relação a métodos tradicionais como Fourier e Wavelet. (CHANG et al., 2022; JUAN et al., 2021).

A HHSa é implementada seguindo as seguintes etapas abaixo:

1. Decomposição do sinal usando EMD. Matematicamente, a decomposição de um sinal $X(t)$ através do EMD pode ser representada como:

$$X(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (2.1)$$

onde $c_i(t)$ são os IMFs extraídos e $r_n(t)$ representa o resíduo final. Cada IMFs é obtido após um processo de peneiração criterioso de forma que, para ser considerado um IMF, é necessário atender aos seguintes critérios: 1) número de máximos + número de mínimos e

o número de vezes que o sinal cruza o eixo zero devem ser iguais ou diferir no máximo em 1 para atender a um comportamento oscilatório local e 2) média dos envelopes superior e inferior tender a zero em todos os pontos a fim de manter a simetria local (CHANG et al., 2022; JUAN et al., 2021).

2. Para extrair essas informações, aplica-se a *Transformada de Hilbert* em cada IMF, permitindo representar o sinal na forma AM-FM (*Amplitude Modulation - Frequency Modulation*):

$$c_i(t) = a_i(t) \cos(\theta_i(t)) \quad (2.2)$$

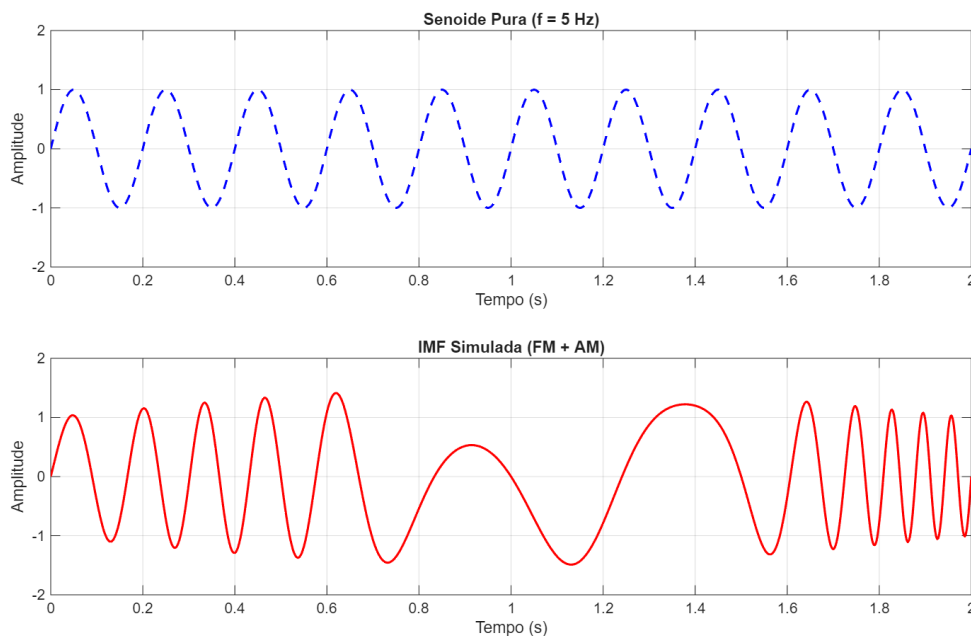
em que:

- $a_i(t)$ é a amplitude instantânea (envelope);
- $\theta_i(t)$ é a fase instantânea, relacionada à frequência instantânea por:

$$\theta_i(t) = \int \omega_i(\tau) d\tau \quad (2.3)$$

Na Figura 3, é possível comparar melhor o comportamento de uma IMF em comparação com uma senoide. A senoide (linha tracejada) apresenta frequência e amplitude constantes, enquanto a IMF (linha contínua) possui variações de frequência (FM) e amplitude (AM) ao longo do tempo, mantendo a oscilação centrada no zero:

Figura 3 – Comparação entre senoide e IMF.




3. A representação completa do sinal após a aplicação combinada do EMD e da Transformada de Hilbert (ou Transformada Hilbert-Huang - HHT) é expressa por:

$$X(t) = \sum_{i=1}^n I_i(t) = \sum_{i=1}^n a_i(t) \cos \theta_i(t) = \Re \left\{ \sum_{i=1}^n a_i(t) e^{j \int \omega_i(\tau) d\tau} \right\} \quad (2.4)$$

Onde $\Re \{ \}$ é o operador que extrai a parte real do sinal, $I_i(t)$ é o i -ésimo IMF_{FM} , e $a_i(t)$ e $\omega_i(t)$ representam, respectivamente, a amplitude e a frequência instantânea do i -ésimo IMF_{FM} no tempo t , obtidos após a aplicação do EMD de primeira camada.

O resultado obtido assemelha-se com o da figura 4:

Figura 4 – Demonstração do EMD decomposto em 7 IMFs.



Fonte: Feng et al. (2019).

4. Na segunda camada, o envelope dos IMFs adquiridos é aplicado na seguinte equação:

$$\hat{a}_i(t) = \Re \left\{ \sum_{k=1}^m a_{i,k}(t) e^{j \int \Omega_{i,k}(\tau) d\tau} \right\} \quad (2.5)$$

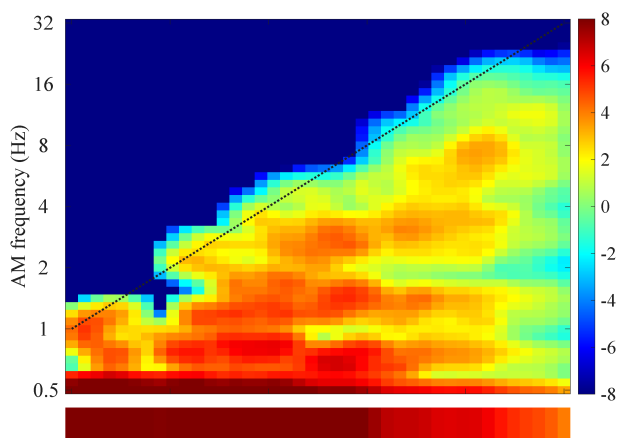
Onde $a_{i,k}(t)$ e $\Omega_{i,k}(\tau)$ são as amplitudes e frequências instantâneas do K -ésimo IMF_{AM} decomposto do i -ésimo IMF_{FM} , respectivamente, no tempo t .

5. Integrar a potência $|a_{i,k}(t)|^2$ com as frequências instantâneas $\omega_L(t)$ e $\Omega_{i,k}(t)$ ao longo do tempo todos os pontos de todas as IMF_{FM} s e IMF_{AM} s para obter o mapa tridimensional do espectro de Holo-Hilbert, ou seja $(\omega, \Omega, P(\omega, \Omega))$.

$$P_{total} = \int \int P_s(\omega, \Omega) d\omega d\Omega \quad (2.6)$$

Ao final do processo, é possível obter o seguinte mapa espectral:

Figura 5 – Mapa espectral obtido de um indivíduo com TEA do canal P3.



2.4 Arquitetura da Rede Neural Convolutacional (CNN)

As *Convolutional Neural Networks* (CNNs) foram inicialmente introduzidas por Yann LeCun et al. 1998 com o modelo LeNet-5 utilizado na classificação de dígitos manuscritos. Seu potencial em um contexto de inteligência artificial e modernidade tem sido amplamente discutido e utilizado no campo da medicina e bioinformática para estudar possíveis diagnósticos complementares. Tal feito poderia facilitar o tratamento médico, proporcionar o diagnóstico sem intervenção humana e acessível sem custos complementares de deslocamento e infraestrutura (LATIF et al., 2024; LECUN et al., 1998).

O aprendizado profundo (*deep learning*) já se mostrou uma ferramenta poderosa e eficaz no processamento de dados e na tomada de decisões. As CNNs vêm sendo amplamente utilizadas no campo da pesquisa médica diagnóstica e, em alguns casos, já se equiparam a médicos humanos. Um feito notável é o CheXNet, uma CNN treinada com 100.000 imagens de raio-X frontais, que apresentou desempenho superior ao de quatro especialistas da área (YADAV; JADHAV, 2019). Desde sua implementação em 1998, diversos aprimoramentos foram propostos, como as arquiteturas ConvNeXt, RegNet, e ResNet, possibilitando a aplicação em tarefas complexas de classificação de Glaucoma (BARROS et al., 2023).

A CNN é composta por diferentes tipos de camadas, cada uma com funções específicas que, em conjunto, permitem o processamento de imagens e a extração de características relevantes para a tarefa de classificação (LI; JOHNSON; YEUNG, 2023).

