



**INSTITUTO FEDERAL DE EDUCAÇÃO,
CIÊNCIA E TECNOLOGIA DO CEARÁ
IFCE CAMPUS FORTALEZA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
TELECOMUNICAÇÕES PPGET**

João Vitor Marques Rabelo Fernandes

**DETECÇÃO DE EMOÇÕES EM SINAIS DE EEG POR MEIO DE
MODELOS DE APRENDIZADO DE MÁQUINA E REDES NEURAIS
PROFUNDAS**

Fortaleza, Ceará

2024

João Vitor Marques Rabelo Fernandes

DETECÇÃO DE EMOÇÕES EM SINAIS DE EEG POR MEIO DE MODELOS DE
APRENDIZADO DE MÁQUINA E REDES NEURAIS PROFUNDAS

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará como requisito parcial para a obtenção do título de Mestre em Engenharia de Telecomunicações. Área de concentração: Processamento Digital de Sinais.

Orientador: Prof. Dr. Auzuir Ripardo de Alexandria

Coorientador: Prof. Dr. João Alexandre Lobo Marques

Fortaleza, Ceará

2024

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

- F363d Fernandes, João Vitor Marques Rabelo.
Detecção de Emoções em Sinais de EEG por meio de modelos de Aprendizado de Máquina e Redes Neurais Profundas / João Vitor Marques Rabelo Fernandes. - 2024.
81 f.
- Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Engenharia de Telecomunicações, Campus Fortaleza, 2024.
Orientação: Prof. Dr. Auzuir Ripardo de Alexandria.
Coorientação: Prof. Dr. João Alexandre Lobo Marques.
1. Detecção de emoções. 2. Reconhecimento de emoções. 3. Eletroencefalograma. 4. Aprendizado profundo. 5. Redes Neurais Convolucionais em Grafos. I. Título.

CDD 621.382

Agradecimentos

A Deus, agradeço pela força, sabedoria e orientação que me guiaram ao longo dessa jornada.

À minha amada esposa Amanda, agradeço por seu apoio incondicional, compreensão e paciência durante todas as etapas deste desafio. Sua presença fez toda a diferença e sem ela eu não conseguiria concluir este desafio.

Aos meus pais, Domingos e Andréa, que me ensinaram com muito amor e zelo o valor dos estudos.

A minhas irmãs, Ana Luisa e Ana Paula, pelos bons momentos compartilhados e inspiração que me dão.

Aos meus orientadores, prof. Auzuir Ripardo e prof. João Alexandre Lobo, expressei minha profunda gratidão. Suas orientações, conhecimentos e incentivos foram essenciais para o desenvolvimento deste trabalho. Agradeço por compartilharem não apenas seu conhecimento acadêmico, mas também por contribuírem para meu crescimento pessoal.

*“[...] Nele [Cristo Jesus] estão escondidos todos os tesouros da sabedoria e do
conhecimento”
(Colossenses 2:3 - Nova Versão Internacional)*

Resumo

A detecção de sentimentos é uma área em crescimento que busca compreender e interpretar as emoções humanas a partir de uma variedade de fontes de dados, incluindo texto, voz e ou ainda mesmo sinais fisiológicos. Entre essas fontes, o Eletroencefalograma (EEG) têm se destacado como uma abordagem única e promissora. O EEG é uma técnica de monitoramento não invasiva que registra a atividade elétrica do cérebro por meio de eletrodos colocados na superfície do couro cabeludo e tem sido utilizado em contextos clínicos e de pesquisa para explorar como o cérebro humano responde às emoções e estímulos cognitivos. Recentemente, seu uso ganhou interesse na detecção em tempo real de sentimentos, proporcionando uma abordagem direta que não depende de expressões faciais ou voz. Isso é especialmente útil em cenários de recursos limitados, como na utilização de interfaces cérebro-computador para apoio à área de saúde mental. O objetivo desta dissertação é avaliar a classificação de sentimentos (positivo, negativo e neutro) em sinais de eletroencefalografia utilizando aprendizado de máquina e aprendizado profundo, com enfoque em redes neurais convolucionais em grafos (GCNN), a partir da análise dos principais atributos do sinal de EEG (Entropia Diferencial (DE), Densidade Espectral de Potência (PSD), Assimetria Diferencial ($DASM$), Assimetria Racional ($RASM$), assimetria (ASM), Causalidade Diferencial ($DCAU$)). O conjunto de dados de Eletroencefalografia utilizado na pesquisa foi o *dataset* público *SEED* (SJTU Emotion EEG Dataset), obtido por meio de estímulos auditivos e visuais na forma de trechos de filmes emocionais chineses. O experimento utilizado para avaliar o resultado dos modelos foi o "dependente do sujeito" e neste método o modelo de rede neural profunda (DNN) obteve uma acurácia de 85,22%, superando o SVM, embora com um tempo de processamento significativo devido a características de otimização inerentes ao algoritmo. O $GCNN$, com sua abordagem de aprendizado não linear e capacidade de modelar relações intrínsecas entre os canais de EEG através de grafos, obteve uma média de acurácia de 89,97% no experimento dependente do sujeito. Este trabalho contribui para a detecção de emoções em EEG, destacando a eficácia de diferentes modelos e enfatizando a escolha de características adequadas e o uso ético dessas tecnologias em aplicações práticas. O $GCNN$ emerge como a metodologia mais promissora para futuras pesquisas.

Palavras-chaves: Detecção de emoções; reconhecimento de emoções; Eletroencefalograma; Aprendizado de máquina; Aprendizado profundo; Redes Neurais Convolucionais em Grafos.

Abstract

The detection of emotions is a growing field aiming to comprehend and interpret human emotions from various data sources, including text, voice, and even physiological signals. Among these sources, Electroencephalogram (EEG) stands out as a unique and promising approach. EEG is a non-invasive monitoring technique that records the brain's electrical activity through electrodes placed on the scalp's surface, used in clinical and research contexts to explore how the human brain responds to emotions and cognitive stimuli. Recently, its use has gained interest in real-time emotion detection, offering a direct approach independent of facial expressions or voice. This is particularly useful in resource-limited scenarios, such as in brain-computer interfaces supporting mental health. The objective of this dissertation is to evaluate the classification of emotions (positive, negative, and neutral) in EEG signals using machine learning and deep learning, focusing on Graph Convolutional Neural Networks (GCNN), based on the analysis of key attributes of the EEG signal (Differential Entropy (DE), Power Spectral Density (PSD), Differential Asymmetry (DASM), Rational Asymmetry (RASM), Asymmetry (ASM), Differential Causality (DCAU)). The Electroencephalography dataset used in the research was the public SEED dataset (SJTU Emotion EEG Dataset), obtained through auditory and visual stimuli in the form of segments from Chinese emotional movies. The experiment employed to evaluate the model results was "subject-dependent," and in this method, the Deep Neural Network (DNN) achieved an accuracy of 86.08%, surpassing SVM, albeit with significant processing time due to optimization characteristics inherent to the algorithm. The GCNN, with its non-linear learning approach and the ability to model intrinsic relationships between EEG channels, achieved an average accuracy of 89.97% in the subject-dependent experiment. This work contributes to emotion detection in EEG, emphasizing the effectiveness of different models and underscoring the importance of selecting appropriate features and the ethical use of these technologies in practical applications. The GCNN emerges as the most promising methodology for future research.

Key-words: Emotion detection; emotion recognition; Electroencephalogram; Machine learning; Deep learning; Graph Convolutional Neural Networks.

Lista de ilustrações

Figura 1 – Amostras de ondas cerebrais para diferentes frequências.	18
Figura 2 – Sistema 10-20.	19
Figura 3 – Modelo de espaço de emoção.	20
Figura 4 – Função Sigmoidal	24
Figura 5 – Modelo K-vizinhos mais próximos.	26
Figura 6 – Máquina de vetor de suporte.	27
Figura 7 – Exemplo de uma Rede Neural Profunda	29
Figura 8 – Arquitetura Típica de uma Rede Neural Convolutiva	32
Figura 9 – Exemplo de um grafo direcionado (Esquerda) e a matriz de adjacência correspondente (Direita).	34
Figura 10 – Protocolo utilizado para aquisição dos dados de Eletroencefalografia do SEED.	49
Figura 11 – Arquitetura <i>GCNN</i>	54
Figura 12 – Metodologia de Aquisição, Processamento e Classificação dos dados de Eletroencefalografia.	55
Figura 13 – Abordagem de avaliação através de metodologia <i>subject-dependent</i>	56
Figura 14 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência δ	63
Figura 15 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência θ	64
Figura 16 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência α	64
Figura 17 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência β	65
Figura 18 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência γ	66
Figura 19 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para todas as frequências.	66

Lista de tabelas

Tabela 1 – Principais artigos utilizados para identificar o estado da Arte (<i>SOTA.</i>)	45
Tabela 2 – Resumo das principais características do dataset escolhido - SEED. . .	49
Tabela 3 – Descritivo de Atributos do SEED.	52
Tabela 4 – Resultado (Acurácia/Desvio Padrão) do modelo <i>LR</i>	57
Tabela 5 – Acurácia detalhada por indivíduo/sessão no modelo <i>LR</i> - <i>feature DE</i> .	58
Tabela 6 – Acurácia detalhada por indivíduo/sessão no modelo <i>LR</i> - <i>feature PSD</i> .	58
Tabela 7 – Acurácia detalhada por indivíduo/sessão no modelo <i>LR</i> - <i>feature DASM</i>	59
Tabela 8 – Acurácia detalhada por indivíduo/sessão no modelo <i>LR</i> - <i>feature RASM</i>	59
Tabela 9 – Acurácia detalhada por indivíduo/sessão no modelo <i>LR</i> - <i>feature ASM</i>	60
Tabela 10 – Acurácia detalhada por indivíduo/sessão no modelo <i>LR</i> - <i>feature DCAU</i>	60
Tabela 11 – Resultados (Acurácia/Desvio Padrão) dos modelos <i>LR</i> , <i>KNN</i> e <i>SVM</i> .	61
Tabela 12 – Resultados (Acurácia/Desvio Padrão) dos modelos <i>DNN</i> e <i>DGCNN</i> . .	61
Tabela 13 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos por <i>feature</i>	63
Tabela 14 – Comparação do modelo <i>DNN</i> com a literatura.	67
Tabela 15 – Comparativo de resultados com a literatura.	68

Lista de abreviaturas e siglas

BLS	<i>Broad Learning System</i>
CNN	<i>Convolutional Neural Network</i>
DASM	<i>Differential Asymmetry</i>
DBN	<i>Deep Belief Network</i>
DCAU	<i>Differential Caudality</i>
DE	<i>Differential Entropy</i>
DNN	<i>Deep Neural Networks</i>
ECLGCNN	Modelo combinado de <i>LSTM</i> e <i>GCNN</i>
EMG	Eletrooculograma
EOG	Eletromiograma
EEG	Eletroencefalograma
GCNN	<i>Graph Convolutional Neural Network</i>
GFT	<i>Graph Fourier Transform</i>
KNN	<i>k-Nearest Neighbors</i>
LR	<i>Logistic Regression</i>
LSTM	<i>Long Short-Term Memory Networks</i>
PSD	<i>Power Spectral Density</i>
RASM	<i>Rational Asymmetry</i>
RNAs	Redes Neurais Artificiais
RNNs	<i>Recurrent Neural Networks</i>
SOTA	<i>State-of-the-art</i>
SEED	<i>SJTU Emotion EEG Dataset</i>
SVM	<i>Support Vector Machine</i>

Sumário

1	INTRODUÇÃO	12
1.1	Objetivos	14
1.1.1	Objetivo geral	14
1.1.2	Objetivos Específicos	14
1.2	Justificativa	14
1.3	Organização da dissertação	15
2	FUNDAMENTOS TEÓRICOS E ESTADO DA ARTE	16
2.1	Sinais de eletroencefalograma - EEG	16
2.1.1	Posicionamento de Eletrodos e o Sistema Internacional 10-20	18
2.2	Reconhecimento de emoções	19
2.3	Modelos de Aprendizagem de Máquina Tradicionais	22
2.3.1	Supervisionado e Não supervisionado	22
2.3.1.1	Regressão Logística	23
2.3.1.2	K-vizinhos mais próximos (KNN)	25
2.3.1.3	Máquina de Vetores de Suporte (<i>SVM</i>)	26
2.4	Redes de Aprendizado Profundo - <i>DNN</i>	28
2.4.1	Redes Neurais Convolucionais - <i>CNNs</i>	30
2.5	Redes Neurais Convolucionais em Grafo - <i>GCNN</i>	32
2.5.1	Teoria de grafos	33
2.5.2	Filtragem Espectral	34
2.6	Estado da Arte	39
3	METODOLOGIA	46
3.1	Conjunto de Dados de eletroencefalografia	46
3.1.1	<i>SEED</i>	48
3.2	Pré-processamento de EEG	48
3.2.1	Extração de Atributos	48
3.2.2	Suavização de Características - <i>Feature Smoothing</i>	51
3.3	Experimentos	53
3.3.1	Modelos de Aprendizado de Máquina e Aprendizado profundo	53
3.3.2	Análise de resultados	54
4	RESULTADOS E DISCUSSÕES	57
4.1	Modelos de Aprendizagem de Máquina Tradicionais	57
4.2	Redes de Aprendizado Profundo	59

5	CONCLUSÕES	69
5.1	Trabalhos Futuros	70
	REFERÊNCIAS	71

1 Introdução

A detecção e compreensão de emoções humanas desempenham um papel fundamental no avanço das interações entre seres humanos e sistemas tecnológicos. Nos últimos anos, a aplicação de técnicas de processamento de sinais, aprendizado de máquina e inteligência artificial tem se mostrado promissora na análise de sinais de Eletroencefalografia (EEG) para a classificação de emoções (LI et al., 2022). O EEG é um registro eletrofisiológico da atividade cerebral que oferece informações sobre os estados emocionais de um indivíduo, fornecendo uma janela para a compreensão das respostas neurais subjacentes a diferentes estímulos emocionais (ROY et al., 2019).

O reconhecimento de emoções humanas concentra-se em uma variedade de modalidades, como expressões audiovisuais, linguagem corporal e sinais fisiológicos e em comparação com outras modalidades, os sinais fisiológicos, como eletroencefalografia (EEG), eletrocardiograma (ECG) e eletromiografia (EMG), têm a vantagem de ser difícil de ocultar ou disfarçar. Nos últimos anos, devido ao rápido desenvolvimento de dispositivos de gravação de EEG não invasivos, fáceis de utilizar e mais baratos em relação a outras técnicas de aquisição, como por exemplo Tomografia e Magnetencefalografia (MEG), o reconhecimento de emoção baseado em EEG recebeu uma quantidade crescente de atenção na pesquisa (WANG et al., 2023) e nas aplicações (ZHONG; WANG; MIAO, 2022). Embora o EEG tenha uma resolução espacial limitada e exija muitos eletrodos posicionados em vários locais na cabeça, fornece uma adequada resolução de tempo, permitindo que os pesquisadores estudem mudanças de fase na resposta a estímulos emocionais. Além disso, o uso de EEG é não invasivo, rápido e barato, tornando-o um método mais usual no estudo das respostas do cérebro a estímulos emocionais (ALARCAO; FONSECA, 2019a).

A relevância dessa área de pesquisa é evidente em suas aplicações potenciais em diversas áreas, como saúde mental (LI et al., 2020), interface cérebro-computador (TORRES et al., 2020) e análise de comportamento humano (SAEED et al., 2020). O uso de técnicas de análise de sinais EEG para a detecção de emoções pode aprimorar diagnósticos clínicos, personalizar intervenções terapêuticas e desenvolver interfaces mais intuitivas e adaptativas, abrindo caminho para uma interação mais natural entre seres humanos e tecnologia.

Embora diversos esforços já tenham sido empreendidos para explorar o uso de modelos de aprendizado de máquina, como Regressão Logística (LR), k-Vizinhos Mais Próximos (KNN), Máquinas de Vetores de Suporte (SVM), Redes Neurais Profundas (DNN) e Redes Convolucionais em Grafos Dinâmicos (DGCNN), na análise de emoções em sinais de EEG, muitos desafios ainda persistem (LIU et al., 2022; SHU et al., 2018).

A sobreposição de padrões de ativação cerebral entre diferentes emoções, a variabilidade interindividual e os ruídos inerentes aos sinais EEG são apenas alguns exemplos dos obstáculos que devem ser superados para alcançar uma classificação precisa e robusta (BOTA et al., 2019).

A análise do estado da arte revela que vários estudos têm se concentrado em abordagens específicas, explorando diferentes técnicas e modelos para a detecção de emoções em EEG. Diversas técnicas de aprendizado de máquina e aprendizado profundo têm sido empregadas na classificação de emoções em sinais de Eletroencefalografia. No campo do aprendizado de máquina tradicional, abordagens como Regressão Logística, k-Vizinhos Mais Próximos e Máquinas de Vetores de Suporte foram exploradas para modelar as relações entre atividades cerebrais e emoções. No âmbito do aprendizado profundo, Redes Neurais Profundas são utilizadas para extrair representações hierárquicas das características do EEG. As Redes Convolucionais em Grafos Dinâmicos foram introduzidas para considerar as relações espaciais e temporais nos dados EEG (SONG et al., 2018), enquanto técnicas avançadas como Recorrent Neural Networks (RNN) (LI et al., 2021), Long Short-Term Memory (LSTM) (FENG et al., 2022), Back Propagation Learning (BLS) (WANG et al., 2018) e *Sparse Coding* (ZHANG et al., 2023) têm sido incorporadas para melhorar a capacidade de captura de padrões e eficiência computacional. Essas abordagens buscam melhorar a precisão na classificação de emoções em EEG, superando desafios relacionados à complexidade dos dados, interpretabilidade dos modelos e generalização para diferentes contextos. Embora esses estudos tenham fornecido descobertas e possibilidades, ainda há lacunas a serem preenchidas em termos de desempenho, generalização e interpretabilidade dos modelos. Esta dissertação visa contribuir para o campo, explorando uma variedade de abordagens de aprendizado de máquina e avaliando suas vantagens e limitações na classificação de emoções em sinais de EEG.

Diante desse cenário, esta pesquisa se propõe a avançar no entendimento da detecção de emoções em sinais EEG, explorando e comparando a eficácia de modelos como Regressão Logística, K-vizinhos mais próximos, Máquina de Vetores de Suporte, Redes de aprendizado profundo e Redes Neurais Convolucionais em Grafo. Esta dissertação busca não apenas identificar os modelos com melhor desempenho, mas também aprofundar a compreensão das relações complexas entre os padrões de atividade cerebral e os estados emocionais. Ao abordar as lacunas existentes na literatura e fornecer uma análise abrangente das abordagens de aprendizado de máquina aplicadas a sinais de EEG para a classificação de emoções, esta pesquisa contribui para a evolução da área, com potencial para impactar positivamente a sociedade e a tecnologia.

A classificação de emoções em sinais de EEG representa um desafio multidisciplinar que envolve a interseção de processamento digital de sinais, aprendizado de máquina e neurociência. A utilização da *DGCNN* nesse contexto é uma abordagem inovadora,

aproveitando a capacidade da rede de aprender representações hierárquicas e dinâmicas, capturando a evolução temporal dos padrões neurais.

1.1 Objetivos

1.1.1 Objetivo geral

O objetivo desta dissertação é avaliar a classificação de emoções (positivo, negativo e neutro) em sinais de eletroencefalografia utilizando aprendizado de máquina e aprendizado profundo a partir da análise dos principais atributos do sinal de EEG (Entropia Diferencial (*DE*), Densidade Espectral de Potência (*PSD*), Assimetria Diferencial (*DASM*), Assimetria Racional (*RASM*), assimetria (*ASM*), Causalidade Diferencial (*DCAU*)).

1.1.2 Objetivos Específicos

Os objetivos específicos que devem ser alcançados neste trabalho são:

- Implementar e avaliar os modelos Regressão Logística, k-Vizinhos Mais Próximos, Máquinas de Vetores de Suporte, Redes Neurais Profundas e Redes Convolucionais em Grafos Dinâmicos no SJTU Emotion EEG Dataset (SEED).
- Realizar uma análise comparativa detalhada dos modelos de Regressão Logística, k-Vizinhos Mais Próximos, Máquinas de Vetores de Suporte, Redes Neurais Profundas e Redes Convolucionais em Grafos Dinâmicos na classificação de emoções em sinais de Eletroencefalografia.
- Analisar as principais características e padrões do EEG para identificar quais atributos do sinal são mais relevantes para a classificação de diferentes emoções.

1.2 Justificativa

A análise de EEG com modelos de Aprendizado de Máquina (ML) e Aprendizado Profundo (DL) apresenta evidências robustas de sua capacidade em fornecer informações cruciais sobre as emoções humanas (ROY et al., 2019). Ao decifrar padrões complexos de atividade cerebral, esses modelos conseguem estabelecer correlações entre a atividade elétrica cerebral e os estados emocionais, ampliando a compreensão das representações neurais associadas a diversas emoções. Dessa forma, este trabalho contribui para o avanço da compreensão e aplicação prática das emoções humanas ao identificar padrões nos sinais de EEG.

Adicionalmente, a necessidade de compreender as respostas emocionais é fundamental para o avanço de sistemas mais intuitivos e responsivos. Em um contexto cada vez mais

centrado no usuário, a capacidade de interpretar e reagir às emoções humanas torna-se crucial para o desenvolvimento de interfaces e interações mais eficazes. A compreensão das respostas emocionais permite a criação de tecnologias mais empáticas, capazes de se adaptar dinamicamente às necessidades e estados emocionais dos usuários. Além disso, essa compreensão aprofundada contribui para aplicações em diversas áreas, desde a saúde mental até a interação homem-máquina. Portanto, a pesquisa nesse campo é justificada pelo impacto significativo que pode ter na melhoria da experiência do usuário e na criação de sistemas mais humanizados e eficientes.

1.3 Organização da dissertação

No capítulo 2, serão abordados os fundamentos teóricos relacionados aos sinais de EEG, técnicas de reconhecimento de emoções e os modelos de aprendizado de máquina e profundo, incluindo as redes neurais convolucionais em grafo. O estado da arte fornecerá uma visão sobre os desenvolvimentos mais recentes na área. No capítulo 3, serão detalhadas as etapas da metodologia, desde a escolha do conjunto de dados até os processos de pré-processamento, extração de atributos e suavização. Os experimentos e a análise de resultados fornecerão informações sobre como os modelos foram aplicados e avaliados. Os resultados obtidos com os diferentes modelos serão apresentados e discutidos no capítulo 4. Isso incluirá uma análise comparativa entre os modelos tradicionais e de aprendizado profundo. Por fim, no capítulo 5 serão apresentadas as conclusões derivadas dos resultados e discutidas as direções futuras para pesquisa.

2 Fundamentos Teóricos e Estado da arte

O presente capítulo explora os fundamentos teóricos e o estado da arte na análise de emoções por meio de sinais de eletroencefalograma (EEG). Inicia-se com uma análise dos sinais EEG, abordando o posicionamento de eletrodos segundo o Sistema Internacional 10-20. Em seguida, são apresentados modelos tradicionais de aprendizado de máquina, como regressão logística, k-vizinhos mais próximos (*KNN*) e máquinas de vetores de suporte (*SVM*), destacando sua aplicação na classificação de emoções. O estudo também explora redes neurais convolucionais (*CNNs*) e redes neurais convolucionais em grafo (*GCNN*), introduzindo conceitos essenciais da teoria de grafos e filtragem espectral. O capítulo conclui com uma revisão concisa do estado atual da arte, fornecendo um panorama dos desenvolvimentos recentes. Essa compreensão é crucial para embasar os experimentos e a análise crítica dos resultados nos capítulos seguintes.

2.1 Sinais de eletroencefalograma - EEG

Os sinais de EEG têm desempenhado um papel crucial na compreensão das atividades elétricas do cérebro humano. Representando as flutuações elétricas geradas pela atividade neuronal, esses sinais disponibilizam informações valiosas sobre a dinâmica cerebral subjacente a diversos estados mentais e emocionais (ABHANG; GAWALI; MEHROTRA, 2016). Amplamente aplicada na investigação das correlações entre padrões de atividade cerebral e estados emocionais, a análise de EEG tem impulsionado progressos significativos na neurociência afetiva (NIEDERMEYER; SILVA, 2005). Essa abordagem não invasiva possibilita a exploração das complexas interações entre as emoções humanas e a atividade cerebral, trazendo contribuições substanciais tanto para a pesquisa fundamental quanto para aplicações práticas.

A relevância da análise de emoções a partir de sinais EEG repousa na habilidade de identificar padrões de atividade cerebral associados a diferentes estados emocionais. Cada estado emocional, como alegria, tristeza ou neutralidade, está conectado a padrões específicos de ativação neuronal, refletindo-se nos sinais EEG (ABHANG; GAWALI; MEHROTRA, 2016). Ao detectar esses padrões, torna-se possível acessar informações sobre os mecanismos neurais subjacentes à experiência emocional (KNYAZEY, 2007). Essa compreensão é de extrema importância para enriquecer o conhecimento acerca das bases neurobiológicas das emoções humanas, bem como para o desenvolvimento de aplicações práticas, como a detecção precoce de transtornos emocionais e a adaptação de interfaces cérebro-computador, visando aprimorar a interação humano-máquina (WANG et al., 2023).


No entanto, a análise de EEG também enfrenta desafios, incluindo a presença de

artefatos que podem obscurecer os padrões genuínos de atividade cerebral. Assim, uma etapa crítica na análise de emoções a partir de sinais EEG é o pré-processamento dos dados, que visa a remoção de artefatos e a melhoria da qualidade dos sinais (JIANG; BIAN; TIAN, 2019). Além disso, a localização dos eletrodos no couro cabeludo desempenha um papel central na interpretação dos padrões de atividade cerebral, visto que diferentes regiões cerebrais estão vinculadas a distintos estados emocionais (MICHEL; MURRAY, 2012). Portanto, a análise de sinais EEG estabelece uma conexão essencial entre a neurociência e a compreensão das emoções humanas, catalisando avanços significativos na pesquisa emocional e suas aplicações clínicas e tecnológicas.

A compreensão das características fundamentais dos sinais de eletroencefalograma, tais como frequência e amplitude, é essencial para uma análise precisa das emoções. Originados por oscilações elétricas que refletem a atividade cerebral, os sinais EEG apresentam uma variação de frequência relacionada a diferentes estados mentais e processos cognitivos (TORRES et al., 2020). Com amplitudes entre 1 μ V e 200 μ V, As faixas tradicionalmente consideradas são δ (0,5-4 Hz), θ (4-8 Hz), α (8-13 Hz), β (13-30 Hz) e γ (30-100 Hz), cada uma delas possuindo associações específicas com funções neurais. A atividade delta, por exemplo, está relacionada ao sono profundo, enquanto a gamma está ligada ao processamento perceptual (VIGÁRIO, 1997). As características de frequência, amplitude e atividade mental relacionada a cada banda são apresentadas na Figura 1. As ondas alfa estão tipicamente associadas a um estado mental relaxado, mas consciente, e são mais visíveis nos lobos parietal e occipital. A alta atividade alfa foi correlacionada com a inativação do cérebro. As ondas beta estão relacionadas a um estado mental ativo, mais proeminente no córtex frontal e em outras áreas durante intensa atividade mental focada. Finalmente, as ondas gama estão associadas a uma hiperatividade cerebral (BOTA et al., 2019).

Adicionalmente à frequência, a amplitude das ondas EEG constitui uma característica vital. Essa amplitude reflete a intensidade da atividade neural subjacente, variando em diferentes estados. Durante estados de relaxamento com os olhos fechados, a amplitude das ondas alpha é tipicamente maior, ao passo que a atividade beta pode aumentar durante tarefas cognitivas intensas (JENKE; PEER; BUSS, 2014). A relação entre amplitude e frequência das oscilações EEG oferece *insights* sobre distintos estados emocionais e cognitivos (HAGEMANN et al., 2005) A compreensão dessas características possibilita a identificação de padrões em diferentes bandas de frequência e suas amplitudes correspondentes, viabilizando uma análise emocional baseada em EEG e a eficaz classificação de emoções a partir das características singulares dos sinais cerebrais (PHAN et al., 2021).

Figura 1 – Amostras de ondas cerebrais para diferentes frequências.



Fonte: Adaptado de [Abhang, Gawali e Mehrotra \(2016\)](#).


2.1.1 Posicionamento de Eletrodos e o Sistema Internacional 10-20

Para a aquisição precisa de dados EEG, o sistema 10-20 é um padrão internacionalmente reconhecido e amplamente utilizado para o posicionamento de eletrodos ([KLEM et al., 1999](#)). Esse sistema oferece uma abordagem padronizada que utiliza pontos de referência anatômicos específicos para determinar a posição exata de cada eletrodo no escalpo do paciente. O sistema 10-20, nomeado devido à distância relativa entre os pontos de referência marcados a cada 10% ou 20% da distância entre pontos anatômicos correspondentes, permite a colocação consistente e precisa dos eletrodos em várias áreas do escalpo ([LI et al., 2020](#)). A padronização proporcionada pelo sistema 10-20 é crucial para a coleta de dados EEG de alta qualidade, possibilitando análises consistentes e comparáveis da atividade cerebral em diferentes indivíduos e grupos.

A notação alfanumérica empregada nos nomes dos eletrodos remete à área abrangente do cérebro onde cada eletrodo é posicionado, seguindo uma codificação precisa. Por exemplo, a designação *Fp* refere-se à região fronto-polar, *F* denota a área frontal, *C* representa a região central, *P* abrange a região parietal, *T* designa a área temporal, *O* identifica a área occipital e *A* indica a posição pré-auricular. Cada eletrodo é identificado por um nome que culmina em um número ou letra, sinalizando sua distância relativa em relação à linha média. Os números mais elevados correspondem a distâncias maiores da linha

média, enquanto os eletrodos posicionados diretamente na linha média são identificados com a letra *z*. Uma peculiaridade relevante é que os eletrodos do hemisfério esquerdo são designados com números ímpares, ao passo que os correspondentes do hemisfério direito ostentam números pares. Para uma visualização clara do padrão internacional adotado, uma representação elucidativa dessa distribuição é apresentada na Figura 2.

Figura 2 – Sistema 10-20.



Fonte: Alarcao e Fonseca (2019b)

A aplicação do sistema 10-20 é essencial não apenas para garantir a coleta de dados confiáveis, mas também para interpretar de maneira precisa as atividades elétricas cerebrais (ALARCAO; FONSECA, 2019b). Ao seguir esse sistema de posicionamento, os pesquisadores podem obter informações consistentes sobre a atividade cerebral em diversas aplicações de pesquisa e clínicas. A padronização proporcionada pelo sistema 10-20 assegura que as áreas cerebrais de interesse sejam adequadamente cobertas pelos eletrodos, permitindo análises específicas e confiáveis que são fundamentais para a obtenção de insights significativos sobre as atividades elétricas do cérebro (ABHANG; GAWALI; MEHROTRA, 2016).


2.2 Reconhecimento de emoções

As emoções representam estados complexos que influenciam significativamente o comportamento humano e a tomada de decisões (ALHALASEH; ALASASFEH, 2020). Elas são compostas por respostas psicológicas, fisiológicas e comportamentais que ocorrem

em reação a estímulos internos e externos. De acordo com [Ekman \(1992\)](#), existem seis emoções básicas universais, como alegria, tristeza, medo, raiva, surpresa e aversão, que são expressas de maneira semelhante em várias culturas. Essas emoções podem ser identificadas por meio de expressões faciais, padrões vocais e até mesmo mudanças na atividade cerebral. [Plutchik \(2001\)](#) propôs oito emoções discretas ao adicionar duas a mais (curiosidade e aceitação).

O modelo dimensional de emoções pode ser representado como um espaço bidimensional ou tridimensional, conforme demonstrado nas Figuras 3a e 3b respectivamente. Valência se refere à atratividade intrínseca/bondade (valência positiva) ou aversão/maldade (valência negativa). A ativação reflete o nível de vigilância mental da emoção e a intensidade da ativação fisiológica que um indivíduo sente. Dominação se refere ao status de um indivíduo, isto é, estar no controle ou ser controlado ([SHU et al., 2018](#)).

Figura 3 – Modelo de espaço de emoção.



Fonte: [Shu et al. \(2018\)](#).

As emoções têm uma base neural complexa e variada, envolvendo várias regiões do cérebro interconectadas ([SANEI; CHAMBERS, 2013](#)). O córtex pré-frontal, por exemplo, está envolvido na regulação emocional e na tomada de decisões, enquanto a amígdala desempenha um papel crucial no processamento do medo e de estímulos emocionais intensos ([PHAN et al., 2002](#)). Através de técnicas de neuroimagem funcional, como ressonância magnética funcional (fMRI), tem sido possível mapear as áreas cerebrais envolvidas em diferentes emoções ([BABAYAN et al., 2019](#)). Estudos têm demonstrado que a emoção da empatia, por exemplo, está associada a uma maior atividade nas áreas de cíngulo anterior e ínsula anterior ([LAMM; DECETY; SINGER, 2011](#)). A compreensão dessas correlações entre a atividade cerebral e as emoções é crucial para o desenvolvimento de modelos de reconhecimento de emoções com base em dados neurais.

Cada emoção desencadeia padrões específicos de ativação neuronal, permitindo sua

identificação por meio de análise de sinais cerebrais. A emoção do medo, por exemplo, é frequentemente associada a um aumento na atividade da amígdala, enquanto a alegria está ligada a uma maior atividade no córtex pré-frontal ventral (ADOLPHS et al., 2005). Esses padrões podem ser detectados por técnicas como EEG, que registra a atividade elétrica do cérebro com alta resolução temporal. A análise de características EEG, como frequências dominantes em diferentes faixas (θ , α , β) e padrões de sincronização entre áreas cerebrais, tem sido usada para identificar a ativação associada a emoções específicas (KREIBIG, 2010). O entendimento desses padrões é essencial para a construção de modelos robustos de reconhecimento de emoções baseados em EEG.

O EEG tem se mostrado uma abordagem promissora para identificar padrões de atividade cerebral associados a diferentes emoções. A análise de frequências específicas, como a maior atividade alfa durante estados de relaxamento, permite a detecção de estados emocionais particulares (AFTANAS; GOLOCHEIKINE, 2001). Além disso, a coerência inter-hemisférica das oscilações cerebrais tem sido utilizada para distinguir emoções positivas e negativas (BALCONI; VANUTELLI, 2016). A aplicação de técnicas avançadas de aprendizado de máquina, como classificação baseada em redes neurais convolucionais, também tem demonstrado sucesso na identificação de emoções a partir de padrões EEG (ZHANG et al., 2019). Isso destaca o potencial do EEG como uma ferramenta valiosa no reconhecimento objetivo de estados emocionais.

Na medicina, pode ser usado para monitorar distúrbios neuropsiquiátricos, como depressão e ansiedade (LIN et al., 2010). Na interação humano-máquina, o reconhecimento de emoções pode melhorar a adaptabilidade de sistemas, personalizando a experiência do usuário com base em seu estado emocional (PICARD et al., 2004). Além disso, a análise de emoções em ambientes de aprendizado pode fornecer informações sobre o engajamento e a eficácia do ensino. O uso de EEG para identificar emoções também é relevante em contextos de pesquisa em neurociência afetiva, ajudando a elucidar os mecanismos neurais subjacentes a diferentes estados emocionais. (HERNANDEZ et al., 2014)

Apesar do progresso no reconhecimento de emoções por meio de técnicas EEG, existem desafios significativos a serem superados. A natureza subjetiva das emoções e a variabilidade interindividual podem dificultar a criação de modelos universalmente precisos. Além disso, a sobreposição de padrões de ativação cerebral entre diferentes emoções pode levar a ambiguidades na classificação (JIRAYUCHAROENSAK; PAN-NGUM; ISRASENA, 2014). A variabilidade de resposta do EEG devido a fatores como idade, gênero e estado de saúde também deve ser considerada (LIU et al., 2022). Esses desafios ressaltam a importância de abordagens robustas e multidisciplinares para o reconhecimento de emoções.