2.4.1 Camada de Convolução

É geralmente a primeira camada da arquitetura, responsável por extrair características da imagem. Como primeira camada, ela captura características mais gerais, como bordas, manchas, texturas e padrões geométricos. A camada possui um conjunto de filtros (*kernels*) aprendíveis,

cada um focado em detectar um tipo específico de característica. Cada filtro possui dimensões espaciais definidas, como 3×3 ou 5×5 , e profundidade igual ao número de canais da imagem de entrada (por exemplo, 3 para imagens RGB, representando os canais vermelho, verde e azul). Assim, um filtro aplicado a uma imagem RGB terá dimensão, por exemplo, $3 \times 3 \times 3$. Durante o processamento, cada filtro percorre a imagem realizando a operação matemática denominada convolução, gerando um mapa de ativação bidimensional, com cada valor neste mapa indicando a intensidade com que a característica buscada foi encontrada naquela região da imagem. Durante o treinamento, a rede aprende automaticamente os valores de cada filtro de forma a detectar padrões relevantes (LI; JOHNSON; YEUNG, 2023; BARROS et al., 2023).

Como geralmente são utilizados vários filtros em cada camada de convolução, o resultado final é um conjunto de mapas de ativação, um para cada filtro. Estes mapas são empilhados, formando uma saída tridimensional (altura \times largura \times número de filtros). Por exemplo, uma saída com dimensões $3 \times 3 \times 8$ indica que foram aplicados 8 filtros, produzindo 8 mapas de ativação com tamanho 3×3 cada. O volume de saída é controlado por 3 hiperparâmetros: profundidade, passo (*stride*) e preenchimento de zeros (*zero padding*). A profundidade refere-se a quantidade de filtros da camada, os quais possuem neurônios ao longo da sua dimensão e ativam na presença de bordas ou manchas a um determinado passo (um pixel por vez é o mais comum, mas também pode ser 2 e em casos mais raros, 3 ou mais) deslizado pelo filtro, produzindo volumes menores na saída. As vezes, convém preencher volumes de entrada com zeros, permitindo assim controlar a dimensão dos volumes de saída, muitas vezes utilizado para manter a dimensão original da matriz de entrada (LI; JOHNSON; YEUNG, 2023; BARROS et al., 2023). Para calcular a quantidade de zeros, é necessário aplicar a Equação (2.7):

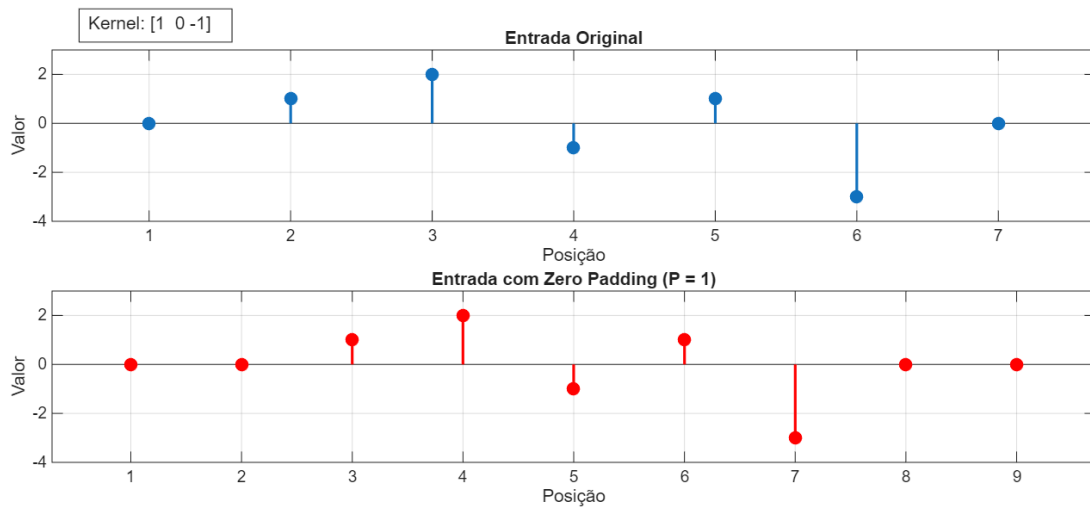
$$P = \frac{F - 1}{2} \quad (2.7)$$

onde:

- P é a quantidade de zeros adicionados em cada lado (padding),
- F é o tamanho do filtro (kernel).

No exemplo a seguir da Figura 6, ao aplicar a Equação (2.7) em uma entrada de tamanho $N = 7$, com um filtro de tamanho $F = 3$, obtém-se $P = 1$. Portanto, é necessário adicionar um zero à esquerda e um zero à direita da entrada (LI; JOHNSON; YEUNG, 2023).

Figura 6 – Demonstração do Zero Padding. O *kernel* aplicado é um vetor com 3 pesos e o volume da entrada é 7.



2.4.2 Camada de Normalização em Lote (*Batch Normalization*)

A Camada de Normalização por lote (*Batch Normalization - BN*) é uma operação de normalização aplicada aos mapas de ativação produzidos pelas camadas convolucionais durante o treinamento. Essa normalização é realizada sobre pequenos lotes (*mini-batches*) de dados, nos quais são calculados a média (μ_B) e o desvio padrão (σ_B) de cada canal de ativação (AWAIS; IQBAL; BAE, 2020; IOFFE; SZEGEDY, 2015).

Para cada lote de dados, a normalização é realizada conforme as Equações (2.8) e (2.9):

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (2.8)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (2.9)$$

Em seguida, cada ativação x_i é normalizada:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (2.10)$$

Por fim, são aplicados dois parâmetros aprendíveis, γ (escala) e β (deslocamento), conforme a equação (2.11):

$$y_i = \gamma \hat{x}_i + \beta \quad (2.11)$$

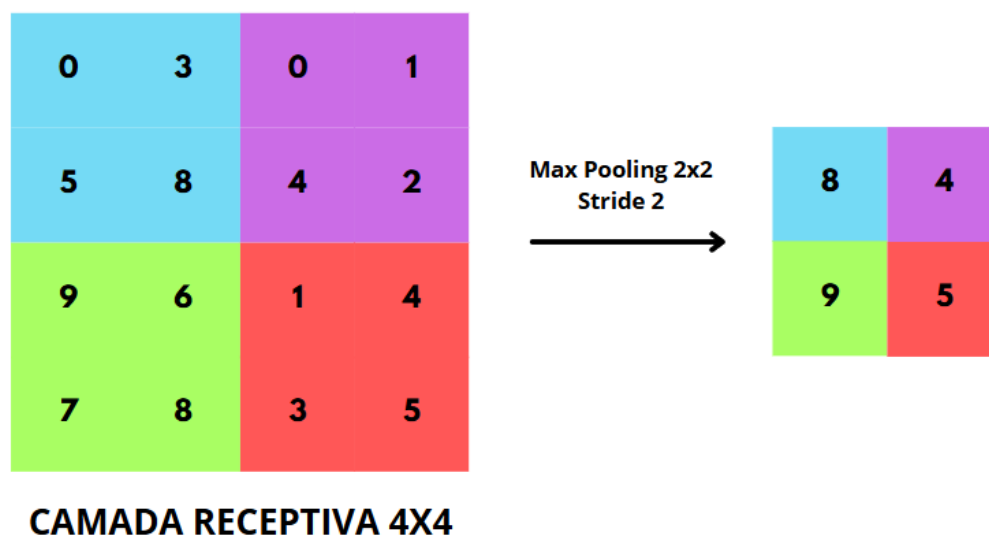
O principal objetivo da Batch Normalization (BN) é estabilizar a distribuição das ativações durante o treinamento, reduzindo o *internal covariate shift* (ICS), fenômeno pelo qual

a distribuição das entradas de cada camada muda constantemente, tornando o aprendizado mais difícil. Como a entrada da camada seguinte é a saída da camada anterior, e o algoritmo de backpropagation atualiza os pesos com frequência, o ICS torna o aprendizado instável e exige o uso de taxas de aprendizado menores. A BN atua diretamente sobre o ICS e, como consequência, o treinamento se torna mais eficiente, permitindo o uso de taxas de aprendizado maiores, acelerando a convergência da rede e contribuindo para reduzir o risco de sobreajuste (*overfitting*) (AWAIS; IQBAL; BAE, 2020; IOFFE; SZEGEDY, 2015).

2.4.3 Camada de Subamostragem (*Max Pooling*)

Em seguida, a camada de *max pooling* é aplicada entre camadas convolucionais e têm o objetivo de reduzir as dimensões espaciais dos mapas de ativação, diminuindo o número de parâmetros, o custo computacional e controlar o sobreajuste. Essa camada percorre a imagem em pequenas janelas (por exemplo, 2×2) e mantém apenas o maior valor de cada região, preservando as informações mais relevantes e tornando a rede mais robusta a pequenas variações e deslocamentos na imagem. Assim, um mapa 4×4 pode acabar com metade da sua dimensão original sem alterar a profundidade. (LI; JOHNSON; YEUNG, 2023; BARROS et al., 2023).