A evolução da neurociência computacional e do aprendizado de máquina possibilita impulsionar ainda mais as técnicas de reconhecimento de emoções a partir de dados

de Eletroencefalografia. A integração de abordagens de aprendizado profundo, como redes neurais convolucionais e redes neurais convolucionais em grafo, pode melhorar a capacidade de identificar padrões complexos nos sinais EEG (WANG et al., 2023). Além disso, utilização de técnicas de interpretabilidade de modelos pode proporcionar uma compreensão mais abrangente das correlações entre a atividade cerebral e as emoções ao utilizar métodos que fornecem visualizações dos padrões de ativação nos nós e arestas do grafo durante o processo de tomada de decisão (MONTI et al., 2016). Essas tendências promissoras abrem caminho para avanços significativos no campo do reconhecimento de emoções, com potencial para impactar diversas aplicações práticas e científicas.

2.3 Modelos de Aprendizagem de Máquina Tradicionais

2.3.1 Supervisionado e Não supervisionado

A aprendizagem de máquina desempenha um papel crucial na capacidade de os sistemas computacionais adquirirem conhecimento a partir de dados. Dois paradigmas amplamente empregados nesse contexto são os modelos de aprendizagem de máquina supervisionados e não supervisionados. Em uma abordagem supervisionada, os algoritmos são treinados com um conjunto de dados rotulados, ou seja, dados em que as respostas desejadas são conhecidas (MURPHY, 2022). Isso permite que os modelos construam relações entre os atributos dos dados e suas respectivas categorias ou valores-alvo. A técnica supervisionada tem sido amplamente utilizada para tarefas como classificação e regressão, onde o objetivo é prever a categoria ou o valor de saída com base nas características dos dados de entrada (GÉRON, 2019).

Muitos métodos existentes de reconhecimento de emoções baseados em EEG são baseados principalmente na abordagem de aprendizado de máquina supervisionado, em que os recursos são frequentemente extraídos de sinais EEG pré-processados em cada canal em uma janela de tempo. Em seguida, um classificador é treinado nas características extraídas para reconhecer emoções (ZHONG; WANG; MIAO, 2022). Algoritmos populares, como a Regressão Logística, o K-Vizinhos Mais Próximos e as Máquinas de Vetores de Suporte, são exemplos notáveis de abordagens supervisionadas que têm sido aplicadas com sucesso em diversas áreas, como reconhecimento de padrões (HASTIE; TIBSHIRANI; FRIEDMAN, 2009), processamento de linguagem natural (ZHANG, 2022) e visão computacional (TOĞAÇAR; ERGEN; CÖMERT, 2020).

Por outro lado, na aprendizagem de máquina não supervisionada, os algoritmos são aplicados a conjuntos de dados não rotulados, sem informações prévias sobre categorias ou valores-alvo. O objetivo principal é encontrar padrões, estruturas ocultas ou agrupamentos intrínsecos nos dados (MURPHY, 2022). Isso torna a aprendizagem não supervisionada especialmente útil para tarefas como análise de cluster, redução de dimensionalidade e

detecção de anomalias (LE et al., 2012). Métodos de aprendizagem não supervisionada, como o K-Means e a *Hierarchical Clustering*, são amplamente empregados para explorar e compreender a estrutura subjacente aos dados, o que pode ser crucial para insights em domínios como bioinformática, marketing e ciências sociais (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Além disso, em redes neurais, algoritmos de *autoencoder* são comumente utilizados em tarefas de aprendizagem não supervisionada, destacando a versatilidade dessas abordagens para descobrir representações úteis nos dados. Em resumo, a diferenciação entre abordagens supervisionadas e não supervisionadas desempenha um papel fundamental na seleção de estratégias adequadas para resolver uma ampla gama de desafios de aprendizagem de máquina, permitindo uma análise abrangente e eficaz dos dados.

2.3.1.1 Regressão Logística

A regressão logística é uma técnica essencial de aprendizado de máquina que encontra aplicação em diversos cenários, sendo particularmente útil quando se lida com variáveis categóricas, como é o caso da classificação de emoções (MURPHY, 2022). Esse método é apropriado quando a variável de saída pertence a um conjunto finito de classes discretas. Através da regressão logística, é possível estimar a probabilidade de uma instância ser atribuída a uma classe específica, e com base nessas probabilidades, realizar a decisão de classificação. Esse processo é crucial para determinar se uma dada amostra de sinal de Eletroencefalografia, por exemplo, pode ser categorizada como tendo uma emoção positiva, negativa ou neutra.

O modelo de regressão logística é baseado na função logística (ou função sigmoide), que mapeia os valores de entrada para um intervalo entre 0 e 1. A função sigmoide σ é definida por

$$\sigma(z) = \frac{1}{1 + e^{-z}}, \quad (2.1)$$

em que z é a combinação linear das variáveis de entrada ponderadas pelos coeficientes do modelo.


A função de decisão da regressão logística calcula a probabilidade estimada de que uma instância pertença a uma classe específica. Para problemas de classificação binária, se a probabilidade estimada p for maior do que um limiar predefinido (geralmente 0,5), a instância é classificada como pertencente à classe positiva; caso contrário, é classificada como pertencente à classe negativa, conforme demonstrado na Figura 4.

A partir da Equação 2.1 tem-se:

$$P(Y = 1|X) = \frac{1}{1 + e^{-\beta_0 - \beta_1 X_1 - \beta_2 X_2 - \dots - \beta_n X_n}} \quad (2.2)$$

em que $P(Y = 1|X)$ é a probabilidade condicional de que a variável dependente Y seja igual a 1 dado um conjunto de variáveis independentes X . $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ são os coefi-

Figura 4 – Função Sigmoidal



Fonte: Autoria própria.

entes do modelo, que representam o impacto das variáveis independentes $X_1, X_2, \dots, X_n$ na probabilidade de Y ser igual a 1. $X_1, X_2, \dots, X_n$ são as variáveis independentes que estão sendo usadas para prever a variável dependente Y .

A função logística $\frac{1}{1+e^{-z}}$, em que z é a combinação linear das variáveis independentes ponderadas pelos coeficientes, é usada para transformar a combinação linear das variáveis em uma probabilidade. Essa função tem a propriedade de mapear qualquer valor real para um intervalo entre 0 e 1.

Para estimar os coeficientes β , é comum usar o método de máxima verossimilhança (BISHOP, 2016). O objetivo é encontrar os valores de β que maximizam a verossimilhança dos dados observados, ou seja, que tornam os dados observados mais prováveis de ocorrerem de acordo com o modelo.

Uma vez que os coeficientes β são estimados, eles podem ser usados para prever a probabilidade de Y ser igual a 1 para novos conjuntos de valores de X . Se a probabilidade prevista for maior que 0.5, podemos classificar o evento como pertencente à categoria 1; caso contrário, classificamos como pertencente à categoria 0.

A regressão logística é amplamente usada em problemas de classificação binária e pode ser estendida para cenários de classificação multiclasse e análise de regressão ordinal, entre outros. Ela é uma técnica fundamental em estatística e aprendizado de máquina.

O treinamento da regressão logística envolve a estimativa dos coeficientes do modelo que melhor se ajustam aos dados de treinamento. Isso é alcançado por meio da minimização de uma função de perda, como a função de perda *log loss* (ou entropia cruzada), que quantifica a discrepância entre as probabilidades previstas e as classes reais. Os coeficientes são atualizados iterativamente usando algoritmos de otimização, como o gradiente. A regressão logística pode ser regularizada para evitar *overfitting*. A regularização L1 (Lasso)

e L2 (*Ridge*) são abordagens comuns que adicionam termos de penalização aos coeficientes do modelo durante o treinamento (GÉRON, 2019).

2.3.1.2 K-vizinhos mais próximos (KNN)

O algoritmo de K-vizinhos mais próximos é um método de aprendizado de máquina supervisionado com aplicação tanto em classificação quanto em regressão. Baseado na premissa de que objetos similares pertencem à mesma classe, o KNN calcula a classe de um novo ponto de dados com base nas classes de suas k amostras de treinamento mais próximas, usando uma métrica de distância, como a Euclidiana (MURPHY, 2022).

Dado Um conjunto de treinamento com pares de entrada e suas classes correspondentes: $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ e um exemplo de entrada de teste: x_{teste} , busca-se o número inteiro K que representa o número de vizinhos mais próximos a serem considerados.

A distância entre dois pontos x e x_i no espaço de características pode ser calculada como:

$$\text{Distância Euclidiana: } \text{dist}(x, x_i) = \sqrt{\sum_{j=1}^d (x_j - x_{i_j})^2} \quad (2.3)$$

ou


$$\text{Distância de Manhattan: } \text{dist}(x, x_i) = \sum_{j=1}^d |x_j - x_{i_j}| \quad (2.4)$$

em que d é a dimensão dos dados de entrada. Após calcular as distâncias, os K exemplos de treinamento mais próximos são selecionados com base nessas distâncias. Em seguida, a classe predominante entre esses K vizinhos é determinada por meio de votação. Ou seja, a classe mais comum entre os vizinhos é atribuída ao exemplo de teste, conforme exemplificado na Figura 5 .

A escolha do valor de K é importante e pode influenciar os resultados do algoritmo. Um valor muito pequeno de K pode levar a uma classificação sensível ao ruído, enquanto um valor muito grande pode tornar o modelo menos sensível a nuances nos dados (BISHOP, 2016).

Quando aplicado ao reconhecimento de emoções a partir de dados de eletroencefalograma (EEG), o KNN desempenha um papel crucial na identificação de padrões de atividade cerebral associados a diferentes estados emocionais (GÉRON, 2019). A cada amostra de EEG, atribui-se um vetor de características representando a atividade cerebral. O KNN, então, processa essas amostras, calculando as distâncias entre elas e selecionando os k vizinhos mais próximos. Com base nas emoções predominantes entre esses vizinhos, o KNN atribui a emoção correspondente à nova amostra (BISHOP, 2016).

Figura 5 – Modelo K-vizinhos mais próximos.



Fonte: Adaptado de [Azmi et al. \(2022\)](#).

2.3.1.3 Máquina de Vetores de Suporte (SVM)

A Máquina de Vetores de Suporte é um modelo de aprendizado de máquina supervisionado utilizado para tarefas de classificação e regressão. Seu objetivo fundamental é encontrar o hiperplano de separação que maximize a margem entre diferentes classes de dados em um espaço de características ([WU et al., 2017](#)). O conceito chave por trás do *SVM* é escolher o hiperplano que melhor divide as classes de maneira a maximizar a distância entre ele e os pontos mais próximos de cada classe, chamados de vetores de suporte. Isso permite que o *SVM* generalize bem para novos dados, evitando *overfitting* ([VAPNIK, 2000](#)).

Uma das principais características do *SVM* é sua capacidade de lidar com dados que não são linearmente separáveis no espaço de características original. Para isso, ele utiliza a técnica de *kernel*, que mapeia os dados para um espaço de dimensão superior onde a separação linear é possível ([SCHÖLKOPF et al., 2001](#)). Um exemplo de *kernel* amplamente usado é o *kernel* gaussiano (*RBF*), que projeta os dados em um espaço infinitamente dimensional ([JIN et al., 2019](#)). A escolha do *kernel* depende da natureza dos dados e da complexidade da separação desejada.

Dado um conjunto de treinamento $X = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, em que x_i é um vetor de características e y_i é a classe associada (-1 ou $+1$), o objetivo é encontrar um hiperplano definido por $w \cdot x + b = 0$, em que, w é o vetor de pesos e b é o termo de viés, conforme demonstrado na Figura 6.

A margem é definida como a distância perpendicular entre o hiperplano e os exemplos de treinamento mais próximos, conhecidos como vetores de suporte. A margem é calculada como $\rho(w, b) = \frac{2}{\|w\|}$.


O problema de otimização das SVMs pode ser formulado da seguinte forma:

$$\text{Maximizar } \frac{2}{\|w\|}$$

$$\text{Sujeito a } y_i(w \cdot x_i + b) \geq 1 \quad \text{para todo } i$$

Isso significa que busca-se maximizar a margem enquanto é garantido que todos os exemplos de treinamento estejam fora de uma “zona de segurança” definida pelas restrições.

Figura 6 – Máquina de vetor de suporte.



Fonte: Adaptado de [Paul \(2018\)](#).

Para lidar com dados não linearmente separáveis, as *SVMs* utilizam o "truque" do *kernel*. Isso envolve o mapeamento dos dados para um espaço de maior dimensão onde eles podem ser linearmente separáveis. O problema de otimização com kernel pode ser escrito como:

$$\text{Maximizar } \frac{2}{\|w\|}$$

$$\text{Sujeito a } y_i(w \cdot \phi(x_i) + b) \geq 1 \quad \text{para todo } i$$

em que $\phi(x_i)$ é a função de mapeamento para o espaço de maior dimensão. Uma vez que o hiperplano é determinado, a função de decisão para classificar novos exemplos x é calculada como $f(x) = w \cdot \phi(x) + b$. Se $f(x)$ for positivo, o exemplo é classificado como $+1$, e se for negativo, é classificado como -1 .

A capacidade de separação de classes do *SVM* é notável, pois busca encontrar um equilíbrio entre maximizar a margem entre classes e minimizar erros de classificação. Em essência, o *SVM* está focado em encontrar a melhor fronteira de decisão que separe as classes de maneira ótima. Essa fronteira é determinada pelos vetores de suporte, que são os pontos mais próximos ao hiperplano de separação ([MURPHY, 2022](#)). O resultado é um modelo que pode lidar eficazmente com dados não lineares e complexos, tornando-o adequado para tarefas de classificação onde as relações entre as classes não são simples.

No contexto do reconhecimento de emoções a partir de dados EEG, o *SVM* pode ser aplicado transformando os padrões de atividade cerebral em um espaço de características e treinando o *SVM* para encontrar o hiperplano que melhor separa as diferentes emoções

(WU et al., 2017). A técnica de *kernel* do *SVM* é particularmente útil para lidar com as nuances e complexidades dos padrões cerebrais relacionados a diferentes estados emocionais. Isso permite uma classificação mais precisa e geralmente superior em relação a abordagens mais simples. Portanto, o *SVM* é uma ferramenta poderosa para a análise de dados EEG emocionais, contribuindo para uma melhor compreensão das respostas emocionais do cérebro.


É evidente que as técnicas de *SVM*, *KNN* e a *LR* têm desempenhado um papel significativo na resolução de problemas de classificação e regressão (BISHOP, 2016). No entanto, à medida que os desafios se tornam mais complexos e os conjuntos de dados aumentam em tamanho e complexidade, surge a necessidade de abordagens mais avançadas. É neste cenário que entram as técnicas de aprendizado profundo, também conhecidas como redes neurais profundas, que têm revolucionado o campo da inteligência artificial. Ao contrário dos modelos tradicionais, o aprendizado profundo é capaz de aprender representações hierárquicas complexas dos dados, automaticamente extrair características relevantes e, assim, enfrentar problemas de alta dimensionalidade e não linearidade de maneira eficaz (BISHOP, 2016).

2.4 Redes de Aprendizado Profundo - *DNN*

A aprendizagem profunda emergiu como uma área proeminente no campo da inteligência artificial, proporcionando avanços notáveis em uma variedade de aplicações complexas. Essa abordagem tem nas Redes Neurais Artificiais (*RNAs*) sua base, buscando simular o funcionamento do cérebro humano por meio de neurônios artificiais interconectados. Esse paradigma possibilita a extração de características complexas e tomada de decisões informadas a partir de dados brutos, contribuindo para um aprendizado automático de representações de alto nível (LECUN; BENGIO; HINTON, 2015).

Dentro dessa perspectiva, as Redes Neurais Profundas (*DNNs*) se destacam como uma categoria especializada de *RNAs* que apresenta múltiplas camadas ocultas, permitindo modelar hierarquias de abstrações cada vez mais complexas (GOODFELLOW; BENGIO; COURVILLE, 2016). As *DNNs* são compostas por camadas de entrada, camadas ocultas e uma camada de saída. A informação flui das camadas de entrada para as camadas ocultas por meio de conexões ponderadas, e cada neurônio processa a informação ponderada e a encaminha usando funções de ativação não-lineares (BENGIO; COURVILLE; VINCENT, 2013). Essas redes operam por meio de dois processos centrais: o *feedforward*, onde os dados de entrada são propagados pelas camadas, e o *backpropagation*, em que os erros de saída são retropropagados para ajustar os pesos das conexões e melhorar a precisão da rede (RUMELHART; HINTON; WILLIAMS, 1986). Um exemplo de modelo clássico é apresentado na Figura 7.

Figura 7 – Exemplo de uma Rede Neural Profunda



Fonte: Adaptado de Roy et al. (2019).

No entanto, o desempenho das *DNNs* está intrinsecamente ligado ao ajuste de hiperparâmetros, que desempenham um papel vital em sua eficácia. Hiperparâmetros como a taxa de aprendizagem, o número de camadas ocultas e o tamanho do lote de treinamento têm um impacto direto na capacidade da rede de convergir para a solução ótima e evitar problemas como convergência lenta ou *overfitting*. O cuidadoso ajuste desses hiperparâmetros pode resultar em melhorias significativas na eficácia e generalização da rede para novos dados (BERGSTRA et al., 2011).