Figura 7 – Demonstração do Max Pooling. A matriz receptiva é uma 4×4 e resulta em uma 2×2 .



2.4.4 Camada Totalmente Conectada (*Fully Connected Layers*)

Após as etapas convolucionais, os mapas de ativação bidimensionais são achatados (*flatten*), convertendo-os em um vetor unidimensional que é, então, processado por uma camada densa de saída (*fully connected*). Para uma rede do tipo CNN, segundo a literatura (SOUZA et al., 2020), é necessário pelo menos uma camada desse tipo. Nessa camada, todos os neurônios estão interconectados, permitindo que a rede combine as características extraídas e calcule

uma probabilidade associada a cada classe. Para isso, geralmente aplica-se uma função a qual determina a identificação das saídas em classes, como a *Softmax*, responsável por transformar as saídas em probabilidades (LI; JOHNSON; YEUNG, 2023; BARROS et al., 2023). O treinamento ocorre por *backpropagation*, o qual ajusta o peso dos neurônios w por meio do erro obtido e o desejado.

2.4.5 Camada de Regularização (*Data Augmentation*)

A *Data Augmentation* é uma técnica para tangenciar o obstáculo de banco de dados pequenos ao programar pequenas variações de forma artificial. Também busca reduzir o sobreajuste adicionando rotações dentro de 0.5 graus, redimensionamento, condições de iluminação e zoom, de maneira randomizada (BARROS et al., 2023; YADAV; JADHAV, 2019).

2.4.6 Camada de Regularização (*Dropout Layer*)

O *Dropout* é uma técnica projetada para evitar o sobreajuste nas camadas densas, omitindo a participação de uma ou mais camadas de neurônios com objetivo de evitar uma dependência excessiva. Com isso, a rede se torna mais robusta e permite uma melhor generalização (BARROS et al., 2023).

2.4.7 Regra de Parada (*Early Stopping*)

É uma técnica diretamente ligada ao sobreajuste, de forma a evitá-lo ao introduzir um critério de paciência de um determinado número de épocas. Isto é, se o erro quadrático médio começa a aumentar, a rede está começando a assimilar informações não relevantes (como ruídos) e está caminhando para a condição de sobreajuste. Por isso, a partir do momento que isso acontece, é necessário interromper a atividade da rede, caracterizando a técnica de *early stopping* (KILSON; CARNEIRO, 2024; RODRIGUES; SOUSA; BORTOLETTO, 2024).

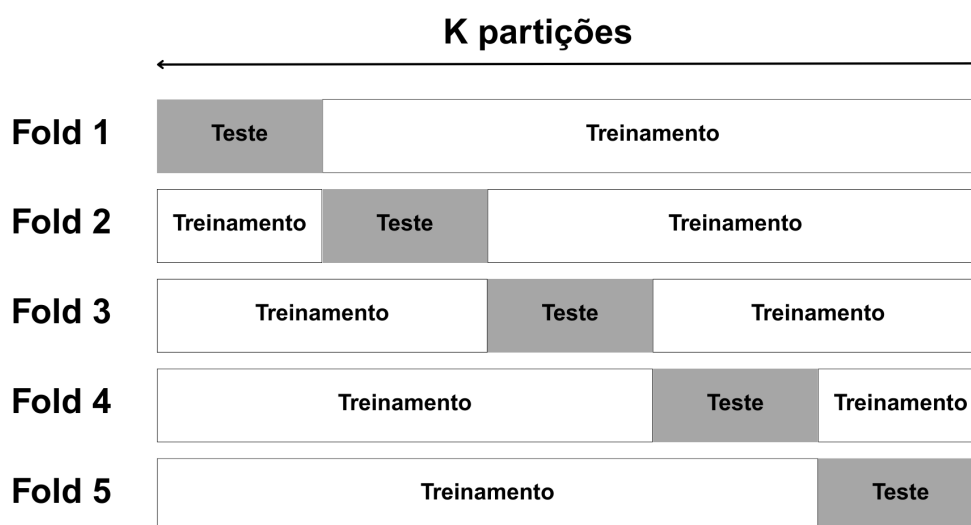
2.4.8 Algoritmo de Otimização (*ADAM*)

O *Stochastic Gradient Descent* (SGD) aplica uma única taxa de aprendizado a todos os pesos. Funciona bem em redes simples (até duas camadas), mas apresenta convergência lenta, forte sensibilidade à taxa de aprendizado e risco de ficar preso em mínimos locais. O *Adaptive Moment Estimation* (Adam) supera essas limitações, ajustando dinamicamente a taxa de aprendizado de cada peso. Combina gradiente adaptativo e *root mean square propagation* (RMSProp), explorando eficientemente os hiperparâmetros, corrigindo vieses e economizando recursos computacionais (KANG et al., 2024).

2.4.9 Validação Cruzada *K Fold*

A Validação Cruzada é um método de avaliação o desempenho de um modelo preditivo de forma robusta e reduzir o risco de overfitting. A técnica consiste em dividir a amostra original A em k partes, denominados *folds*, cada um com tamanho m_k . O modelo então é treinado em $k - 1$ partes e testado na parte restante, com esse processo repetindo k vezes, mudando o *fold* que está sendo utilizado como teste ao passar das iterações (VELOSO, 2022; SPEZIA, 2024), conforme ilustrado na Figura 8:

Figura 8 – Demonstração do comportamento das partições no decorrer das iterações.



3 METODOLOGIA

3.1 Participantes

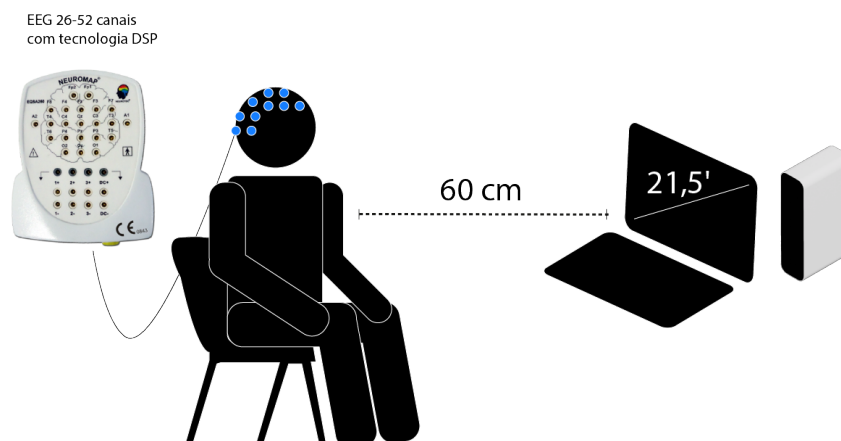
O grupo participante dessa pesquisa contou com 12 voluntários, 6 com diagnóstico de TEA (segundo critérios do DSM-5), nível 1 de suporte, e 6 controles típicos para compor o grupo controle, com idades entre 20 e 28 anos.

Dentre os critérios de inclusão, têm-se que: os indivíduos precisavam pertencer a faixa etária entre 18 e 30 anos, visão normal ou corrigida e capacidade de seguir instruções, sendo essas, por sua vez, definidas como tarefas cognitivas simples com instruções visuais e auditivas. Foram excluídos da pesquisa indivíduos com histórico de epilepsia, lesões cerebrais ou condições médicas que comprometessem a atividade elétrica cerebral e os que não consentiram formalmente com o Termo de Consentimento Livre e Esclarecido (TCLE). O estudo foi aprovado pelo Comitê de Ética em Pesquisa da UFPA (CAAE 56365722.9.0000.0018).

3.2 Setup Experimental

O experimento foi conduzido em um ambiente controlado, com iluminação indireta, temperatura ambiente e isolamento acústico. Os participantes foram posicionados a 60cm de um monitor de 21,5", em uma cadeira ajustável, conforme ilustrado na Figura 9:

Figura 9 – Setup do experimento.




3.3 Aquisição de Sinais

Para a aquisição de sinais, cada participante foi submetido a uma tarefa de cancelamento visual automatizada, inspirada no modelo do Cars' Test por Cascaes et. al (2020). A tarefa

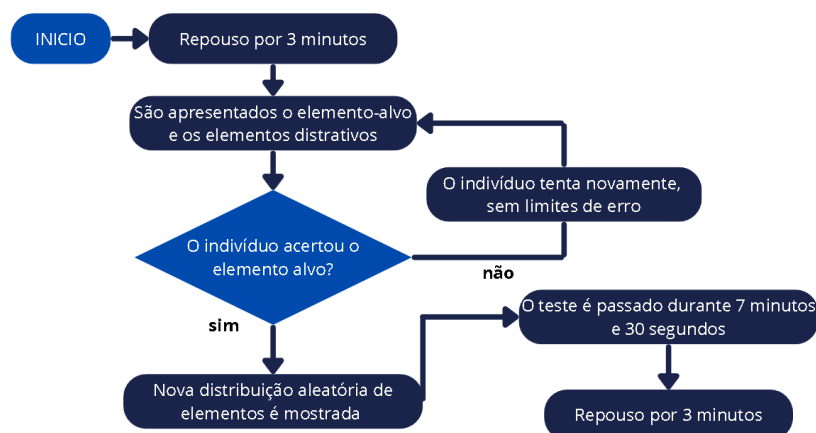
consistia na exibição contínua de múltiplos estímulos gráficos, definindo um deles como elemento alvo e os demais como distratores, ambos definidos de forma randômica a cada apresentação. Se o participante selecionou corretamente o elemento alvo, o sistema atualiza automaticamente a distribuição e realoca os alvos, escolhendo um novo elemento alvo e novos elementos distratores, reiniciando o ciclo de busca visual. O objetivo do participante era selecionar corretamente os estímulos-alvo utilizando o mouse sem qualquer penalização por erros ou limite de tempo pré-estabelecido para aquela distribuição específica por um total de 7 minutos e 30 segundos.

Figura 10 – Apresentação dos elementos utilizados como alvo e distratores de forma randômica.



No estado pré e pós tarefa, o indivíduo passou por um repouso de 3 minutos no qual ele observava uma tela sem conteúdo algum no monitor, sob orientações de evitar deglutições, piscadas excessivas e movimentos voluntários. Para este presente trabalho, os sinais analisados foram o de estado pré e pós tarefa cognitiva.

Figura 11 – Fluxograma da aquisição de sinais do EEG.

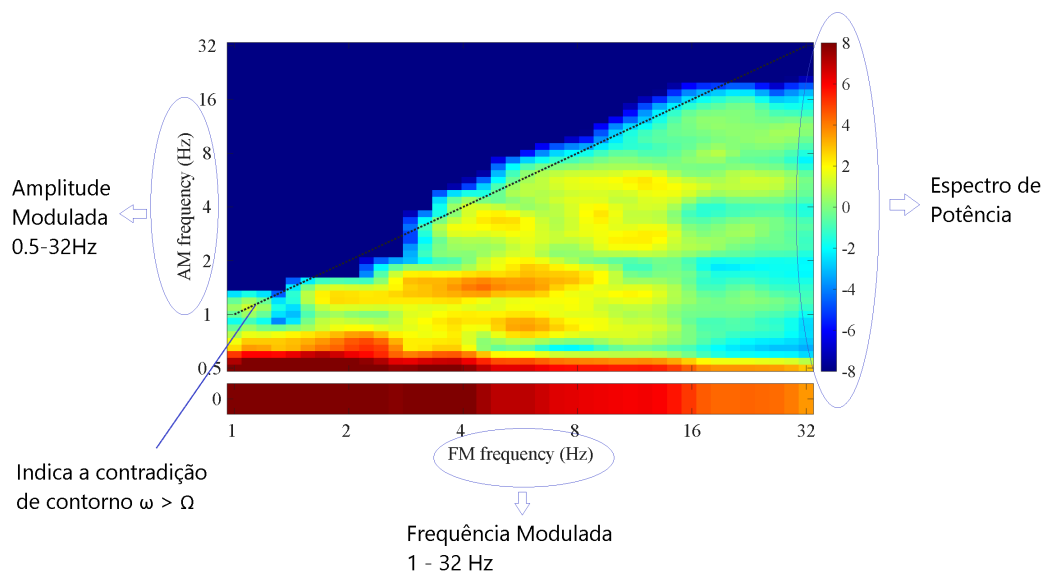


3.4 Análise Espectral de Holo-Hilbert

O conjunto de dados utilizado neste estudo foi disponibilizado no formato de imagens espectrais tridimensionais geradas a partir da técnica de HHSA. Esses mapas foram fornecidos no formato .fig do MATLAB®, correspondendo à distribuição espectral nos canais P3 e P4, em condições pré e pós-tarefa cognitiva.

A HHSA é uma técnica avançada de análise de sinais não estacionários, como o eletroencefalograma (EEG), que permite decompor o sinal em três dimensões principais: frequência portadora (amplitude modulada), frequência de modulação e potência conforme Figura 12:

Figura 12 – Leitura do mapa espectral.




Nos mapas analisados, o eixo y representa a frequência portadora (am), o eixo x representa a frequência de modulação (fm) e o eixo z (cor) representa a amplitude normalizada da atividade cerebral. A região de interesse (ROI) deste trabalho concentrou-se nos canais parietais P3 e P4, sendo sua escolha justificada pela natureza da tarefa cognitiva, visto que estudos (TSENG et al., 2024) demonstram que os canais P3 e P4 tem maiores atividades registradas devido à sua localização sobre o córtex parietal, região diretamente associada a processos de atenção visual, integração espacial e controle da exploração visuo-motora. Ressalta-se ainda que a linha tracejada ($\omega = \Omega$) demarca o limite teórico entre a frequência instantânea (Hilbert) e a frequência global (Fourier); assim, regiões em que $\omega > \Omega$ configuram uma contradição de contorno, indicando possíveis artefatos da decomposição ou instabilidades na estimativa da frequência instantânea, e não fenômenos neurais propriamente ditos.

Como os mapas foram previamente gerados a partir dos sinais brutos de EEG por meio de scripts MATLAB®, este trabalho concentrou-se na análise e interpretação dos padrões espectrais, não sendo realizada a etapa de decomposição HHSA diretamente. A leitura e comparação entre

os mapas foram conduzidas com base em padrões visuais reconhecidos pela CNN, permitindo inferências sobre o comportamento de indivíduos com TEA e controle, especialmente quanto à sua modulação após a tarefa de cancelamento visual sustentado.

Essa abordagem possibilitou a identificação de diferenças intergrupais no padrão de ativação eletrofisiológica, fornecendo subsídios para a compreensão de possíveis alterações funcionais associadas ao Transtorno do Espectro Autista.


Figura 13 – Comparação entre um sinal controle à esquerda e TEA à direita.



3.5 Banco de Dados

O banco de dados inicial continha 24 imagens originais dos canais P3 e P4 de 12 participantes. Entretanto, devido à performance instável observada em testes preliminares, foi necessário ampliar o conjunto de dados para esta rede. Para contornar essa limitação, foram geradas cópias adicionais dos mesmos sinais, totalizando 48 imagens, às quais foram aplicadas técnicas de aumento de dados (*data augmentation*). A ferramenta de *data augmentation* realizou leves alterações de zoom, rotação e contraste, gerando um banco de dados artificial das imagens, conforme ilustrado na Figura 14:

Figura 14 – Imagem original e suas variações geradas artificialmente.