As aplicações das *DNNs* têm se mostrado inovadoras em diversas áreas. Na visão computacional, as *DNNs* revolucionaram a detecção de objetos (PARK et al., 2023), reconhecimento facial (CAO et al., 2022) e segmentação de imagens (LIU; DENG; YANG, 2019), trazendo avanços notáveis para tecnologias de veículos autônomos (LECUN; BENGIO; HINTON, 2015). No processamento de linguagem natural, as *DNNs* têm impulsionado a tradução automática, análise de emoções em textos e geração de linguagem natural (GOLDBERG, 2017). Além disso, na medicina, as *DNNs* têm sido aplicadas na análise de imagens médicas e no diagnóstico precoce de doenças, demonstrando um potencial impacto significativo em várias áreas (LITJENS et al., 2017). Esses exemplos refletem a crescente variedade de aplicações das *DNNs* em campos diversos.

As *DNNs* têm ganhado destaque em relação aos modelos tradicionais devido a diversas vantagens intrínsecas que oferecem. Uma das principais vantagens é a capacidade de aprendizado hierárquico de representações complexas diretamente de dados brutos ou minimamente pré-processados (GOODFELLOW; BENGIO; COURVILLE, 2016). Isso evita a necessidade de engenharia de recursos manual intensiva, comum em modelos tradicionais, o que pode ser uma etapa demorada e propensa a erros. A abordagem das *DNNs* permite que as redes aprendam automaticamente características relevantes,

aumentando a eficiência e qualidade das representações extraídas dos dados (HINTON; OSINDERO; TEH, 2006; SCHMIDHUBER, 2015).

No entanto, enquanto as *DNNs* possuem vantagens notáveis, também apresentam algumas limitações. Uma delas é a exigência de grandes conjuntos de dados para um treinamento eficaz. *DNNs* geralmente requerem quantidades significativas de exemplos para aprender com sucesso as complexas relações nos dados. Além disso, o treinamento de *DNNs* é computacionalmente intensivo, demandando poder computacional substancial e recursos para evitar *overfitting*. Essas limitações podem ser obstáculos, especialmente em contextos onde conjuntos de dados são limitados ou recursos computacionais são escassos (BENGIO, 2012; GOODFELLOW; BENGIO; COURVILLE, 2016).

Apesar das limitações, as vantagens das *DNNs*, como o aprendizado hierárquico a partir de dados brutos, frequentemente superam as desvantagens, tornando-as ideais para tarefas complexas de processamento de dados, como o processamento de sinais de EEG (FAUST et al., 2018). A capacidade de aprender representações relevantes diretamente dos dados brutos permite explorar os detalhes intrínsecos das informações cerebrais, fornecendo um aprimoramento significativo em relação aos modelos tradicionais, que muitas vezes dependem de recursos pré-definidos e processamento manual (SCHMIDHUBER, 2015).

2.4.1 Redes Neurais Convolucionais - *CNNs*

As Redes Neurais Convolucionais (*CNNs*) surgiram como uma classe de arquiteturas de aprendizado profundo que revolucionaram a visão computacional. Elas foram projetadas especificamente para processar dados em forma de grade, como imagens, explorando a natureza local e hierárquica das informações visuais (ZHANG et al., 2023). Podem ser aplicadas também em tarefas de processamento de linguagem natural (PLN), reconhecimento de voz, em diagnósticos médicos e análise de grafos (KIPF; WELLING, 2017). A arquitetura das *CNNs* é tipicamente composta de três camadas:

1. Camada Convolutiva (*CL*): Nas *CNNs*, as camadas de convolução são fundamentais para a detecção de características complexas em dados de entrada, como imagens. Cada camada de convolução consiste em um conjunto de filtros (ou kernels) que são aplicados a regiões específicas da entrada. Esses filtros realizam operações de convolução, que envolvem multiplicar os valores dos pixels da região de entrada pelos valores correspondentes do filtro, somar os resultados e gerar um valor de saída. Essa operação permite que a rede identifique bordas, texturas e padrões distintos na imagem. À medida que as camadas de convolução são empilhadas, os filtros subsequentes podem capturar características mais abstratas e complexas, aumentando a capacidade de reconhecimento da rede. A operação de convolução 2D pode ser definida por,

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) \cdot K(m, n) \quad (2.5)$$

em que $S(i, j)$ é o valor na posição (i, j) da saída da convolução, I é a matriz de entrada e K é o filtro.

2. Camada de *Pooling* (*PL*): Após as camadas de convolução, as *CNNs* frequentemente incluem camadas de *pooling*. O *pooling* é uma técnica usada para reduzir a dimensionalidade dos mapas de características gerados pelas camadas de convolução. Essa redução é alcançada por meio da amostragem de valores representativos de regiões adjacentes. Um tipo comum de *pooling* é o *max pooling*, representado na Equação 2.6, onde o valor máximo dentro de uma região é selecionado como representante. Isso ajuda a manter características relevantes enquanto reduz a complexidade computacional da rede e auxilia no controle de *overfitting*. O *pooling* também contribui para tornar a rede mais invariante a pequenas variações na posição das características.


$$MaxPooling(x, y) = \max_{i, j \in R_{x, y}} \text{Input}(i, j) \quad (2.6)$$

em que $R_{x, y}$ é a região de entrada mapeada para a saída.

3. Camada Totalmente Conectada (*FC*): Após a etapa de convolução e *pooling*, as *CNNs* geralmente incorporam camadas totalmente conectadas (ou densas) para realizar tarefas de classificação ou regressão. Nessas camadas, todos os neurônios estão conectados a cada neurônio da camada anterior, formando um grafo completamente conectado. Os valores resultantes após a convolução e o *pooling* são achatados em um vetor e passados por essas camadas. Essas camadas finais realizam operações lineares, seguidas por funções de ativação não-lineares, para mapear os recursos extraídos para as classes de saída desejadas. Isso permite que a CNN tome decisões sobre as categorias de objetos presentes na entrada.

Uma arquitetura típica de uma *CNN* utilizada para a classificação de sinais EEG é apresentada na Figura 8. A arquitetura das *CNNs* é construída em camadas que operam em conjunto para extrair, representar e interpretar características complexas nos dados de entrada, permitindo a realização de tarefas de classificação e reconhecimento de padrões (SONG et al., 2022). A extensão das *CNNs* para o domínio de dados estruturados tem como objetivo aplicar o poder das *CNNs* em tarefas que envolvem estruturas complexas, como grafos. Ao contrário de dados de grade regular, os dados estruturados são representados por meio de relações não uniformes entre elementos (SONG et al., 2018). Esses elementos e suas interações são frequentemente modelados como nós e arestas em um grafo. Essa extensão é particularmente valiosa em domínios onde os dados têm uma natureza intrinsecamente interconectada, como redes sociais, sistemas de recomendação, bioinformática e análise de linguagem natural (NEWMAN, 2010).

Figura 8 – Arquitetura Típica de uma Rede Neural Convolutacional



Fonte: Adaptado de [Rajwal e Aggarwal \(2023\)](#).

A adaptação das convoluções para a estrutura de grafos é um passo crucial para incorporar as vantagens das *CNNs* em dados estruturados. Convoluções em grafos estendem os princípios das convoluções tradicionais, levando em consideração as relações e a topologia das arestas em um grafo. Ao contrário das convoluções em dados de grade, onde os filtros são aplicados a regiões fixas, as convoluções em grafos aplicam transformações ponderadas aos nós, levando em conta seus vizinhos conectados ([DEFFERRARD; BRES-SON; VANDERGHEYNST, 2016](#)). Isso permite a extração de informações estruturais e contextuais das relações entre os nós, permitindo a identificação de padrões complexos e características significativas nos dados estruturados.

2.5 Redes Neurais Convolucionais em Grafo - *GCNN*

Com o avanço da pesquisa em aprendizado profundo, surgiram arquiteturas mais complexas e destacadas, uma das quais é a arquitetura de Redes Neurais Convolucionais em Grafo. Essa abordagem representa uma evolução das *CNNs* tradicionais, ao expandir sua aplicabilidade para dados estruturados e relacionados, como grafos e redes ([HENAFF; BRUNA; LECUN, 2015](#)). Em comparação com a rede neural convolutacional clássica, a rede neural convolutacional gráfica é vantajosa na extração de características discriminativas de sinais no domínio espacial discreto ([YONGQIANG, 2021](#)).

A arquitetura *GCNN* utiliza operações de convolução adaptadas para grafos, de

modo que cada nó do grafo possa interagir com seus vizinhos, capturando assim informações contextuais e relacionais. Isso torna a *GCNN* particularmente adequada para uma variedade de aplicações, incluindo análise de redes sociais, modelagem molecular e reconhecimento de padrões em dados relacionais complexos (DEFFERRARD; BRESSON; VANDERGHEYNST, 2016). Ao abordar dados nesses contextos, a arquitetura *GCNN* preserva as vantagens das *CNNs*, como a capacidade de aprender representações hierárquicas e abstratas, enquanto incorpora a estrutura e as conexões específicas dos dados em questão (KIPF; WELING, 2017).

2.5.1 Teoria de grafos

A teoria de grafos é um campo essencial da matemática e ciência da computação que proporciona uma estrutura para modelar e analisar as interações entre elementos. Grafos são representações abstratas e visuais compostas por nós (ou vértices) e suas conexões, denominadas arestas (CHUNG, 1997). Essa estrutura é amplamente empregada para descrever situações do mundo real, como redes sociais, sistemas de transporte, circuitos elétricos e modelagem molecular (SCARSELLI et al., 2009).

Os nós de um grafo representam entidades individuais, enquanto as arestas definem as relações ou interações entre essas entidades. As arestas podem ser direcionadas ou não direcionadas, dependendo do contexto. No caso de grafos direcionados, as arestas têm uma orientação específica, indicando uma relação unidirecional entre os nós (BONDY; MURTY, 1976). Por exemplo, em uma rede social, um grafo direcionado pode representar “seguir” ou “amizade” entre usuários, em que a orientação da aresta reflete a direção da conexão. Em contraste, em grafos não direcionados, as arestas não possuem direção, representando relações bidirecionais, como a “amizade” em redes sociais, onde a conexão é mútua.


Formalmente, um grafo pode ser representado por:

$$G = (V, E, W) \quad (2.7)$$

em que $V = \{v_1, v_2, \dots, v_n\}$ é o conjunto de nós. $E = \{(v_i, v_j) \mid v_i, v_j \in V\}$ é o conjunto de arestas, representando as conexões entre os nós. E W é a matriz de adjacência, em que w_{ij} é o peso da aresta entre os nós v_i e v_j . Métodos comumente usados para determinar as entradas w_{ij} de W incluem o grafo baseado na correlação de Pearson, o método K-vizinhos mais próximos (KNN) e o grafo baseado em distância (SONG et al., 2018). Um exemplo de um grafo contendo seis vértices e as arestas conectando os nós do grafo, juntamente com a matriz de adjacência do grafo, é ilustrado na Figura 9.

Essas representações matemáticas formais permitem a análise e compreensão das propriedades estruturais e relacionais dos grafos, desempenhando um papel fundamental na modelagem e resolução de problemas complexos em diversos campos.

Figura 9 – Exemplo de um grafo direcionado (Esquerda) e a matriz de adjacência correspondente (Direita).



Fonte: Adaptado de [Song et al. \(2018\)](#)

Além disso, os grafos podem ser ponderados, ou seja, as arestas têm valores numéricos associados, refletindo medidas ou atributos das relações entre nós. Esses pesos podem representar distâncias em sistemas de transporte ou forças de conexão em redes de coautoria científica. Além dos tipos fundamentais de grafos, a teoria de grafos abrange categorias específicas, como grafos ponderados e bipartidos ([NEWMAN, 2010](#)). Grafos ponderados usam pesos numéricos para representar características das relações, enquanto grafos bipartidos dividem os nós em conjuntos distintos, conectando apenas nós de conjuntos diferentes. Esses tipos de grafos têm aplicações em análise de redes sociais, sistemas de recomendação e muito mais.

2.5.2 Filtragem Espectral

A análise de grafos vai além da descrição das relações entre nós, incorporando a compreensão das características desses nós e suas conexões. Métricas de centralidade e conectividade desempenham papéis cruciais nesse contexto ([SCARSELLI et al., 2009](#)). A centralidade de um nó mensura sua importância dentro do grafo, identificando os nós mais influentes ou cruciais para a estrutura. Métricas comuns incluem centralidade de grau e de intermediação. A conectividade está associada à robustez e acessibilidade da rede, identificando componentes conectados e pontos de conexão importantes ([BRUNA et al., 2014](#)). Essas ferramentas auxiliam na compreensão da propagação de informações e na identificação de estruturas vitais nos grafos.

A Filtragem Espectral de Grafos, também conhecida como convolução em grafos, é uma técnica fundamental para processar dados estruturados em forma de grafos. Ela estende os conceitos de convolução de sinais tradicionais para o domínio dos grafos, permitindo a extração de informações relevantes de maneira eficaz ([BRONSTEIN et al., 2017](#)). A filtragem espectral de grafos tem aplicações em várias áreas, incluindo reconhecimento de padrões, aprendizado de máquina e processamento de sinais em redes

complexas (DEFFERRARD; BRESSON; VANDERGHEYNST, 2016).

O conceito central por trás da filtragem espectral de grafos é a representação de sinais em vértices de grafos e a aplicação de operações de filtragem nesse domínio. A matriz de adjacência (W) e a matriz laplaciana (L) desempenham um papel fundamental nesse processo. A matriz de adjacência descreve as relações de conectividade entre os vértices do grafo, onde W_{ij} é igual a 1 se existe uma aresta entre os vértices i e j , e 0 caso contrário. A matriz laplaciana, por sua vez, é uma medida da conectividade dos vértices e é definida como:

$$L = D - W \quad (2.8)$$

em que D é uma matriz diagonal que contém os graus dos vértices do grafo.

A filtragem espectral de grafos é realizada por meio da transformada de Fourier em grafos, que é baseada nos autovalores e autovetores da matriz laplaciana. A ideia é mapear o sinal original do domínio do vértice para o domínio das frequências no espaço espectral (KIPF; WELLING, 2017). Isso permite a aplicação de operações de filtragem, como suavização ou realce de componentes específicos do sinal, de acordo com a distribuição das frequências no espaço espectral.

Em uma Deep Graph Convolutional Neural Network (DGCNN), a filtragem espectral de grafos é usada para processar os dados em cada camada da rede. A matriz de adjacência e a matriz laplaciana são usadas para calcular as transformações espectrais dos sinais nos vértices (SONG et al., 2018). Isso permite que as redes identifiquem padrões complexos e relevantes nos dados de grafos. As operações de filtragem em DGCNNs são realizadas por meio de convoluções de grafos, onde as matrizes de peso aprendidas ajustam como as informações são propagadas entre os vértices vizinhos.

Para um dado sinal espacial $x \in \mathbb{R}^N$, sua filtragem espectral de grafos (GFT) é expressa por

$$\hat{x} = U^T x \quad (2.9)$$

em que $\hat{x}$ denota o sinal transformado no domínio da frequência, U é uma matriz ortonormal que pode ser obtida através da decomposição em valor singular (SVD) do gráfico Matriz Laplaciana L :

$$L = U \Lambda U^T \quad (2.10)$$

em que as colunas de $U = [u_0, \dots, u_{n-1}]$ constituem a base de Fourier, e $\Lambda = \text{diag}([\lambda_0, \dots, \lambda_{N-1}])$ é uma matriz diagonal.

A partir da Equação 2.9, o inverso de GFT pode ser expresso da seguinte forma:

$$x = U U^T x = U \hat{x} \quad (2.11)$$

Então, a convolução de dois sinais x e y no gráfico, denotada por $x *_G y$, pode ser expressa como:

$$x *_G y = U((U^T x) \odot (U^T y)) \quad (2.12)$$

em que $\odot$ denota o produto de *Hadamard* elementar. Agora seja $g(\cdot)$ uma função de filtragem e então um sinal x filtrado por $g(L)$ pode ser expresso como:

$$y = g(L)x = g(U\Lambda U^T)x = Ug(\Lambda)U^T x \quad (2.13)$$

em que $g(\Lambda)$ é expresso como:

$$g(\Lambda) = \begin{bmatrix} g(\lambda_0) & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & g(\lambda_{N-1}) \end{bmatrix} \quad (2.14)$$

É notável que a operação de filtragem descrita na Equação 2.13 é equivalente à convolução do gráfico do sinal x com o vetor de $\mathbf{U}diag(g(\Lambda))$ devido à seguinte formulação:

$$\begin{aligned} y = g(L)x &= Ug(\Lambda)U^T x \\ &= U(diag(g(\Lambda)) \odot (U^T x)) \\ &= U((U^T(Udiag(g(\Lambda)))) \odot (U^T x)) \\ &= x *_G (Udiag(g(\Lambda))) \end{aligned} \quad (2.15)$$

Seja W^* denotando a matriz de adjacência ótima a ser aprendida. Então, a convolução gráfica do sinal x com o vetor de $U^*diag(g(\Lambda^*))$ definido pela filtragem espacial $g(L^*)$ pode ser expressa como:

$$y = g(L^*)x = U^*g(\Lambda^*)U^{*T} x, \quad (2.16)$$

em que o L^* pode ser calculado a partir de W^* com base na Equação 2.8, e $\Lambda^* = diag([\lambda_0^*, \dots, \lambda_{N-1}^*])$ é uma matriz diagonal.