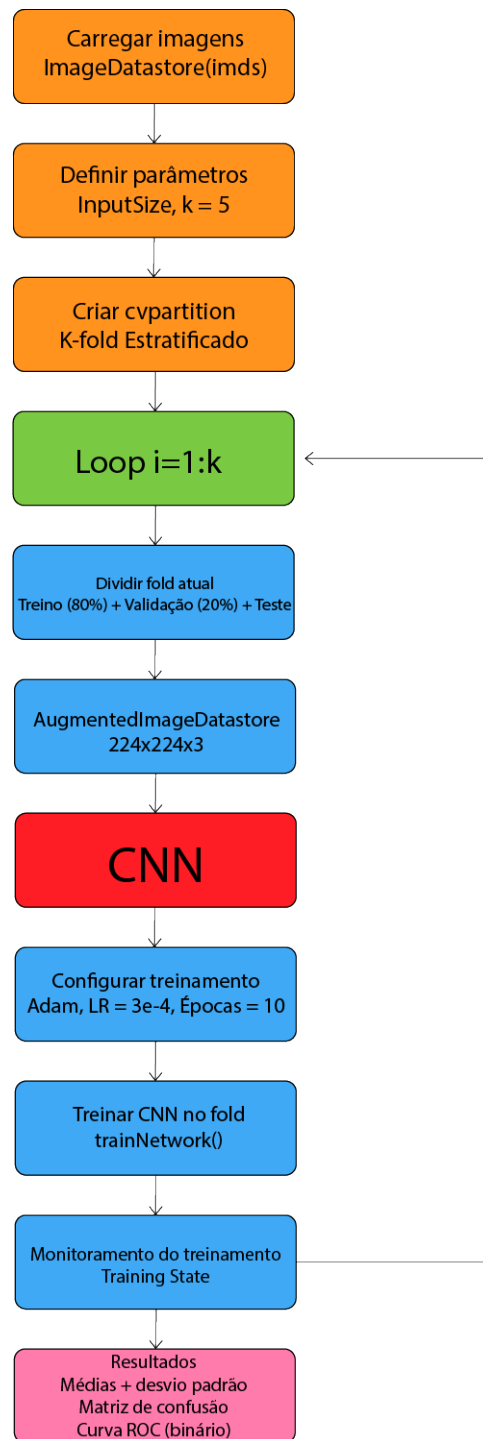


Dessa forma, o banco de dados, inicialmente com 48 imagens, foi expandido para 576, com o objetivo de evitar sinais de sobreajuste previamente observados. Para esta pesquisa, dentro do conjunto de treinamento, é estipulado 20% para teste e 80% para treinamento e validação. Dentro do conjunto de treinamento e validação, 80% do *fold* é para treino e 20% para validação, estimando-se que: para todos os *folds* 64% está reservado para treino, 16% para validação e 20% para teste.

3.6 Rede Neural Convolutacional

O presente trabalho utilizou como ferramenta auxiliar o programa MATLAB® no desenvolvimento do pipeline da CNN. Desta forma, têm-se conforme a Figura 15:

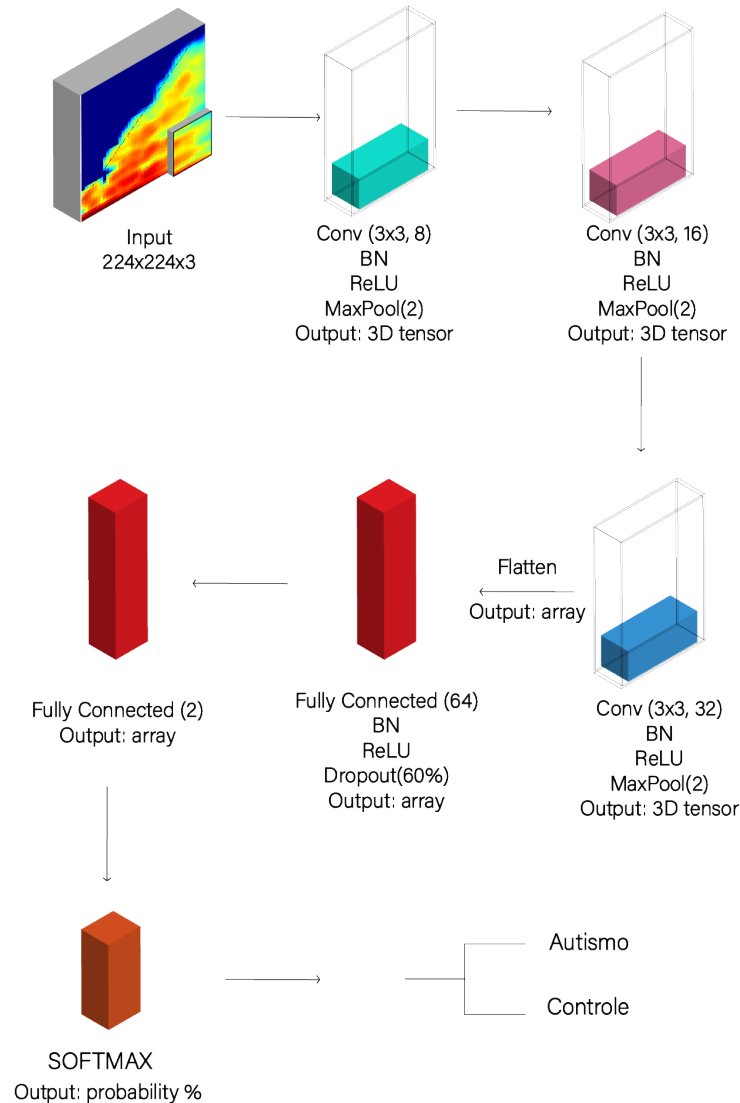
Figura 15 – Pipeline geral da programação.



A sequência de passos destacados em laranja corresponde ao bloco de definição de parâmetros e rotulação das imagens. Nesse estágio, foram selecionados os parâmetros de entrada, definido o número de *folds* a ser utilizado e realizada a criação da partição. O bloco em verde marca o início do *loop* da validação cruzada estratificada. Já o bloco azul refere-se às operações realizadas dentro desse *loop*, nas quais cada *fold* é dividido em 80% para treino e 20% para validação, além da execução dos testes. Em seguida, realiza-se o *upload* das imagens previamente aumentadas, para pré-processamento das dimensões adequadas à CNN. Assim, conclui-se a

primeira metade do bloco azul, dando início à construção da CNN, com a definição de seus parâmetros, incluindo o otimizador ADAM, taxa de aprendizado (*learning rate*) de 0,0003 e 10 épocas de treinamento. A segunda metade do bloco azul contempla o treinamento da CNN e seu monitoramento, até a finalização do *loop* e a apresentação dos resultados, representados pelo bloco em rosa.

Figura 16 – Arquitetura da CNN personalizada.



A entrada da CNN consiste em imagens RGB no formato $224 \times 224 \times 3$ pixels, representando os espectros HHSA dos grupos controle e TEA. No bloco de camadas convolucionais, a primeira camada convolucional possui dimensão 3×3 e 8 filtros, gerando 8 mapas de ativação na saída, também chamados de *3D tensor*. Em seguida, aplica-se a normalização em batch (BN), a função de ativação ReLU e a operação de MaxPooling(2), obtendo-se uma saída com metade das dimensões espaciais da entrada, preservando o número de filtros: $112 \times 112 \times 8$.

O mapa de ativação resultante segue para a próxima camada convolucional, até a terceira camada convolucional, que possui dimensão 3×3 e 32 filtros. Nesta etapa, os mapas de

ativação têm suas dimensões reduzidas consideravelmente, chegando a $28 \times 28 \times 32$, e em seguida são achatados pela função *flatten*, tornando-se um vetor unidimensional (*ID array*) com $28 \times 28 \times 32 = 25.088$ elementos.

Após esta etapa, o vetor é enviado para uma camada totalmente conectada (*fully connected - FC*) com 64 neurônios, seguida de BN, ReLU e dropout de 60%. O vetor resultante de tamanho 64 é então encaminhado para a camada FC final, produzindo um vetor de tamanho 2, que é transformado em probabilidades pela função softmax.

Para o treinamento da rede neural, foram utilizados dois conceitos importantes: épocas e iterações. Diferente de abordagens mais simples, em que uma época pode equivaler a uma única iteração, o uso de mini-batches — viabilizado pelo aumento artificial do banco de dados — permitiu dividir o conjunto de imagens em pequenos grupos de 32 amostras. A cada iteração, a rede é atualizada com base em um mini-batch, ou seja, ela ajusta seus pesos a partir de 32 imagens por vez. Dessa forma, são necessárias várias iterações para completar uma única época, ou seja, para que todas as imagens do conjunto de treino sejam processadas uma vez. Isso torna o treinamento mais eficiente e menos exigente em termos de hardware, além de permitir um monitoramento mais frequente do desempenho e do risco de sobreajuste. No caso deste trabalho, o conjunto de treino por fold possuía 368 imagens, o que resulta em aproximadamente 11 iterações por época. Ao final, foram realizadas 10 épocas, totalizando 90 a 110 iterações, dependendo da divisão exata dos dados e do critério de parada antecipada utilizado.

3.7 Métricas de Desempenho

A acurácia é uma métrica amplamente utilizada para avaliar o desempenho de modelos de classificação baseados em CNN, indicando a proporção entre previsões corretas e o total (FOROUGH; CHEN; WANG, 2021), conforme a Equação 3.7:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN}$$

- *VP*: verdadeiro positivo;
- *VN*: verdadeiro negativo;
- *FP*: falso positivo;
- *FN*: falso negativo.

Por outro lado, há métricas amplamente utilizadas no campo da saúde para testes de diagnósticos que podem auxiliar a verificar se o paciente possui uma condição ou não. Trazendo para o contexto do TEA, a sensibilidade, especificidade e precisão são métricas para avaliar a acurácia do teste diagnóstico, de forma retratada nas Equações 3.1, 3.2 e 3.3 :

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \tag{3.1}$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.2)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (3.3)$$

Essas métricas permitem avaliar o desempenho da rede de forma equilibrada, considerando tanto a capacidade de identificar corretamente as amostras positivas quanto a habilidade de não classificar erroneamente amostras negativas ([COSTA; ZANINI, 2020](#)).