Devido a complexidade de calcular diretamente a expressão de $g(\Lambda^*)$, o cálculo é simplificado usando os polinômios *Chebyshev* de ordem K (DEFFERRARD; BRESSON; VANDERGHEYNST, 2016) para substituir a expansão polinomial de $g(\Lambda^*)$, de modo que o cálculo se torne muito mais fácil e rápido. Especificamente, deixe λ_{max}^* denotar o maior elemento entre as entradas diagonais de Λ^* e $\tilde{\Lambda}^*$ denotar o Λ^* normalizado, ou seja, $\tilde{\Lambda}^* = 2\Lambda^*/\lambda_{max}^* - I_N$, de modo que os elementos diagonais de $\tilde{\Lambda}^*$ situa-se no intervalo de $[1; 1]$, onde I_N é a $N \times N$ matriz identidade. Sob a estrutura de polinômios de *Chebyshev* de ordem K , obtemos que $g(\Lambda^*)$ pode ser aproximado por

$$g(\Lambda^*) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\Lambda}^*) \quad (2.17)$$

em que θ_k é o coeficiente dos polinômios de *Chebyshev* e $T_k(x)$ pode ser calculado recursivamente de acordo com as seguintes expressões recursivas:

$$\begin{cases} T_0(x) = 1, T_1(x) = x, \\ T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x), \quad k \geq 2 \end{cases} \quad (2.18)$$

De acordo com a Equação 2.17, obtém-se que a operação de convolução do grafo definida na Equação 2.16 pode ser reescrita por

$$\begin{aligned} y &= U^* g(\Lambda^*) U^{*T} x \\ &= \sum_{k=0}^{K-1} U^* \begin{bmatrix} \theta_k T_k(\tilde{\lambda}_0^*) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \theta_k T_k(\tilde{\lambda}_{N-1}^*) \end{bmatrix} U^{*T} x \\ &= \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L}^*) x, \end{aligned} \quad (2.19)$$

em que $\tilde{L}^* = 2L^*/\lambda_{max}^* - I_N$

Em resumo, a Filtragem Espectral de Grafos é uma técnica poderosa para processar dados estruturados em forma de grafos. Ela utiliza as matrizes de adjacência e laplaciana para representar e transformar os sinais nos vértices do grafo. Nas *DGCNNs*, essa técnica é aplicada por meio de convoluções em grafos, permitindo que as redes aprendam representações complexas e relevantes para tarefas de classificação, regressão e outras análises em dados de grafos (SONG et al., 2022).

Para otimizar os parâmetros ideais da rede, adota-se o método de retropropagação (*Backpropagation* ou *BP*) para atualizar iterativamente os parâmetros da rede até que as soluções ideais sejam alcançadas. Para esse propósito, define-se uma função de perda baseada no custo de entropia cruzada, que é expressa da seguinte forma:

$$Loss = cross_entropy(1, 1^p) + \alpha \|\Theta\| \quad comma \quad (2.20)$$

Em que 1 e 1^p denotam o vetor de rótulo real dos dados de treinamento e o predito, respectivamente, Θ denota todos os parâmetros do modelo e α é o peso de regularização de trade-off. A função de entropia cruzada $cross_entropy(1, 1^p)$ visa medir a dissimilaridade entre os rótulos emocionais reais e os desejados, enquanto a regularização $\alpha \|\Theta\|$ visa evitar o ajuste excessivo do aprendizado dos parâmetros do modelo.

Ao aplicar o método BP para aprender dinamicamente a matriz de adjacência ótima W^* do modelo DGCNN, tem-se que calcular a derivada parcial da função de perda em relação a W^* , que é formulada como:

$$\frac{\partial Loss}{\partial W^*} = \begin{pmatrix} \frac{\partial Loss}{\partial w_{11}^*} & \cdots & \frac{\partial Loss}{\partial w_{1N}^*} \\ \vdots & \vdots & \vdots \\ \frac{\partial Loss}{\partial w_{N1}^*} & \cdots & \frac{\partial Loss}{\partial w_{NN}^*} \end{pmatrix} \quad (2.21)$$

em que w_{ij}^* denota a i -ésima linha e j -ésima coluna elemento de W^* . De acordo com a regra da cadeia, o cálculo de $\frac{\partial Loss}{\partial w_{ij}^*}$ pode ser expresso como

$$\frac{\partial Loss}{\partial w_{ij}^*} = \frac{\partial cross_entropy}{\partial \tilde{L}^*} \cdot \frac{\partial \tilde{L}^*}{\partial w_{ij}^*} + \alpha \frac{\partial \|\Theta\|}{\partial w_{ij}^*} \quad (2.22)$$

Depois de calcular a derivada parcial de $\frac{\partial Loss}{\partial W^*}$, pode-se utilizar a seguinte regra para atualizar a matriz de adjacência ótima W^* :

$$W^* = (1 - \rho)W^* + \rho \frac{\partial Loss}{\partial W^*} \quad (2.23)$$

em que ρ denota a taxa de aprendizado da rede. A incorporação da teoria de grafos nas *CNNs* permite a captura de informações contextuais e estruturais dos sinais de EEG. Isso é especialmente útil em tarefas como classificação de estados emocionais, onde as relações entre os eletrodos vizinhos podem conter informações fundamentais (BRUNA et al., 2014). A matriz laplaciana também desempenha um papel fundamental na definição de operadores de convolução no domínio do grafo, permitindo a aplicação de filtros para identificar padrões e características específicas nos sinais cerebrais (DEFFERRARD; BRESSON; VANDERGHEYNST, 2016).

Em resumo, a relação entre a teoria de grafos e redes neurais convolucionais reside na representação das relações entre eletrodos de entrada do EEG por meio de um grafo. Matrizes de adjacência e laplacianas são utilizadas para capturar informações estruturais e contextuais, permitindo que as *CNNs* explorem as conexões entre eletrodos e realizem tarefas de classificação de sinais de EEG de maneira mais eficaz e significativa (SONG et al., 2018).

As redes neurais convolucionais são altamente eficazes na extração de padrões em dados, como imagens, através da aplicação de operações de convolução. No entanto, aplicar *CNNs* diretamente aos sinais de EEG pode não capturar totalmente as complexas interações entre os eletrodos (HENAFF; BRUNA; LECUN, 2015). É neste ponto que a teoria de grafos demonstra o potencial inovador, permitindo a modelagem das relações e conexões entre eletrodos como um grafo estruturado (SONG et al., 2022). Essa abordagem oferece um meio de incorporar informações contextuais e topológicas, melhorando a representação dos sinais de EEG.

A utilização de matrizes de adjacência e laplacianas, derivadas da configuração espacial dos eletrodos, pode ser fundamental para a representação eficaz das relações inter-eletrodos. Essas matrizes capturam informações sobre a proximidade e a conectividade entre os eletrodos, permitindo que a *CNN* incorpore essas informações estruturais em suas operações de convolução (KIPF; WELLING, 2017). Isso resulta em uma abordagem mais rica e contextualmente informada para a classificação de sinais de EEG, melhorando a

capacidade de distinguir padrões complexos e relevantes para o reconhecimento de emoções ou outras tarefas relacionadas.

Dessa forma, a fusão da teoria de grafos com as redes neurais convolucionais oferece uma abordagem promissora para aprimorar a análise de sinais de EEG e a classificação de emoções. Essa abordagem híbrida possibilita a exploração das conexões entre eletrodos, agregando informações estruturais e contextuais, ao mesmo tempo em que se beneficia da capacidade de extração de características das *CNNs* (ZHOU et al., 2023).

2.6 Estado da Arte

O EEG encontra amplo uso em diversas aplicações. Clinicamente, monitora convulsões em pacientes epiléticos e ajuda a diagnosticar distúrbios neurológicos (LIN et al., 2010). Em pesquisas, mapeia atividades motoras e avalia funções cognitivas (ZHANG et al., 2019). No entanto, o seu papel se destaca de maneira notável no âmbito do reconhecimento de emoções. Identificando padrões cerebrais, o EEG traduz nuances emocionais como felicidade, tristeza e estresse (LIU et al., 2022; ZHENG; ZHU; LU, 2019). Isso tem aplicações significativas: na psicologia, analisa respostas emocionais (HERNANDEZ et al., 2014); em interfaces homem-máquina, melhora interações adaptativas (PICARD et al., 2004); em jogos e entretenimento, cria experiências envolventes e realistas (YANG et al., 2019). O EEG, assim, traça uma ponte entre a atividade elétrica cerebral e a complexidade das emoções humanas, impulsionando inovações em áreas diversas.

A trajetória da aplicação do sinal de EEG ao reconhecimento de emoções é permeada por avanços significativos, que refletem tanto o desenvolvimento das tecnologias de aquisição de EEG quanto a evolução das abordagens de processamento de sinais. No pioneiro trabalho de (FINK, 1969) a relação entre EEG e psicofarmacologia humana foi explorada. O autor investigou as modificações nas ondas cerebrais induzidas por substâncias farmacológicas e delineou as bases iniciais para compreender como o EEG poderia ser sensível a estados emocionais e fisiológicos.

Posteriormente, Musha et al. (1997) apresentaram um marco na exploração das associações entre EEG e emoções humanas. O estudo propôs a extração de características dos sinais EEG relacionadas a diferentes estados emocionais. Ao considerar uma variedade de emoções, os autores exploraram a relação entre padrões de ondas cerebrais e estados emocionais específicos, estabelecendo assim uma base para a identificação objetiva de emoções através do EEG. Este trabalho precursor pavimentou o caminho para uma compreensão mais profunda das respostas cerebrais às emoções, estimulando o desenvolvimento de algoritmos e modelos mais sofisticados para o reconhecimento de emoções baseado em EEG.

No contexto atual, a convergência entre neurociência e aprendizado de máquina

abriu caminho para abordagens mais robustas de reconhecimento de emoções a partir de sinais EEG, como o emprego de algoritmos como *SVM* (LIN et al., 2010), *LR* e *KNN* (ZHENG; LU, 2015). Através de características extraídas dos sinais EEG, esses algoritmos buscam mapear padrões neurais para estados emocionais específicos, proporcionando uma compreensão mais precisa das respostas cerebrais associadas a diferentes emoções. A interseção entre as técnicas tradicionais de processamento de sinais e o poder das abordagens de aprendizado de máquina proporciona uma abordagem abrangente e eficaz para a classificação de emoções no contexto do EEG (JENKE; PEER; BUSS, 2014).

Lin et al. (2010) extraíram a densidade do espectro de potência (*PSD*), a potência de assimetria diferencial (*DASM*) e a potência de assimetria racional (*RASM*) para identificar as respostas emocionais dos indivíduos ao ouvirem diferentes gêneros musicais, utilizando sinais EEG para capturar variações na atividade cerebral. Os resultados mostraram que os atributos relacionados a assimetria (*DASM*, *RASM*) proporcionaram o melhor desempenho de classificação, com diferença significativa nas faixas de frequência δ , θ e α .

Wang, Nie e Lu (2014) exploram uma variedade de características extraídas dos sinais EEG (densidade espectral de potência (*PSD*), recursos wavelet e recursos dinâmicos não lineares) e avaliam diferentes algoritmos de classificação, incluindo *SVM* e *Random Forests*, para determinar a abordagem mais eficaz. O trabalho destaca a importância da seleção de características relevantes e do uso de algoritmos de classificação adequados para obter resultados precisos na classificação de estados emocionais. Zheng e Lu (2015) destacam a aplicação de metodologias de aprendizado profundo para o reconhecimento de emoções a partir de dados multicanais de EEG. Por meio da análise das distribuições de peso aprendidas pela *DBN*, foi possível otimizar a disposição de eletrodos, resultando em uma abordagem mais eficaz e viável. Os resultados experimentais revelaram que as características de entropia diferencial (*DE*) extraídas das cinco bandas de frequência (δ , θ , α , β e γ) oferecem informações precisas e estáveis para o reconhecimento de emoções, possibilitando a identificação de padrões neurais específicos associados a diferentes estados emocionais.

Zheng, Zhu e Lu (2019) abordam a estabilidade temporal dos padrões do eletroencefalograma ao longo do tempo, algo que ainda não havia sido completamente explorado até então. A pesquisa avalia métodos de extração, seleção e suavização de características, bem como classificação de padrões, utilizando o conjunto de dados *DEAP* e o novo conjunto de dados *SEED*, desenvolvido especificamente para esse estudo. O algoritmo *Discriminative Graph regularized Extreme Learning Machine (GELM)* com características de entropia diferencial alcança as melhores precisões médias nos conjuntos *DEAP* e *SEED*, comparado aos resultados dos classificadores *KNN*, *Logistic Regression* e *SVM*. Os resultados mostram que os padrões estáveis exibem consistência entre sessões, revelando características específicas para emoções positivas, neutras e negativas em diferentes regiões cerebrais e

bandas de frequência.

Gan et al. (2019) investigam a detecção de emoções em diferentes contextos culturais. O estudo explora o uso de técnicas de aprendizado profundo para identificar estados emocionais a partir de sinais de voz e expressões faciais. Além disso, o estudo analisa a aplicação de Entropia Diferencial (*DE*) para melhorar a precisão na extração de características dos sinais. Ao focar nas variações culturais, o trabalho fornece informações sobre como as emoções são interpretadas em diferentes culturas, considerando também as particularidades das bandas de frequência. O estudo realça a capacidade das redes neurais profundas em analisar múltiplos modais para aprimorar a identificação de emoções transculturais.

A revisão histórica da aplicação do sinal de EEG ao reconhecimento de emoções traça um percurso de progresso e descoberta, que, ao longo dos anos, tem sido impulsionada pelo avanço das tecnologias de aquisição e processamento de sinais (SCHOMER; SILVA, 2017), bem como pela ascensão do aprendizado de máquina e aprendizado de máquina e aprendizado profundo (LECUN; BENGIO; HINTON, 2015). Desde as primeiras investigações sobre a influência de substâncias farmacológicas nos padrões de EEG, como abordado por Fink (1969), e a extração de características distintivas associadas a diferentes estados emocionais, exemplificado pelo trabalho de Musha et al. (1997), a pesquisa nessa área culminou em abordagens modernas que aliam a expertise em neurociência com as capacidades de análise de dados proporcionadas pela aprendizagem de máquina e *deep learning* (ZHONG; WANG; MIAO, 2022). Essa trajetória histórica demonstra o contínuo interesse em mapear a relação entre o cérebro e as emoções humanas, impulsionando aplicações que abrangem desde a neurociência básica até a saúde mental e interfaces cérebro-computador (ZHOU et al., 2023; PARK et al., 2023), aproveitando as capacidades das técnicas modernas de aprendizado de máquina para alcançar resultados mais precisos e interpretáveis. Nos últimos anos, os métodos de aprendizado profundo tornaram-se predominantes em muitas áreas, incluindo no reconhecimento de emoções utilizando EEG (ZHANG et al., 2022)

A aplicação de *CNNs* em sinais de EEG oferece vantagens significativas em comparação com as redes neurais profundas convencionais (FAUST et al., 2018). As *CNNs* são especialmente adequadas para a análise de dados multidimensionais, como os sinais EEG, devido à sua capacidade intrínseca de capturar padrões espaciais e temporais complexos (SCHIRRMEISTER et al., 2017). Ao empregar camadas convolucionais e de pooling, as *CNNs* podem aprender a hierarquia de características relevantes nos sinais EEG, resultando em uma representação mais eficaz e robusta (BRUNA et al., 2014).

Além disso, as *CNNs* podem aproveitar a estrutura inerente dos sinais EEG, como a topografia em duas dimensões das atividades cerebrais em diferentes canais e frequências (SCHIRRMEISTER et al., 2017). Isso se traduz em uma capacidade aprimorada de

identificar padrões específicos relacionados a estados emocionais ou tarefas cognitivas. A abordagem das *CNNs* é particularmente valiosa quando se trata de variações temporais e espaciais complexas presentes nos sinais EEG.

Zhang et al. (2018) e Zhang et al. (2019) introduziram abordagens que buscavam incorporar relações espaciais em sinais de EEG para o reconhecimento de emoções, utilizando *CNN* e Redes Neurais Recorrentes (*RNN*), respectivamente. Entretanto, essas metodologias apresentam limitações relevantes (HENAFF; BRUNA; LECUN, 2015). A abordagem baseada em *CNNs* exige a representação dos canais de EEG no couro cabeludo de forma bidimensional, o que pode resultar em perda de informação durante o processo de achatamento, uma vez que a disposição real dos canais ocorre em um espaço tridimensional (ALARCAO; FONSECA, 2019b). Recentemente, Li et al. (2021) propuseram o uso de *RNNs* para aprender as relações topológicas espaciais entre os canais por meio da varredura de eletrodos em direções vertical e horizontal. No entanto, suas abordagens não exploram completamente a estrutura topológica dos canais de EEG. Por exemplo, dois canais topologicamente próximos podem estar distantes um do outro em sua sequência de varredura. E, uma vez que a sequência de varredura não reflete completamente as verdadeiras conexões funcionais entre os eletrodos, o modelo não captura efetivamente as complexas relações espaciais presentes nos sinais de EEG,

As Redes Neurais Convolucionais em Grafos surgem como uma promissora solução para superar as limitações das abordagens tradicionais, como *CNNs* e *RNNs*, na representação de mapas topológicos de sinais de EEG (SONG et al., 2018). Ao considerar a estrutura de rede dos eletrodos como um grafo, as GCNNs podem efetivamente modelar as complexas relações espaciais entre os canais de maneira mais precisa e abrangente (AHMEDT-ARISTIZABAL et al., 2021). Essa abordagem permite capturar as conexões funcionais entre os eletrodos em um contexto tridimensional, levando em consideração as diferentes distâncias e padrões de ativação. Dessa forma, as GCNNs podem explorar a topologia real dos eletrodos de EEG, superando as limitações de outras técnicas que não conseguem capturar plenamente as verdadeiras relações entre canais (SONG et al., 2022). Isso resulta em uma representação mais detalhada e informativa dos sinais de EEG, contribuindo para uma melhor compreensão das complexas dinâmicas neurais associadas a diferentes estados emocionais e otimizando a precisão do reconhecimento de emoções. (ZHOU et al., 2023; BRONSTEIN et al., 2017)

Song et al. (2018) propuseram um modelo baseado em uma Rede Neural Convolutiva de Gráfico Dinâmico (DGCNN) para aprender automaticamente os pesos ideais nas conexões do grafo. Cada nó no grafo corresponde a um canal de EEG, com representações escalares ou vetoriais. Isso permite tratar os dados EEG como sinais em um grafo irregular, com conexões definidas pelas relações espaciais entre canais. O objetivo era determinar a força das conexões entre os nós como características funcionais e a abordagem desenvolvida

mostrou-se eficaz no reconhecimento de emoções. Wang et al. (2018) introduziu um amplo sistema de aprendizado (*Broad Learning System*) e propôs um modelo que combina uma rede neural convolucional de gráfico dinâmico e um amplo sistema de aprendizado. Através de análises em entropia diferencial, a dinâmica dos gráficos de redes neurais convolucionais obteve resultados considerados o estado-da-arte até então nos conjuntos de dados SEED.