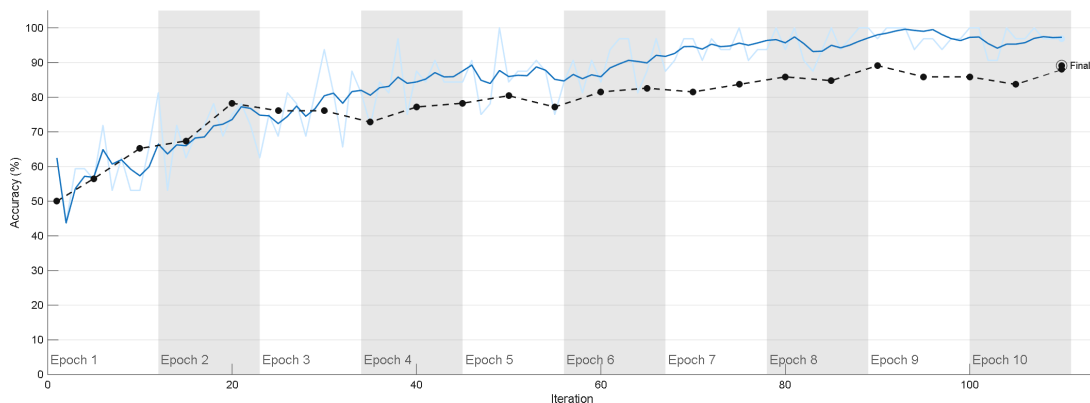
4 RESULTADOS

Durante o treinamento da CNN personalizada, foram monitoradas métricas de desempenho como acurácia, função perda e curva ROC, tanto para o conjunto de treinamento quanto para validação. O monitoramento da rede permitiu atestar os valores iniciais, finais, médios e a verificação visual do comportamento das métricas no decorrer das iterações.

4.1 Monitoramento do treinamento


Para se analisar o comportamento geral da rede, utiliza-se a janela *training state* do MATLAB® para tal feito. A acurácia apresentada ao final do treinamento não reflete de forma fidedigna o treino, validação e teste, todavia é possível identificar traços de sobreajuste e outros comportamentos relevantes na rede. Primeiro, é importante analisar a Figura 17:

Figura 17 – Gráfico do comportamento da acurácia em função das épocas.



Para uma melhor compreensão do que está sendo visto, fixa-se os seguintes conceitos: a linha em azul mais clara é o valor bruto da acurácia de treinamento, enquanto que a linha azul forte caracteriza-se por ser a média das acurácias (apresentando um comportamento mais estável) e a linha tracejada é a de validação. Com isso em mente, é possível perceber um comportamento oscilatório, porém com trajetória ascendente, tendo em vista que nas primeiras iterações a acurácia se assemelhava-se a um mero chute, porém nas finais já apresentava uma acurácia de validação entre 80% e 90%. Outro fator essencial para descategorizar uma presença de sobreajuste significativo é a convergência entre a linha de validação e a linha das médias de treinamento, de forma que na maioria das iterações, a diferença não ultrapassa os 10%. Dessa forma, sugere-se que o modelo não sofreu de sobreajuste significativo e apresentou boa capacidade de generalização das características relevantes dos espectros utilizados.

Figura 18 – Gráfico do comportamento da função de perda em função das épocas.



De forma análoga, a Figura 18 mostra a evolução da função de perda durante o treinamento. Inicialmente, os valores de perda foram elevados e oscilatórios, com picos próximos de 1,4. Com o avanço das épocas, a perda de validação foi reduzida de forma consistente, atingindo valores próximos a 0,4 ao final do processo de treinamento.

Essa redução contínua da função de perda, acompanhada da melhora na acurácia, reforça que o modelo convergiu de forma eficaz, sem indícios claros de sobreajuste.

4.2 Validação Cruzada com Aumento de Dados

Para então avaliar a robustez do modelo em termos de acurácia de treino, validação e teste, foi aplicada a validação cruzada estratificada com $k = 5$ folds, utilizando um conjunto de imagens aumentado artificialmente com o *data augmentation*. A Tabela 2 apresenta os valores da acurácia e *Area Under the Curve* (AUC) obtidos em cada fold, assim como a média total e o desvio padrão.

Tabela 2 – Resultados de acurácia por fold e métricas finais

Fold	Acurácia Treino (%)	Acurácia Validação (%)	Acurácia Teste (%)
1	84.83	89.13	86.09
2	85.14	81.52	80.17
3	85.45	88.04	81.74
4	84.20	81.52	86.96
5	82.50	88.04	80.00
Média	84.43 ± 1.17	85.65 ± 3.80	82.99 ± 3.31
AUC médio: 0.92 ± 0.03			


Os resultados indicam um desempenho consistente da rede neural, com acurácia média de teste de 82,99% e baixa variabilidade entre os folds ($\pm 3,31\%$). A AUC média foi de 0,92, evidenciando a alta capacidade discriminativa do classificador.

4.3 Curva ROC e AUC

A Figura 19 apresenta a curva ROC gerada após a predição no conjunto de teste. A linha azul representa o desempenho do classificador, a linha amarela o desempenho ideal e a linha

tracejada vermelha indica a performance esperada de um classificador aleatório.

Figura 19 – Curva ROC gerada pela CNN personalizada.

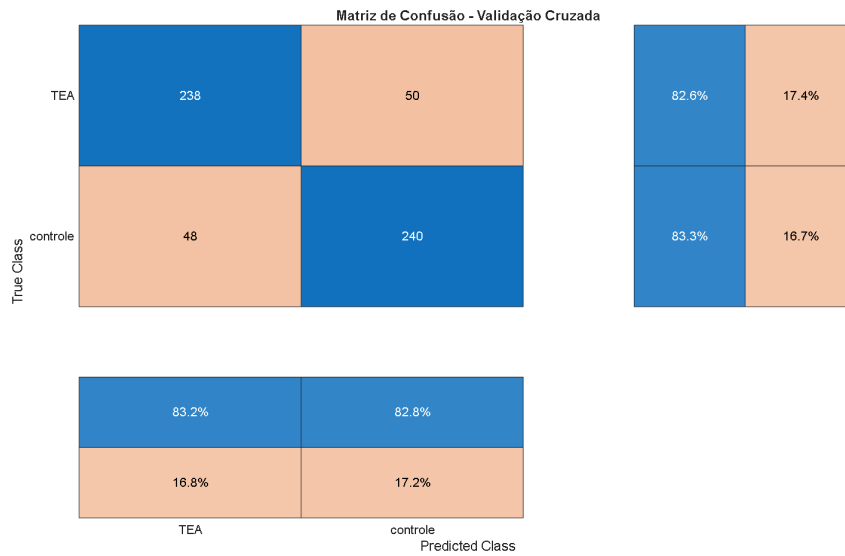


A área sob a curva (AUC) obtida foi de 0,92, indicando excelente capacidade de distinção entre as classes. Este valor reforça que, mesmo com arquitetura simples e base de dados reduzida, o modelo foi capaz de aprender padrões discriminativos relevantes.

4.4 Matriz de Confusão

A Figura 20 apresenta a matriz de confusão obtida a partir das predições realizadas sobre o conjunto de teste. A rede neural foi treinada para distinguir entre as classes *TEA* e *CONTROLE*, com base nas imagens espectrais.

Figura 20 – Matriz de confusão gerada pela CNN personalizada.



A rede classificou corretamente, em validação cruzada, 238 amostras da classe *TEA* e 240 amostras da classe *CONTROLE*, totalizando 98 erros. No presente estudo, a sensibilidade foi de 82,6% para a classe *TEA* e 83,3% para a classe *CONTROLE*, enquanto as precisões foram de 83,2% e 82,8%, respectivamente. Esses resultados indicam um desempenho equilibrado entre as classes, reforçando a eficácia das estratégias de treinamento adotadas.

5 DISCUSSÃO

Este estudo propôs o desenvolvimento e a avaliação de uma Rede Neural Convolutacional (CNN) personalizada para a classificação de espectros HHSA, distinguindo as classes *TEA* e *CONTROLE*. Os resultados obtidos demonstram o potencial da arquitetura proposta, evidenciando um modelo robusto e com boa capacidade de generalização. Neste capítulo, discutem-se os principais achados, suas implicações e a relação com o estado da arte.