Yongqiang (2021) propôs o modelo *ECLGCNN*, uma fusão inovadora entre *LSTM* e *GCNN* para melhorar o reconhecimento de emoções. Nesse método, a *DE* é extraída de segmentos para formar um cubo de recursos. Múltiplas *GCNNs* extraem informações do domínio gráfico de cada cubo, enquanto células *LSTM* memorizam mudanças nas relações entre pares de canais EEG e extraem informações temporais. Essa abordagem de fusão mostra a tendência de utilizar estratégias combinadas para melhorar a precisão e a eficácia no reconhecimento de emoções a partir de sinais de EEG. Zhong, Wang e Miao (2022) propôs uma rede neural de gráfico regularizado para reconhecimento de emoções baseado em EEG. O modelo é inspirado nas teorias da neurociência sobre a organização do cérebro humano e captura as relações entre canais locais e globais em sinais de EEG. Em comparação com estudos como Zhang et al. (2019) e Li et al. (2021), que se concentraram exclusivamente em Redes Neurais Recorrentes, a adoção de grafos demonstra um passo adiante ao incorporar efetivamente as relações espaciais complexas presentes nos dados de EEG.

O trabalho recente de Zhang et al. (2022) introduz o conceito de *Graph Convolutional Broad Network (GCB-net)* para melhorar a classificação de sinais. A *GCB-net* emprega convolução regular para explorar informações profundas, abstraindo recursos de alto nível das representações de grafos. Além disso, incorpora um *Broad Learning System*, atuando como camada adaptável, para selecionar recursos apropriados. Essa abordagem busca capturar informações de alta e baixa frequência dos sinais EEG, permitindo avanços na classificação por meio de uma rede ampla. Zhang et al. (2023) aprimorou o modelo *DGCNN* ao introduzir uma restrição de dispersão na representação gráfica G e propor uma solução para minimização com essa restrição, denominada *DGCNN* esparso. Esse método demonstrou desempenho superior à sua versão não esparsa, destacando a eficácia da introdução de dispersão nos padrões de conectividade gráfica irregular de sinais de EEG para classificação de emoções. A abordagem *SparseDGCNN* combina a arquitetura *DGCNN* com técnicas de esparsidade, permitindo a representação de padrões temporais e espaciais nos sinais de EEG, enquanto reduz a complexidade computacional.

Classificação de sinais de encefalografia por meio de redes convolucionais em grafos é caracterizado pela diversidade de abordagens que visam capturar a complexidade dos dados EEG e a dinâmica das interações neurais (ZHOU et al., 2023). Através desses estudos pioneiros, o campo tem avançado na direção de uma melhor compreensão das relações entre padrões cerebrais e estados emocionais, com implicações que abrangem

desde a neurociência básica até aplicações clínicas e de bem-estar (ROY et al., 2019). A crescente adoção de *GCNNs* em combinação com diversas técnicas, como *LSTM*, *BLS* e a introdução de esparsidade, reflete uma tendência promissora de aprimorar a representação e compreensão dos padrões emocionais nos sinais de EEG. O uso dessas abordagens tem o potencial de não apenas aprofundar nossa compreensão das interações complexas entre canais de EEG, mas também proporcionar ganhos significativos na precisão de classificação de emoções (RAJWAL; AGGARWAL, 2023). A convergência de diversos estudos enfatiza a importância de explorar a arquitetura de redes neurais em grafo para aprimorar a análise de sinais EEG, oferecendo uma perspectiva empolgante para avanços futuros na interface entre neurociência, processamento de sinais e aprendizado de máquina.

Neste capítulo, foram apresentados os fundamentos teóricos necessários para a compreensão da pesquisa. Inicia-se com uma introdução aos sinais de eletroencefalograma, destacando o posicionamento de eletrodos e o sistema internacional 10-20, fornecendo uma base sólida para a aquisição de dados EEG. Em seguida, explora-se o campo do reconhecimento de emoções, discutindo seu significado e relevância em várias aplicações, incluindo a saúde mental e as interfaces cérebro-computador. Além disso, investigam-se modelos de aprendizado de máquina tradicionais, como regressão logística, *KNN* e *SVM*, que servirão como base de comparação para os modelos de aprendizado profundo. No capítulo seguinte, é detalhada a metodologia que guiará a pesquisa. Inicia-se descrevendo o conjunto de dados de EEG utilizado, o SEED, e explicando sua relevância para o estudo. Em seguida, aborda-se o pré-processamento de EEG, incluindo a extração de atributos e a técnica de suavização de características, que visam aprimorar a qualidade dos dados. No âmbito dos experimentos, são apresentados os modelos de aprendizado de máquina e aprendizado profundo que serão testados e comparados na pesquisa. Por fim, delineia-se a abordagem para analisar os resultados, que será fundamental para avaliar o desempenho dos modelos e contribuir para a evolução da detecção de emoções a partir de sinais de EEG.

Os principais artigos selecionados para esta pesquisa são apresentados a Tabela 1, com informações de ano, autor, título do artigo, modelos utilizados, conjuntos de dados explorados e características analisadas. A tabela serve como um instrumento para compreender as tendências, métodos e abordagens predominantes na literatura recente, fornecendo uma base sólida para o desenvolvimento e a justificção da presente pesquisa. Cada artigo revisado contribui com uma perspectiva única para a compreensão do reconhecimento de emoções a partir de sinais de EEG, e a síntese dessas contribuições prepara o terreno para os experimentos e análises detalhadas que serão apresentados nos capítulos subsequentes desta dissertação.

Tabela 1 – Principais artigos utilizados para identificar o estado da Arte (SOTA.)

Ano	Autor(es)	Artigo	Modelo	DATASET	Features
2015	ZHENG, W.-L et al.	Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks	KNN, LR, SVM e DBN	pesquisa que originou o SEED	DE, PSD, DASM, RASM, DCAU
2018	SONG, T. et al.	EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks.	DGCNN	SEED, DREAMER	DE, PSD, DASM, RASM, DCAU - SEED PSD - DREAMER
2018	WANG, X.-h. et al.	EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks and Broad Learning System.	DGCNN + BLS	SEED	DE
2019	ZHANG, T. et al.	Spatial-Temporal Recurrent Neural Network for Emotion Recognition	spatial-temporal RNN	SEED	DE
2019	ZHENG, W.-L et al.	Identifying Stable Patterns over Time for Emotion Recognition from EEG	KNN, LR, SVM, GELM	SEED	DE, PSD, DASM, RASM, DCAU
2021	LI, Y. et al	A Novel Bi-Hemispheric Discrepancy Model for EEG Emotion Recognition	Bi-Hemispheric Discrepancy Model - 4 RNNs in 2 spatial orientations	SEED, SEED IV, MPED	DE - SEED e SEED IV STFT - MPED
2021	YONGQIANG, Y.	EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM	LSTM + GCNN	DEAP	DE
2022	ZHANG, T. et al.	GCB-Net: Graph Convolutional Broad Network and Its Application in Emotion Recognition	GCB-net	SEED, DREAMER	DE, PSD, DASM, RASM, DCAU - SEED PSD - DREAMER
2022	ZHONG, P.	EEG-Based Emotion Recognition Using Regularized Graph Neural Networks	RGCNN	SEED, SEED IV	DE
2023	ZHANG, G. et al.	SparseDGCNN: Recognizing Emotion From Multichannel EEG Signals	sparse DGCNN	SEED, DEAP, DREAMER e CMEED	DE, PSD, DASM, RASM e DCAU - SEED e DEAP PSD - DREAMER, CMEED

Fonte: Elaborada pelo autor.

3 Metodologia

O presente capítulo é centrado na metodologia e delineia o processo estratégico adotado para realizar a pesquisa proposta. Inicia-se com uma descrição detalhada do conjunto de dados de eletroencefalografia, focalizando especialmente o conjunto *SJTU Emotion EEG Dataset (SEED)*. Em seguida, explora-se o pré-processamento do EEG, destacando as etapas cruciais de extração de atributos e suavização de características, concebidas para otimizar a qualidade e relevância dos dados. Os experimentos conduzidos, abordados na seção 3.3, envolvem a implementação de modelos de Aprendizado de Máquina e Aprendizado Profundo, proporcionando uma visão completa das estratégias adotadas. Na análise de resultados são apresentadas informações derivadas dos experimentos, fundamentando as conclusões e discussões a serem apresentadas nos capítulos subsequentes.

3.1 Conjunto de Dados de eletroencefalografia

A escolha do *dataset* de EEG desempenha um papel crucial na condução de pesquisas e estudos relacionados ao reconhecimento de emoções. No entanto, a obtenção de conjuntos de dados adequados de EEG pode ser uma tarefa desafiadora devido a várias dificuldades inerentes. Primeiramente, a disponibilidade de *datasets* de EEG específicos para o reconhecimento de emoções é relativamente limitada em comparação com outras áreas de pesquisa (ROY et al., 2019). Isso ocorre devido à natureza sensível e restrita dos dados de EEG, que são coletados diretamente do cérebro dos indivíduos.

Além disso, esses conjuntos de dados geralmente têm restrições em termos de tamanho, segurança e custos. Dados de EEG são volumosos em termos de quantidade de amostras e dimensões, o que pode limitar a acessibilidade a conjuntos de dados maiores (ABHANG; GAWALI; MEHROTRA, 2016). Além disso, a segurança e a privacidade dos participantes envolvidos na coleta de dados de EEG são preocupações fundamentais, o que muitas vezes exige protocolos rigorosos para a obtenção, armazenamento e compartilhamento dos dados (LI et al., 2022). Isso pode tornar ainda mais desafiador o acesso a conjuntos de dados de EEG disponíveis publicamente. Além disso, a preparação e curadoria de dados de EEG podem ser custosas em termos de recursos humanos e financeiros, uma vez que a coleta, processamento e rotulação de dados de EEG exigem especialização técnica e equipamentos adequados.

Apesar dos desafios mencionados na obtenção de dados, existem alguns conjuntos de dados disponíveis que têm sido fundamentais no avanço dos estudos no reconhecimento de padrões em EEG (LOTTE et al., 2018). Esses *datasets* oferecem uma variedade de sinais cerebrais registrados durante diferentes tipos de estímulos emocionais e atividades,

possibilitando a análise e experimentação de algoritmos de reconhecimento de emoções.

Entre os conjuntos de dados notáveis estão:

- *SEED (SJTU Emotion EEG Dataset)* - (ZHENG; ZHU; LU, 2019)
- *DEAP (Database for Emotion Analysis using Physiological Signals) Dataset* - (KOELSTRA et al., 2012)
- *DREAMER (Database for Emotion Analysis using Physiological Signals) Dataset* - (KATSIGIANNIS; RAMZAN, 2018)
- *TUH EEG (Temple University Hospital EEG) Dataset* - (LEE et al., 2022)
- *MPI LEMON (Max Planck Institute for Biological Cybernetics Linear EEG data) Dataset* - (BABAYAN et al., 2019)
- *MAHNOB HCI (Multimedia Analysis and Human-Computer Interaction)* - (SOLEYMANI et al., 2012)

Esses *datasets* variam em tamanho, formato, qualidade e propósito, mas todos oferecem uma riqueza de informações valiosas para a análise de padrões de EEG associados a diferentes emoções.

O *SEED*, por exemplo, contém dados de EEG de múltiplos sujeitos enquanto experimentam diferentes estímulos emocionais, tornando-o um recurso valioso para treinar e testar algoritmos de reconhecimento de emoções (ZHENG; ZHU; LU, 2019). O *DEAP* e o *DREAMER*, por sua vez, apresentam sinais fisiológicos multimodais, incluindo EEG, que são coletados durante a exibição de estímulos audiovisuais projetados para evocar diferentes emoções (KOELSTRA et al., 2012; KATSIGIANNIS; RAMZAN, 2018). O *TUH EEG Dataset* e o *MPI LEMON Dataset* oferecem dados clínicos de EEG coletados de pacientes em ambientes hospitalares, permitindo a exploração de emoções em contextos médicos (LEE et al., 2022). O *MAHNOB HCI Dataset* foi projetado para capturar uma ampla gama de emoções humanas, coletando dados de diversos sujeitos expostos a estímulos emocionais variados, como imagens, vídeos e músicas. Ele contém registros detalhados dos sinais de EEG de cada sujeito, permitindo a análise das variações nos padrões cerebrais durante diferentes estados emocionais (SOLEYMANI et al., 2012).

Entre os vários conjuntos de dados disponíveis para investigação no campo do reconhecimento de emoções, o *SEED* se destaca como uma opção notável devido às suas particularidades distintas e vantagens peculiares. O *SEED* oferece um ambiente controlado para a aquisição de dados de EEG relacionados às emoções, contemplando um leque diversificado e bem delineado de estímulos emocionais, o que resulta em uma gama abrangente de respostas emocionais capturadas. Isso, por sua vez, enriquece a variedade

e representatividade intrínsecas do *dataset*. Além disso, o *dataset* apresenta sinais EEG de alta qualidade, com um rigoroso controle de interferências e ruídos, o que assegura a confiabilidade dos resultados obtidos. Vale ressaltar, também, a resolução espacial precisa dos eletrodos utilizados no *SEED*, o que viabiliza uma identificação acurada das atividades cerebrais em regiões específicas. Essa característica desempenha um papel crucial na compreensão das correlações entre padrões cerebrais e estados emocionais, fomentando análises mais minuciosas e correlações mais profundos. Portanto, a seleção do *SEED* como base para esta dissertação se fundamenta nessas vantagens, que permitem a exploração aprofundada das complexas interações entre o cérebro e as emoções por meio de técnicas de aprendizado de máquina.

3.1.1 *SEED*

O *SEED* é um conjunto de dados que visa capturar as respostas cerebrais associadas a diferentes estados emocionais. Foram coletados dados EEG de 15 sujeitos (7 homens e 8 mulheres, média de idade = 23,27). Esses dados EEG foram obtidos por meio de estímulos auditivos e visuais na forma de trechos de filmes emocionais chineses. Enquanto os participantes assistiam a 15 trechos de filmes de 4 minutos com três tipos de emoção (positiva, negativa e neutra), seus dados EEG foram registrados por um sistema *ESI NeuroScan* com 62 canais a uma taxa de amostragem de 1.000 Hz. O protocolo utilizado em cada indivíduo é apresentado na Figura 10. Os dados EEG foram posteriormente subamostrados para 200 Hz e verificados manualmente para remover artefatos de *EOG* e *EMG* (CORREA et al., 2007). Para cada sujeito, os registros EEG foram capturados ao longo de três sessões cronologicamente desconexas, e cada sessão repetiu o mesmo experimento. Além disso, o *SEED* não contém informações de excitação, portanto, reconhecemos apenas emoções positivas, neutras e negativas no *SEED*. Após o pré-processamento com um filtro passa-banda (entre 0,3 e 50 Hz), cinco características (*DE*, *PSD*, *DASM*, *RASM* e *DCAU*) foram extraídas com uma janela de 1 segundo em cinco bandas, banda δ (0,5-4 Hz), banda θ (4-7 Hz), banda α (8-13 Hz), banda β (14-30 Hz) e banda γ (> 30 Hz). As principais informações do *dataset* estão resumidas na Tabela 2.

3.2 Pré-processamento de EEG

3.2.1 Extração de Atributos


A análise de sinais de EEG é uma tarefa complexa devido à natureza multidimensional e dinâmica desses sinais (JENKE; PEER; BUSS, 2014). Portanto, a extração adequada de atributos é crucial para destacar informações importantes que possam ser utilizadas nos processos subsequentes de classificação e reconhecimento de emoções (WANG; WANG, 2021).

Tabela 2 – Resumo das principais características do dataset escolhido - SEED.

Informações Gerais	
Número total de amostras	15 indivíduos x 3 sessões
Distribuição por gênero	Homens: 7, Mulheres: 8
Idade média dos participantes	23,27 anos
Características dos Sinais EEG	
Número de eletrodos	62
Frequência de amostragem	1000 Hz ->200 Hz
Duração média dos segmentos	~3.5 minutos (226 segundos)
Classes de Emoções	
Classes representadas	Positivo, Negativo e Neutro
Distribuição por classe	Positivo: 5, Negativo: 5 e Neutro: 5
Características Extraídas	
Entropia Diferencial (DE)	Mede a complexidade e a irregularidade nos padrões temporais dos sinais EEG.
Densidade Espectral de Potência (PSD)	Distribuição de energia do sinal EEG em diferentes bandas de frequência.
Assimetria Diferencial (DASM)	Diferença entre as atividades elétricas dos hemisférios cerebral direito e esquerdo.
Assimetria Racional (RASM)	Razão da diferença entre as atividades elétricas dos hemisférios cerebrais.
Assimetria (ASM)	Avalia a dissimetria global na atividade elétrica entre hemisférios cerebrais.
Causalidade Diferencial (DCAU)	Mede a direcionalidade das interações causais entre diferentes regiões do cérebro.

Fonte: Elaborada pelo autor.

Figura 10 – Protocolo utilizado para aquisição dos dados de Eletroencefalografia do SEED.



Fonte: Adaptado de [Zheng, Zhu e Lu \(2019\)](#).

A extração de características é conduzida em três principais dimensões: o domínio do tempo, o domínio da frequência e a combinação dos domínios. No domínio do tempo, diversos atributos estatísticos são extraídos diretamente dos sinais EEG. Entre esses atributos, destacam-se a média, desvio padrão, curtose e assimetria, que fornecem informações sobre a tendência central, dispersão e forma dos sinais ([SANEI; CHAMBERS, 2013](#)). Além disso, características temporais, como a taxa de cruzamento por zero e a energia do sinal, também são consideradas para compreender aspectos da variação ao longo do tempo.

Já no domínio da frequência, técnicas como a Transformada de Fourier são aplicadas para mapear os sinais EEG do domínio do tempo para o domínio da frequência. Isso permite a análise das componentes espectrais presentes nos sinais, revelando padrões de atividade em diferentes faixas de frequência ([ABHANG; GAWALI; MEHROTRA, 2016](#)).

Características espectrais, como *PSD* e a relação entre as faixas de frequência, são extraídas para capturar a distribuição de energia ao longo do espectro de frequência (SHU et al., 2018).

A combinação de atributos extraídos tanto no domínio do tempo quanto no domínio da frequência fornece uma representação abrangente dos sinais EEG, permitindo a identificação de padrões discriminativos relacionados às emoções (YONGQIANG, 2021). Essa etapa de extração de características é crucial para alimentar os algoritmos de classificação posteriormente empregados, possibilitando o desenvolvimento de modelos robustos de reconhecimento emocional a partir dos sinais EEG.

No domínio do tempo, as vantagens incluem a representação direta dos sinais EEG em sua forma bruta, permitindo uma visualização direta das variações temporais (SANEI; CHAMBERS, 2013). Características como amplitudes e durações de picos podem ser observadas, preservando informações importantes sobre a dinâmica temporal. No entanto, há desvantagens como a susceptibilidade a ruídos, uma vez que os sinais EEG podem ser afetados por diversos tipos de interferências. Além disso, a análise de padrões complexos em sinais temporais pode ser desafiadora, especialmente quando várias atividades cerebrais estão sobrepostas (ALARCAO; FONSECA, 2019b).

No domínio da frequência, a principal vantagem é a caracterização espectral, que possibilita a identificação de padrões de atividade em diferentes faixas de frequência, como δ , θ , α , β e γ , fornecendo informações sobre atividades cerebrais específicas (JENKE; PEER; BUSS, 2014). A detecção de componentes espectrais, como picos de frequência, também é possível. No entanto, há uma desvantagem associada à perda de informação temporal, uma vez que a transformação de Fourier não preserva a sequência temporal dos eventos. Além disso, a sobreposição de diferentes atividades cerebrais na mesma faixa de frequência pode dificultar a distinção entre essas atividades (SANEI; CHAMBERS, 2013).

O domínio do tempo-frequência combina as vantagens dos domínios anteriores, permitindo a visualização de como as características espectrais evoluem ao longo do tempo (SHU et al., 2018). Ele é adequado para detectar mudanças rápidas nas características espectrais, como picos de frequência transitórios, indicando mudanças dinâmicas no sinal. Entretanto, apresenta limitações, como resolução limitada devido ao princípio de incerteza de Heisenberg, que impõe um compromisso entre resolução temporal e de frequência. Além disso, a transformação do sinal para o domínio tempo-frequência requer maior complexidade computacional (JENKE; PEER; BUSS, 2014).

Em suma, a escolha do domínio de análise de EEG depende dos objetivos e contexto da análise. O domínio do tempo é adequado para estudar eventos rápidos e complexos, o domínio da frequência é útil para caracterizar diferentes atividades cerebrais, enquanto o domínio do tempo-frequência combina as vantagens dos anteriores, mas requer considerações de resolução e complexidade computacional (BOTA et al., 2019).

O *SEED* disponibiliza algumas características intrínsecas aos sinais de eletroencefalografia EEG, que podem ser exploradas para a análise de padrões relevantes na identificação das emoções dos participantes. Essas características incluem:

- Entropia Diferencial (*DE*)
- Densidade Espectral de Potência (*PSD*)
- Assimetria Diferencial (*DASM*)
- Assimetria Racional (*RASM*)
- Assimetria (*ASM*)
- Causalidade Diferencial (*DCAU*)

A densidade espectral de potência descreve a distribuição de potência nas diferentes faixas de frequência do sinal EEG, fornecendo informações valiosas sobre a atividade cerebral em diferentes estados emocionais. A entropia diferencial captura a complexidade do sinal EEG, sendo uma medida da incerteza associada às diferentes amostras de dados, o que é crucial para a análise de emoções.

O *SEED* também disponibiliza características que revelam informações sobre a assimetria entre os hemisférios cerebrais. A assimetria diferencial fornece uma medida da diferença nas atividades elétricas entre os hemisférios esquerdo e direito, enquanto a assimetria racional e a assimetria medem os desequilíbrios nas atividades cerebrais entre pares de eletrodos específicos. Essas características são de grande importância, pois muitos estudos têm relacionado assimetrias hemisféricas a diferentes estados emocionais ([DU et al., 2022](#); [AHMED et al., 2022](#); [LI et al., 2021](#)).

Adicionalmente, o *dataset SEED* inclui a causalidade diferencial (*DCAU*), que explora as relações causais entre diferentes regiões cerebrais. Essa característica oferece informações sobre como diferentes áreas do cérebro interagem e influenciam umas às outras, o que é fundamental para entender as bases neurais das emoções.

Os atributos *PSD*, *DE*, *DASM*, *RASM*, *ASM* e *DCAU* possuem as respectivas dimensões: 310 (62 eletrodos $\times$ 5 faixas), 310 (62 eletrodos $\times$ 5 faixas), 135 (27 pares de eletrodos $\times$ 5 faixas), 135 (27 pares de eletrodos $\times$ 5 faixas), 270 (54 pares de eletrodos $\times$ 5 faixas) e 115 (23 pares de eletrodos $\times$ 5 faixas).

3.2.2 Suavização de Características - *Feature Smoothing*

Utilizar o método de suavização de características (*Feature Smoothing*) por meio de sistemas dinâmicos lineares (*LDS*) oferece uma abordagem promissora para o processamento de sinais de EEG. Uma das principais vantagens dessa abordagem é a capacidade

Tabela 3 – Descritivo de Atributos do SEED.

Atributo	Quantidade de atributos de EEG por sessão				
	δ	θ	α	β	γ
PSD	62	62	62	62	62
DE	62	62	62	62	62
DASM	27	27	27	27	27
RASM	27	27	27	27	27
ASM	54	54	54	54	54
DCAU	23	23	23	23	23

Fonte: Adaptado de [Song et al. \(2018\)](#).

de reduzir o ruído presente nos sinais EEG, resultando em características mais suaves e representativas. Isso é crucial, uma vez que os sinais EEG frequentemente sofrem com diversos tipos de interferências, como artefatos musculares e elétricos, que podem comprometer a precisão das análises ([SANEI; CHAMBERS, 2013](#)). No caso do *SEED*, os autores utilizaram o método *LDS* para filtrar componentes não associados a estados emocionais (ruídos e artefatos) e levar em consideração a dinâmica temporal dos estados emocionais. Ao suavizar as características, o *LDS* pode contribuir para a remoção dessas interferências, melhorando a qualidade das informações extraídas e, conseqüentemente, a acurácia das análises emocionais ([ALARCAO; FONSECA, 2019b](#)).

Além disso, o uso de *LDS* na suavização de características permite incorporar informações de estados anteriores, criando uma relação temporal mais coerente entre os dados. Isso é particularmente relevante em EEG, uma vez que a atividade cerebral é intrinsecamente dependente do tempo. Através de uma abordagem sequencial, o *LDS* considera a evolução temporal das características, proporcionando uma representação mais dinâmica dos sinais EEG e, assim, preservando a informação temporal relevante para a análise de emoções ([PENG; LONG; DING, 2005](#)).

Contudo, é importante ressaltar que a utilização de *LDS* para a suavização de características também enfrenta desafios. Um dos principais é o compromisso entre suavização e preservação de informações importantes. Em alguns casos, uma suavização excessiva pode levar à perda de detalhes relevantes, afetando a precisão das análises. Além disso, a aplicação de *LDS* requer um bom entendimento das propriedades do sistema dinâmico subjacente aos dados EEG, o que pode ser uma tarefa complexa e demandar ajustes adequados ([LOTTE et al., 2007](#)).

Em resumo, a suavização de características por meio de *LDS* apresenta vantagens significativas para o processamento de sinais EEG, contribuindo para a redução de ruído, a melhoria na qualidade das informações e a preservação da informação temporal. No entanto, é essencial considerar os desafios associados à suavização excessiva e à modelagem dos sistemas dinâmicos, buscando um equilíbrio que resulte em análises emocionais mais confiáveis e precisas.

3.3 Experimentos

3.3.1 Modelos de Aprendizado de Máquina e Aprendizado profundo

A linguagem de programação *Python* tem se destacado como uma escolha popular para desenvolvimento em diversas áreas, inclusive no campo de aprendizado de máquina ([Python.org](https://python.org), 2023). Com uma sintaxe simples e intuitiva, *Python* oferece uma vasta gama de bibliotecas e *frameworks* especializados, o que a torna uma ferramenta versátil e poderosa para implementar algoritmos de análise de dados e aprendizado de máquina. Devido a estes benefícios e familiaridade do autor desta dissertação com a linguagem, optou-se por utilizá-la como base para implementar as arquiteturas propostas.

O *scikit-learn*, também conhecido como *sklearn*, é uma biblioteca em *Python* amplamente utilizada para aprendizado de máquina. Ele fornece uma variedade de ferramentas para tarefas como classificação, regressão, clustering, pré-processamento de dados e seleção de modelos ([SCIKIT-LEARN.org](https://scikit-learn.org), 2023). Através de uma modularização consistente e de fácil utilização possibilita aplicar algoritmos de aprendizado de máquina, tornando-o uma escolha preferida para experimentação e prototipagem. No presente trabalho optou-se pela utilização da referida biblioteca para implementar os modelos de Regressão Logística, K-vizinhos mais próximos e Máquina de Vetores de Suporte.


Por outro lado, o PyTorch é um *framework* de aprendizado de máquina e *Deep Learning* que tem ganhado destaque devido à sua flexibilidade e eficiência. Desenvolvido pela equipe da *Meta AI*, *PyTorch* permite a construção de modelos de redes neurais de maneira dinâmica e imperativa, o que facilita a experimentação e depuração ([META AI](https://pytorch.org), 2023). Além disso, *PyTorch* suporta operações em *GPU*, acelerando o treinamento de modelos em grandes conjuntos de dados. Sua arquitetura baseada em tensores permite a criação de redes neurais complexas com camadas customizadas e oferece funcionalidades para *autograd* e otimização. A combinação de sua flexibilidade e eficiência torna o *PyTorch* uma excelente escolha para implementar e treinar modelos de *Deep Learning*, incluindo *CNNs* e *Graph Convolutional Neural Networks*.

Em relação aos parâmetros utilizados para cada um dos modelos, foi utilizada a estrutura descrita a seguir: para o classificador *KNN*, a distância euclidiana é escolhida como métrica de distância, e o número de vizinhos mais próximos foi ajustado no intervalo de $[3, 10]$ para encontrar o melhor hiperparâmetro. Para a Regressão Logística, os parâmetros são calculados usando a estimativa de máxima verossimilhança, função padrão fornecida pelo módulo *scikit-learn*. Para o classificador *SVM*, adotou-se a função no módulo *scikit-learn* com um *kernel* linear, e o parâmetro *C* foi definido a partir da busca em grade nos conjuntos $[2^{(-10)}, 2^{(-9)}, \dots, 2^{10}]$ e $[0.1, 20]$, com um passo de 0.5 para as situações de grande e pequeno passo, respectivamente.

Para o modelo *DNN* utilizado neste trabalho, há três camadas ocultas com 128,

64 e 32 unidades ocultas. A camada de saída possui três unidades correspondentes a três emoções. As funções de ativação não lineares usadas são *ReLU*. O algoritmo de otimização utilizado foi o *RMSProp*, e definiu-se o número de épocas como 5.000. Para o modelo *DGCNN*, a camada de entrada corresponde às características EEG extraídas de múltiplas bandas de frequência. Após a operação de filtragem do grafo, há uma camada de convolução 1×1 , que tem como objetivo aprender características discriminativas entre os diversos domínios de frequência. Além disso, para alcançar a capacidade de mapeamento não linear da rede, a função de ativação *ReLU* é adotada para garantir que as saídas da camada de filtragem do grafo sejam não negativas. Por fim, as saídas da função de ativação são enviadas para uma rede de conexão total de várias camadas e uma função *softmax* também é usada para prever a informação da etiqueta de classe desejada das características EEG de entrada. As arquitetura de *DNN* e *DGCNN* estão representadas respectivamente nas Figuras 7 e 11. Um resumo da metodologia utilizada no presente trabalho é demonstrada na Figura 12.

Figura 11 – Arquitetura *GCNN*.




Fonte: Adaptado de Zhang et al. (2023).

3.3.2 Análise de resultados

De acordo com Liu et al. (2022), Song et al. (2022), Li et al. (2021) e Zheng, Zhu e Lu (2019) existem dois tipos principais de experimentos para avaliar o desempenho do reconhecimento de emoções em sinais de EEG. O primeiro tipo de experimento é denominado "dependente do sujeito" (*subject-dependent*), enquanto o segundo "independente do sujeito" (*subject-independent*). Na abordagem *subject-dependent*, os dados de um determinado sujeito são divididos em conjuntos de treinamento e teste. Ou seja, os dados coletados de um sujeito específico são usados tanto para treinar o modelo quanto para testá-lo. Isso permite avaliar a capacidade do modelo em reconhecer emoções do próprio sujeito a partir de seus próprios dados EEG. No caso do Dataset *SEED*, os primeiros 9 ensaios dos dados EEG são usados como conjunto de treinamento e os 6 restantes como conjunto de teste, conforme demonstrado na Figura 13. Esta divisão de treino e teste 60/40

Figura 12 – Metodologia de Aquisição, Processamento e Classificação dos dados de Eletroencefalografia.




Fonte: Adaptado de Wang e Wang (2021).

é estabelecido pela literatura ((ZHENG; LU, 2015; ZHENG; ZHU; LU, 2019; ZHANG et al., 2020)). Em seguida, a precisão de reconhecimento correspondente a cada período é obtida para cada sujeito. Por fim, a média da precisão de classificação e o desvio padrão ao longo de duas sessões de todos os 15 sujeitos são calculados. No entanto, essa abordagem pode levar a resultados enviesados, pois o modelo pode memorizar os padrões específicos de um sujeito, prejudicando sua generalização para outros sujeitos.

Por outro lado, na abordagem *subject-independent*, os dados de um conjunto de sujeitos são usados para treinar o modelo, e os dados de um conjunto diferente de sujeitos são usados para testá-lo. Nesse caso, o modelo é avaliado em sua capacidade de generalização para sujeitos que não foram vistos durante o treinamento. Isso fornece uma avaliação mais realista do desempenho do modelo em situações do mundo real, onde ele precisa reconhecer emoções de sujeitos desconhecidos. No entanto, essa abordagem pode ser mais desafiadora, pois exige que o modelo capture padrões gerais de emoção em vez de depender de características específicas de cada sujeito.

Em resumo, a abordagem *subject-dependent* avalia o desempenho do modelo na capacidade de reconhecer emoções de um sujeito específico, enquanto a abordagem *subject-independent* avalia seu desempenho na capacidade de generalização para sujeitos não vistos durante o treinamento. Ambas as abordagens têm suas vantagens e desafios, e a escolha entre elas depende dos objetivos do estudo e da natureza dos dados EEG. No presente trabalho, optou-se por utilizar a abordagem *subject-dependent*.

Figura 13 – Abordagem de avaliação através de metodologia *subject-dependent*.

Fonte: Elaborado pelo autor.

Neste capítulo, foi apresentada a metodologia utilizada para investigar o reconhecimento de emoções por meio de sinais de EEG, aplicando técnicas de aprendizado de máquina e aprendizado profundo. O conjunto de dados EEG, o SEED, foi descrito em detalhes, destacando sua importância para a pesquisa. Em seguida, foi discutido o pré-processamento de EEG, incluindo a extração de atributos e a aplicação de suavização de características, visando melhorar a qualidade dos dados. Além disso, a estrutura dos experimentos foi delineada, explorando modelos de aprendizado de máquina e aprendizado profundo. O próximo capítulo abordará os resultados e conduzirá discussões detalhadas sobre o desempenho dos modelos. Isso permitirá a avaliação das contribuições desses modelos para a detecção de emoções por meio de EEG e fornecerá informações para pesquisas futuras na área de processamento de sinais de EEG.

4 Resultados e Discussões

Neste capítulo são apresentados os resultados alcançados por meio da aplicação dos modelos de aprendizado de máquina, nomeadamente Regressão Logística, K-vizinhos Mais Próximos, Máquinas de Vetores de Suporte, Redes Neurais Profundas e Redes Neurais Convolucionais em Grafos, com o objetivo de detecção de emoções (positivo, negativo e neutro) a partir de sinais do *SEED*. Cada modelo foi avaliado considerando métricas de acurácia e desvio padrão que oferecem uma visão abrangente do seu desempenho. A análise dos resultados revela uma panorâmica das habilidades de cada modelo na classificação de emoções, permitindo comparar e contrastar os desempenhos de cada um.

Nesse contexto, uma avaliação detalhada da performance individual de cada modelo é conduzida, destacando o desempenho notável de determinados modelos em relação a outros. A metódica comparação dos resultados possibilita a identificação dos modelos que mais se destacaram na detecção de diferentes estados emocionais, promovendo uma visão abrangente das capacidades de cada abordagem. Além disso, a análise explora a variação de desempenho entre os modelos em relação a diferentes emoções, apontando se algum modelo é especialmente apto para reconhecer determinados estados emocionais em comparação com outros.

4.1 Modelos de Aprendizagem de Máquina Tradicionais

Os resultados apresentados na Tabela 4 demonstram a acurácia e desvio padrão para o modelo de Regressão Logística aplicado em cada uma das cinco bandas de frequência do sinal do EEG e também considerando todo o espectro de frequências do sinal do EEG. Os resultados detalhados do modelo citado para cada indivíduo e sessão são demonstrados nas Tabelas 5 a 10. A mesma estrutura de resultados foi gerada para os modelos *KNN* e *SVM*.