Os resultados indicam que a CNN personalizada foi capaz de classificar espectros relacionados ao TEA com acurácia média de teste de 82,99% e AUC de 0,92, valores considerados robustos para um problema de classificação binária complexo e com base de dados limitada. Esses resultados estão alinhados com os apresentados por [Neto et al. \(2023\)](#), que utilizaram técnicas de deep learning e processamento de sinais para diagnóstico de autismo, obtendo acurácia superior a 80% e AUC acima de 0,83 em diferentes redes, com exceção de MobileNet e MobileNetV2.

De forma similar, [Peketi e Dhok \(2023\)](#) propôs um classificador P300 baseado em *Variational Mode Decomposition* (VMD) e SVM, alcançando acurácia de 91,12% e AUC de 0,96 em sinais de EEG de indivíduos com TEA. Apesar da metodologia distinta – baseada em sinais temporais e decomposição modal –, esse estudo reforça a viabilidade de abordagens baseadas em inteligência artificial para extrair padrões sutis associados ao TEA. Já [Xu et al. \(2024\)](#) utilizou mapas de conectividade funcional cerebral baseados em EEG e um modelo CNN-LSTM, atingindo acurácias de 81,08% (repouso) e 74,55% (tarefa). Esses achados destacam a importância de representações temporais e espaciais dos sinais neurais, bem como a necessidade de evitar contaminação entre os conjuntos de treino e teste, cuidado também adotado em nosso trabalho por meio da validação cruzada estratificada.

No monitoramento da função perda, os valores iniciais apresentaram oscilações, atingindo picos próximos a 1,4 nas primeiras iterações, mas reduziram-se de forma consistente para menos de 0,4 ao final do treinamento. Esse comportamento é consistente com os resultados de [Mao et al. \(2020\)](#), que obtiveram 76,43% de acurácia e 0,496 de perda, confirmando o potencial das CNNs mesmo quando treinadas com bases de dados reduzidas.

Estudos envolvendo HHSA são relativamente recentes, como exemplificam [Chu et al. \(2023\)](#), [Hsu et al. \(2018\)](#), [Liu et al. \(2024\)](#) e [Gallego-Molina et al. \(2022\)](#), reforçando o potencial acadêmico da utilização de mapas espectrais em sinais de EEG. Todavia, não foram encontrados na literatura trabalhos que combinassem EEG, HHSA e CNNs, caracterizando uma contribuição inédita deste estudo.

A utilização de *data augmentation* exerceu papel fundamental na melhoria do desempe-

nho e na generalização do modelo. Obtivemos baixa variabilidade entre os folds, indicando que a rede foi capaz de aprender características robustas e generalizáveis a partir de um conjunto limitado de dados espectrais de EEG. Esses resultados estão em consonância com a literatura, que demonstra que técnicas de aumento de dados — como transformações geométricas e injeção de ruído — são eficazes para evitar overfitting e melhorar a capacidade de generalização em tarefas de classificação de sinais neurais. O fato de não termos observado sobreajuste significativo, aliado à convergência entre as curvas de treinamento e validação, sugere que a estratégia adotada expandiu a diversidade do conjunto de treinamento sem introduzir viés ou degradar a qualidade do sinal original.

Apesar dos resultados promissores, algumas limitações devem ser destacadas. O número reduzido de participantes, a utilização de apenas dois canais (P3 e P4) e a dependência de aumento artificial de dados podem restringir a generalização dos resultados. Estudos futuros podem explorar a inclusão de múltiplos canais e arquiteturas híbridas, como CNN-LSTM ou GCNN, além da aplicação em conjuntos de dados maiores e mais heterogêneos, a fim de validar e potencialmente ampliar a performance do modelo.

De forma geral, os achados deste estudo reforçam que CNNs aplicadas a mapas espectrais de EEG podem fornecer uma ferramenta promissora para auxiliar na detecção de padrões associados ao TEA. Apesar das limitações, a acurácia, AUC e equilíbrio entre as classes obtidos demonstram que arquiteturas relativamente simples, quando combinadas com estratégias de validação cruzada e aumento de dados, podem apresentar resultados robustos e comparáveis a abordagens mais complexas presentes na literatura.

6 CONCLUSÃO

O presente estudo teve como objetivo principal desenvolver e avaliar uma Rede Neural Convolutiva (CNN) personalizada para a classificação de espectros HHSA de sinais de EEG, distinguindo indivíduos com TEA e controles típicos. Os objetivos específicos foram revisados e atingidos da seguinte forma:

1. Revisar e selecionar bases de dados neurofisiológicos relevantes (EEG): foram escolhidos conjuntos de dados contendo registros de indivíduos com TEA e controles, garantindo representatividade e qualidade dos sinais utilizados no estudo.

2. Aplicar a HHSA para decompor e extrair características espectrais e temporais: a análise de Hilbert-Huang Spectrum Analysis permitiu extrair informações discriminativas dos sinais de EEG, que serviram como insumos relevantes para o treinamento da CNN.

3. Aplicar e treinar uma CNN utilizando as características extraídas via HHSA: a rede convolutiva personalizada foi implementada, treinada e monitorada, demonstrando convergência adequada, ausência de sobreajuste significativo e aprendizado de padrões robustos.

4. Avaliar o desempenho do modelo CNN em termos de métricas de classificação: o modelo alcançou acurácia média de teste de 82,99%, AUC de 0,92 e sensibilidade equilibrada entre as classes, indicando boa capacidade de generalização e discriminação entre TEA e controles.

5. Discutir as implicações clínicas e computacionais: os resultados reforçam o potencial das CNNs aplicadas a mapas espectrais de EEG como ferramenta auxiliar na identificação de padrões associados ao TEA, evidenciando contribuição inédita do uso de HHSA para extração de características relevantes.

Em síntese, todos os objetivos específicos foram atingidos, demonstrando que a combinação de HHSA com CNNs constitui uma abordagem promissora para classificação de EEG no contexto do TEA. Entretanto, algumas limitações devem ser consideradas, como o número reduzido de participantes, a utilização de apenas dois canais (P3 e P4) e a dependência de aumento artificial de dados. Estudos futuros podem explorar a inclusão de múltiplos canais, arquiteturas híbridas (como CNN-LSTM ou GCNN) e aplicação em conjuntos de dados maiores e mais heterogêneos, visando aprimorar a acurácia e validar a generalização do modelo.

Em suma, este trabalho demonstra que estratégias relativamente simples de aprendizado profundo, quando combinadas com técnicas de validação cruzada e aumento de dados, podem gerar modelos robustos e promissores para a análise de EEG no contexto do TEA, abrindo caminhos para aplicações clínicas e investigações futuras.

Referências

- ALMEIDA, J. M. d. et al. Rede neural artificial para detecção do estado ocular usando sinal de eeg. 2023. Citado na página 7.
- AWAIS, M.; IQBAL, M. T. B.; BAE, S.-H. Revisiting internal covariate shift for batch normalization. *IEEE Transactions on Neural Networks and Learning Systems*, IEEE, v. 32, n. 11, p. 5082–5092, 2020. Citado 2 vezes nas páginas 12 e 13.
- BARROS, J. C. d. C. et al. Transferência de aprendizagem em cnn: Um estudo comparativo aplicado ao diagnóstico de glaucoma. 2023. Citado 4 vezes nas páginas 10, 11, 13 e 14.
- BHARATH, R. et al. Comparison of physiological and biochemical autonomic indices in children with and without autism spectrum disorders. *Medicina*, MDPI, v. 55, n. 7, p. 346, 2019. Citado na página 4.
- BISSARO, L. Z. et al. Aprendizado de padrões eeg para prognóstico precoce de pacientes em coma usando redes echo state e redes neurais convolucionais. Universidade Federal de Uberlândia, 2021. Citado na página 5.
- BORRA, D.; MAGOSSO, E. et al. Deep learning-based eeg analysis: investigating p3 erp components. *Journal of Integrative Neuroscience*, v. 20, n. 4, p. 791–811, 2021. Citado na página 6.
- BOSETTI, C. et al. Children with autism spectrum disorder and abnormalities of clinical eeg: A qualitative review. *Journal of Clinical Medicine*, MDPI, v. 13, n. 1, p. 279, 2024. Citado na página 3.
- BRIHADISWARAN, G. et al. Eeg-based processing and classification methodologies for autism spectrum disorder: A review. *Journal of Computer Science*, v. 15, n. 8, 2019. Citado 2 vezes nas páginas 3 e 5.
- CHANG, K.-H. et al. Evaluating the different stages of parkinson’s disease using electroencephalography with holo-hilbert spectral analysis. *Frontiers in aging neuroscience*, Frontiers Media SA, v. 14, p. 832637, 2022. Citado 2 vezes nas páginas 7 e 8.
- CHU, K.-T. et al. A holo-spectral eeg analysis provides an early detection of cognitive decline and predicts the progression to alzheimer’s disease. *Frontiers in aging neuroscience*, Frontiers Media SA, v. 15, p. 1195424, 2023. Citado na página 29.
- COSTA, B. C. A. dos S.; ZANINI, D. S. Sensibilidade e especificidade de instrumentos psicológicos na avaliação do transtorno de déficit de atenção e hiperatividade: um estudo de revisão sistemática. *Cadernos de Pós-Graduação em Distúrbios do Desenvolvimento*, v. 20, n. 1, 2020. Citado na página 24.
- FENG, W. et al. Ultrasonic flaw echo enhancement based on empirical mode decomposition. *Sensors*, v. 19, p. 236, 01 2019. Citado na página 9.
- FOROUGH, F.; CHEN, Z.; WANG, J. A cnn-based system for mobile robot navigation in indoor environments via visual localization with a small dataset. *World Electric Vehicle Journal*, MDPI, v. 12, n. 3, p. 134, 2021. Citado na página 23.

- GALLEGO-MOLINA, N. J. et al. Unraveling dyslexia-related connectivity patterns in eeg signals by holo-hilbert spectral analysis. In: SPRINGER. *International Work-Conference on the Interplay Between Natural and Artificial Computation*. [S.l.], 2022. p. 43–52. Citado na página 29.
- HSU, H.-T. et al. Analyses of eeg oscillatory activities during slow and fast repetitive movements using holo-hilbert spectral analysis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 26, n. 9, p. 1659–1668, 2018. Citado na página 29.
- HUANG, N. E. et al. On holo-hilbert spectral analysis: a full informational spectral representation for nonlinear and non-stationary data. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 374, n. 2065, p. 20150206, 2016. Citado na página 7.
- HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, v. 454, n. 1971, p. 903–995, 1998. Citado na página 7.
- IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*, 2015. Disponível em: <<https://arxiv.org/abs/1502.03167>>. Citado 2 vezes nas páginas 12 e 13.
- JACK, C. *From Autistic Linear Spectrum to Pie Chart Spectrum*. 2022. *Psychology Today*. Acesso em: 26 ago. 2025. Disponível em: <<https://www.psychologytoday.com/us/blog/women-autism-spectrum-disorder/202208/autistic-linear-spectrum-pie-chart-spectrum>>. Citado na página 3.
- JUAN, C.-H. et al. Revealing the dynamic nature of amplitude modulated neural entrainment with holo-hilbert spectral analysis. *Frontiers in Neuroscience*, Frontiers Media SA, v. 15, p. 673369, 2021. Citado 2 vezes nas páginas 7 e 8.
- KANG, J. et al. Fault diagnosis of a wave energy converter gearbox based on an adam optimized cnn-lstm algorithm. *Renewable energy*, Elsevier, v. 231, p. 121022, 2024. Citado na página 14.
- KILSON, G. F.; CARNEIRO, F. R. D. P. Estudo do impacto da variaç ao de parâmetros em uma rede neural artificial aplicado a bases com diferentes características. 2024. Citado na página 14.
- LATIF, G. et al. Deep convolutional neural network (cnn) model optimization techniques—review for medical imaging. *AIMS Mathematics*, v. 9, n. 8, p. 20539–20571, 2024. Citado na página 10.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2323, 1998. Citado na página 10.
- LI, F.-F.; JOHNSON, J.; YEUNG, S. *CS231n: Convolutional Neural Networks for Visual Recognition*. 2023. Acesso em: 14 jun. 2025. Disponível em: <<https://cs231n.github.io/convolutional-networks/#conv>>. Citado 4 vezes nas páginas 10, 11, 13 e 14.
- LIU, J. et al. Analysis of amplitude modulation of eeg based on holo-hilbert spectrum analysis during general anesthesia. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 71, n. 5, p. 1607–1616, 2024. Citado na página 29.
- LORD, C. et al. Autism spectrum disorder. *Nature reviews Disease primers*, Nature Publishing Group UK London, v. 6, n. 1, p. 5, 2020. Citado na página 3.

- MAO, W. et al. Eeg dataset classification using cnn method. In: IOP PUBLISHING. *Journal of physics: conference series*. [S.l.], 2020. v. 1456, n. 1, p. 012017. Citado na página 29.
- MAROTTA, R. et al. The neurochemistry of autism. *Brain sciences*, MDPI, v. 10, n. 3, p. 163, 2020. Citado na página 3.
- MICHEL, C. M.; HE, B. Eeg source localization. *Handbook of clinical neurology*, Elsevier, v. 160, p. 85–101, 2019. Citado na página 7.
- NEO, W. S. et al. Resting-state eeg power differences in autism spectrum disorder: a systematic review and meta-analysis. *Translational Psychiatry*, Nature Publishing Group UK London, v. 13, n. 1, p. 389, 2023. Citado 2 vezes nas páginas 4 e 7.
- NETO, J. L. et al. Classificação de sinais de eeg para diagnóstico do transtorno do espectro autista utilizando cnn e rnn. 2023. Citado na página 29.
- NICOTERA, A. G. et al. EEG abnormalities as a neurophysiological biomarker of severity in autism spectrum disorder: a pilot cohort study. *Journal of Autism and Developmental Disorders*, Springer, v. 49, p. 2337–2347, 2019. Citado na página 5.
- PAGANI, M. et al. mtor-related synaptic pathology causes autism spectrum disorder-associated functional hyperconnectivity. *Nature communications*, Nature Publishing Group UK London, v. 12, n. 1, p. 6084, 2021. Citado na página 4.
- PEKETI, S.; DHOK, S. B. Machine learning enabled p300 classifier for autism spectrum disorder using adaptive signal decomposition. *Brain Sciences*, MDPI, v. 13, n. 2, p. 315, 2023. Citado na página 29.
- PLAIN, R.; PLAIN, A. R. 2.2 análise de sinais de eletroencefalograma (eeg). *Aprendizado de padrões EEG para prognóstico precoce de pacientes em coma usando redes echo state e redes neurais convolucionais*, p. 44, 2021. Citado na página 5.
- RODRIGUES, S. do P.; SOUSA, G. d. V. de; BORTOLETTO, R. C. Rede neural artificial como agente em redes ópticas elásticas. In: *Congresso de Inovação, Ciência e Tecnologia do IFSP*. [S.l.: s.n.], 2024. v. 15, n. 2. Citado na página 14.
- SANTARONE, M. E. et al. Eeg features in autism spectrum disorder: a retrospective analysis in a cohort of preschool children. *Brain Sciences*, MDPI, v. 13, n. 2, p. 345, 2023. Citado 2 vezes nas páginas 4 e 5.
- SOUZA, S. C. d. et al. Análises de atividades oscilatórias de eeg durante treinamento cognitivo e análise espectral de holo-hilbert. Universidade Federal do Pará, 2022. Citado na página 7.
- SOUZA, V. et al. Análise comparativa de redes neurais convolucionais no reconhecimento de cenas. *Anais do Computer on the Beach*, v. 11, p. 419–426, 2020. Citado na página 13.
- SPEZIA, A. M. Estudo de estratégias de validação cruzada baseadas em clusters. 2024. Citado na página 15.
- TSENG, Y.-L. et al. Characterizing autism spectrum disorder through fusion of local cortical activation and global functional connectivity using game-based stimuli and a mobile eeg system. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, 2024. Citado 2 vezes nas páginas 6 e 18.

UPADHYAY, J. et al. Dysregulation of multiple signaling neurodevelopmental pathways during embryogenesis: a possible cause of autism spectrum disorder. *Cells*, MDPI, v. 10, n. 4, p. 958, 2021. Citado na página 5.

VELOSO, L. T. *Um estudo comparativo de técnicas de validação cruzada aplicadas a modelos para dados desbalanceados*. Tese (Doutorado) — Universidade de São Paulo, 2022. Citado na página 15.

WAIZBARD-BARTOV, E. et al. Autism severity and its relationship to disability. *Autism Research*, Wiley Online Library, v. 16, n. 4, p. 685–696, 2023. Citado na página 3.

XU, Y. et al. Autism spectrum disorder diagnosis with eeg signals using time series maps of brain functional connectivity and a combined cnn–lstm model. *Computer methods and programs in biomedicine*, Elsevier, v. 250, p. 108196, 2024. Citado na página 29.

YADAV, S. S.; JADHAV, S. M. Deep convolutional neural network based medical image classification for disease diagnosis. *Journal of Big data*, Springer, v. 6, n. 1, p. 1–18, 2019. Citado 2 vezes nas páginas 10 e 14.