Tabela 4 – Resultado (Acurácia/Desvio Padrão) do modelo *LR*

Modelo	Feature	δ	θ	α	β	γ	todas as frequências
LR	DE	61,18/13,71	65,32/14,16	67,58/13,74	76,71/14,33	74,34/15,73	82,46/11,11
	PSD	58,66/15,66	66,02/12,92	62,81/17,23	67,87/18,09	67,09/15,92	75,44/15,02
	DASM	45,31/12,83	49,85/15,55	56,42/14,7	71,02/17,92	73,41/16,25	75,34/15,56
	RASM	45,72/12,8	49,93/15,67	56,57/14,54	71,12/17,71	73,39/16,1	75,41/15,53
	ASM	45,36/12,95	50,05/15,56	56,92/14,27	70,71/17,96	73,05/16,59	74,73/15,48
	DCAU	53,77/15,15	55,22/15,72	60,98/14,92	72,19/17,31	73,86/17,74	80,69/11,72

Fonte: Elaborada pelo autor.

Uma comparação do desempenho dos modelos tradicionais entre diferentes características extraídas de sinais de EEG para a detecção de emoções é apresentada na Tabela

Tabela 5 – Acurácia detalhada por indivíduo/sessão no modelo *LR - feature DE*

Feature	indivíduo	sessão	δ	θ	α	β	γ	todas as frequências
DE	1	1	56,58	85,19	82,15	88,22	82,15	95,3
		2	60,84	71,97	51,73	63,08	73,55	79,55
		3	45,66	69,44	53,61	61,2	56	70,09
	2	1	79,99	19,58	35,84	45,74	55,42	79,48
		2	73,99	57,73	68,64	65,03	65,61	91,84
		3	59,47	65,97	81,65	52,89	51,23	61,13
	3	1	67,92	52,96	63,37	78,83	68,28	89,88
		2	46,68	70,45	64,96	64,02	73,84	80,27
		3	63,58	74,49	90,39	91,76	87,43	97,18
	4	1	57,37	57,88	75,43	71,97	65,1	71,46
		2	59,03	56,58	59,03	58,38	63,73	68,5
		3	61,71	78,11	71,68	55,64	67,05	74,06
	5	1	67,27	88,15	61,56	55,06	37,14	70,74
		2	58,89	74,35	71,6	90,68	77,02	90,39
		3	67,12	71,97	61,78	72,83	55,71	75,14
	6	1	82,88	86,27	88,51	91,11	84,75	99,64
		2	46,32	71,6	75,29	82,73	84,1	78,03
		3	51,81	69,58	70,95	80,27	77,38	80,78
	7	1	52,1	80,71	77,67	86,85	64,31	84,03
		2	26,81	65,68	64,02	100	99,21	99,78
		3	51,95	52,17	72,04	65,82	45,88	69,87
	8	1	60,55	48,55	65,17	79,41	77,24	77,31
		2	42,27	64,02	69,58	87,21	57,44	89,02
		3	69,65	50,87	84,03	97,54	68,28	96,46
	9	1	78,83	65,46	54,91	77,96	97,4	92,77
		2	58,96	71,39	84,25	95,95	83,16	87,86
		3	55,92	53,83	62,5	61,56	71,97	67,99
	10	1	57,3	56,36	60,77	69,15	77,46	66,62
		2	69,94	34,9	41,55	66,69	68,35	70,16
		3	52,17	48,27	54,7	76,59	78,11	81,65
	11	1	48,99	65,75	79,62	64,52	76,23	70,59
		2	54,84	58,16	60,26	72,47	74,78	72,47
		3	77,82	48,63	84,68	85,69	86,2	96,03
	12	1	85,98	94,44	61,42	74,57	86,2	92,2
		2	29,91	49,78	54,48	62,07	56,07	73,27
		3	64,16	62,21	77,17	89,81	96,17	85,91
	13	1	59,75	63,87	43,06	73,92	86,05	84,39
		2	43,28	71,89	57,88	93,71	93,21	88,08
		3	69,65	86,49	55,49	87,93	83,74	80,85
	14	1	85,19	72,47	60,48	86,78	81,21	83,67
		2	64,52	70,59	62,36	72,47	68,42	79,84
		3	52,1	64,23	61,27	63,22	44,15	66,33
	15	1	70,23	72,83	91,33	93,06	98,7	100
		2	80,85	70,66	72,11	100	100	100
		3	82,44	73,05	100	97,62	100	100

Fonte: Elaborada pelo autor.

Tabela 6 – Acurácia detalhada por indivíduo/sessão no modelo *LR - feature PSD*

Feature	indivíduo	sessão	δ	θ	α	β	γ	todas as frequências
PSD	1	1	46,24	73,7	88,8	70,09	74,71	90,17
		2	47,11	78,76	55,13	56,21	62,93	76,3
		3	35,4	52,53	58,24	71,68	60,84	54,99
	2	1	82,44	55,78	21,17	38,44	49,71	65,03
		2	72,9	55,42	60,62	49,21	60,12	81,58
		3	64,23	63,44	81,07	48,34	47,18	64,16
	3	1	61,92	58,67	70,23	61,92	62,43	78,61
		2	69,44	70,16	56,43	60,55	74,35	76,16
		3	54,26	65,82	92,34	93,93	78,83	93,42
	4	1	39,31	67,7	63,8	54,12	65,03	78,47
		2	72,9	73,05	66,69	68,21	69,73	75,51
		3	50,29	71,68	73,84	45,3	54,7	72,25
	5	1	63,29	82,01	67,63	52,75	43,79	66,11
		2	57,51	71,97	62,72	84,68	74,42	82,95
		3	69,15	63,87	49,57	70,45	59,03	73,99
	6	1	70,45	81,36	57,51	73,63	67,05	85,04
		2	40,17	48,48	44,22	45,66	45,88	37,64
		3	52,96	63,01	42,92	50,65	75,14	55,78
	7	1	51,23	76,01	71,39	60,19	44,58	72,98
		2	27,6	85,77	56,72	96,24	88,29	95,38
		3	66,26	53,83	62,36	35,4	34,47	64,09
	8	1	65,25	33,67	56,5	82,51	66,33	65,82
		2	64,96	62,21	60,77	79,77	62,43	75,94
		3	69,94	69,08	60,48	94,58	69,8	85,69
	9	1	71,75	66,55	60,04	71,53	71,1	84,32
		2	64,81	58,24	69,65	83,96	64,67	71,46
		3	59,75	48,63	79,19	61,49	61,34	69,94
	10	1	50,43	45,74	56,65	60,69	39,96	59,68
		2	45,3	58,16	39,88	57,88	52,75	43,86
		3	63,73	55,49	26,81	45,95	53,25	62,21
	11	1	28,97	65,75	83,89	54,34	82,44	86,71
		2	48,41	78,4	65,1	77,96	75,51	67,77
		3	63,44	65,61	94,08	91,26	86,2	98,77
	12	1	86,78	94,44	54,55	75,72	71,24	97,54
		2	25,79	35,04	40,68	28,47	46,6	42,2
		3	38,73	69,94	41,47	75,29	88,44	70,52
	13	1	70,81	54,12	53,83	64,02	86,27	87,21
		2	41,47	66,11	52,75	81,07	84,1	80,06
		3	59,83	78,83	57,08	84,47	67,12	77,96
	14	1	60,33	68,93	51,01	73,27	79,55	77,89
		2	54,19	83,45	67,05	79,55	62,64	74,57
		3	53,97	70,09	70,38	52,46	57,66	74,28
	15	1	86,78	71,89	91,69	91,76	97,62	100
		2	89,45	86,71	89,74	100	100	100
		3	79,84	70,66	100	98,48	98,63	100

Fonte: Elaborada pelo autor.

11. Foram analisadas seis características: *PSD*, *DE*, *DASM*, *RASM*, *ASM* e *DCAU*, em relação às bandas de frequência total. Para a classificação, foram utilizados o modelos tradicionais de aprendizado de máquina *LR*, *KNN* e *SVM*.

Os resultados apresentados nas Figuras 15 a 19 mostram que as características *DE* (*differential entropy*) apresentaram uma maior acurácia e um desvio padrão menor do que as características tradicionais de *PSD* (*power spectral density*). Isso sugere que as características *DE* são mais adequadas para o reconhecimento de emoções baseado em EEG do que as outras características. Outra conclusão importante é que as características de assimetria (*DASM*, *RASM*, *ASM*) tiveram um desempenho semelhante e em alguns casos melhor do que *PSD*, apesar de terem menos dimensões (135 (27 pares de eletrodos $\times$ 5 faixas), 135 (27 pares de eletrodos $\times$ 5 faixas), 270 (54 pares de eletrodos $\times$ 5 faixas) e 310 (62 eletrodos $\times$ 5 faixas) respectivamente). Isso sugere que o processamento cerebral

Tabela 7 – Acurácia detalhada por indivíduo/sessão no modelo *LR - feature DASM*

Feature	indivíduo	sessão	δ	θ	α	β	γ	todas as frequências
DASM	1	1	59,97	49,71	68,06	86,42	96,1	96,82
		2	40,25	73,34	32,23	63,66	57,66	73,48
		3	46,82	52,46	36,13	47,47	56,43	72,04
	2	1	34,32	27,24	47,04	65,46	68,35	75,29
		2	46,82	24,86	42,85	76,16	59,54	74,78
		3	52,89	23,55	61,92	41,91	47,33	62,57
	3	1	50,72	45,74	54,34	52,82	58,82	66,76
		2	75,94	61,34	32,37	47,62	64,67	64,88
		3	56,5	51,3	56,5	78,03	75,07	96,32
	4	1	41,4	50,94	65,75	69	69,29	68,71
		2	46,24	25,72	43,57	57,37	59,61	46,6
		3	68,35	32,95	63,29	42,2	57,95	56,58
	5	1	32,59	63,87	35,69	41,62	29,7	45,01
		2	51,73	64,74	56,21	50,87	74,13	69,94
		3	49,42	32,51	35,62	40,03	52,96	57,01
	6	1	28,76	39,52	64,38	97,54	88,15	97,4
		2	17,77	55,78	59,39	65,39	72,04	61,71
		3	32,8	71,6	66,26	84,68	80,13	78,32
	7	1	45,38	70,81	72,69	74,64	78,68	84,32
		2	31,65	63,58	75,22	94,15	96,6	96,89
		3	40,46	37,36	66,26	50,79	50,94	71,03
	8	1	59,25	17,2	32,51	77,6	84,83	63,95
		2	48,41	55,64	48,34	100	72,83	91,33
		3	35,4	52,96	56,65	65,39	93,64	77,17
	9	1	62,43	66,62	53,25	75,29	68,5	74,13
		2	25,14	62,86	71,89	85,69	87,79	87,14
		3	53,32	46,68	72,98	48,55	68,64	68,06
	10	1	53,03	48,41	78,47	71,6	66,62	59,1
		2	56,21	35,19	49,93	61,71	78,68	75,94
		3	52,82	38,58	39,81	71,97	76,81	73,41
	11	1	47,9	35,91	82,37	77,53	85,12	90,61
		2	15,97	42,34	52,38	73,84	86,49	60,62
		3	58,02	32,15	84,47	97,76	89,81	93,42
	12	1	39,6	59,47	65,46	76,23	85,98	89,88
		2	40,17	27,6	50,94	48,7	39,23	40,03
		3	63,73	53,25	45,66	92,34	99,35	99,06
	13	1	38,58	74,78	50,51	79,48	91,98	92,63
		2	32,01	52,1	67,92	92,92	72,83	69,73
		3	53,97	57,73	52,1	86,85	91,47	77,38
	14	1	44	61,05	49,13	69,29	75,72	72,83
		2	59,68	77,38	50,14	77,38	75,43	74,78
		3	41,62	57,08	56,65	62,07	58,82	57,88
	15	1	29,48	44,44	40,46	88,29	86,99	91,4
		2	51,3	72,54	75,36	92,2	74,64	96,32
		3	44,36	56,14	82,44	100	96,32	100

Fonte: Elaborada pelo autor.

Tabela 8 – Acurácia detalhada por indivíduo/sessão no modelo *LR - feature RASM*

Feature	indivíduo	sessão	δ	θ	α	β	γ	todas as frequências
RASM	1	1	65,46	52,75	67,34	85,4	95,95	97,25
		2	38,15	73,92	32,37	63,8	57,88	73,41
		3	46,24	51,66	35,84	46,1	57,51	72,69
	2	1	32,37	26,45	46,1	65,03	68,57	76,73
		2	47,62	26,66	40,97	76,01	57,95	73,05
		3	54,26	26,08	61,56	39,09	46,17	62,57
	3	1	51,37	40,17	51,73	50,07	56,43	63,22
		2	74,78	60,4	33,53	49,21	68,86	66,84
		3	58,96	49,42	55,71	78,68	73,84	96,32
	4	1	39,38	59,75	63,01	67,41	64,81	67,49
		2	44,94	24,78	51,45	56,94	62,21	50,29
		3	62,79	30,49	63,08	40,1	55,27	55,2
	5	1	36,05	62,5	34,18	40,75	26,16	44,08
		2	52,1	58,31	55,92	52,46	73,7	69,73
		3	53,03	30,85	31,79	41,62	56,79	55,56
	6	1	25,72	37,14	69,65	98,05	86,63	98,12
		2	19,15	57,08	59,32	64,31	64,88	60,77
		3	27,6	75,07	67,27	84,97	82,37	77,89
	7	1	43,5	69,51	75,29	77,24	77,67	83,89
		2	38,73	65,53	75,43	94,15	96,53	96,82
		3	38,87	35,69	64,09	51,95	50,94	72,47
	8	1	57,95	19,51	30,56	80,27	85,91	64,81
		2	50,29	52,67	48,7	99,49	77,1	91,69
		3	35,98	48,41	57,01	65,53	93,57	77,1
	9	1	61,34	67,99	53,18	73,63	70,01	74,57
		2	24,57	57,95	70,81	84,61	87,64	86,49
		3	48,05	51,01	58,02	49,28	68,14	66,04
	10	1	51,81	48,55	82,66	69,94	64,52	58,82
		2	59,03	38,95	52,53	63,22	79,12	77,1
		3	51,01	38,95	41,47	69,44	75,58	72,11
	11	1	51,59	36,71	81	77,24	86,49	90,46
		2	14,67	43,06	54,19	73,48	86,34	61,99
		3	55,06	32,08	83,67	97,62	90,39	92,56
	12	1	35,69	59,54	64,88	76,95	85,84	89,45
		2	39,31	27,67	48,63	48,84	43,64	40,03
		3	57,51	51,3	43,86	92,34	100	99,13
	13	1	42,12	72,76	48,92	79,77	92,05	91,76
		2	34,18	50,87	68,86	92,99	73,84	70,66
		3	50,36	58,45	45,09	87,07	92,49	77,89
	14	1	45,45	60,48	50,79	68,93	75,58	71,32
		2	62,07	78,03	49,71	78,25	72,18	77,17
		3	40,82	62,79	55,71	61,71	62,86	57,15
	15	1	25,58	45,81	51,16	88,37	89,31	91,18
		2	47,76	69,73	79,41	93,64	74,28	96,53
		3	45,52	55,85	82,59	100	95,59	100

Fonte: Elaborada pelo autor.

relacionado às emoções positivas, neutras e negativas possui características assimétricas.

Esses resultados sugerem que características como *DE* e as de assimetria podem ser mais relevantes para a detecção de emoções em sinais de EEG do que características tradicionais como *PSD*. Além disso, o uso de algoritmos de suavização e a escolha do classificador certo podem ter um impacto significativo na precisão do reconhecimento de emoções.

4.2 Redes de Aprendizado Profundo

O modelo *DNN* utilizado neste trabalho é composto por três camadas ocultas com 128, 64 e 32 unidades ocultas, respectivamente. A camada de saída possui três unidades correspondentes a três emoções diferentes. O algoritmo de otimização utilizado foi o

Tabela 9 – Acurácia detalhada por indivíduo/sessão no modelo *LR - feature ASM*

Feature	indivíduo	sessão	δ	θ	α	β	γ	todas as frequências
ASM	1	1	66,18	49,35	67,12	86,99	97,04	97,4
		2	42,63	73,12	32,8	66,26	52,67	70,09
		3	44,29	53,47	35,19	53,11	56,58	77,53
	2	1	37,21	26,81	44,65	66,18	67,56	76,01
		2	44	30,13	45,16	74,57	58,45	71,82
		3	54,91	25,14	62,21	38,01	46,97	59,9
	3	1	52,02	41,84	53,25	51,66	58,96	62,57
		2	74,35	59,03	31,86	44,58	66,91	59,39
		3	58,53	50,65	57,66	77,96	77,02	91,47
	4	1	40,68	63,08	65,68	67,63	68,21	65,9
		2	46,53	27,67	45,81	57,3	62,28	51,16
		3	60,19	29,12	63,08	39,45	56,86	55,71
	5	1	33,74	64,09	37,07	38,01	27,67	42,77
		2	52,02	64,38	52,82	49,42	65,17	68,57
		3	50,72	30,27	33,82	43,14	52,67	54,62
	6	1	28,25	36,78	62,86	99,21	86,27	98,41
		2	19,08	55,49	59,61	69,08	70,16	57,51
		3	33,09	75,87	66,33	83,67	81,21	79,05
	7	1	44,65	70,23	71,97	74,78	77,67	86,13
		2	32,08	60,26	74,42	95,45	94,65	95,95
		3	36,05	33,53	68,71	50,43	50,94	74,57
	8	1	60,84	19,65	35,77	81,07	80,71	62,79
		2	50,87	57,51	50,72	98,63	83,67	91,84
		3	40,25	51,88	62,72	66,18	94,29	79,84
	9	1	62,43	67,7	53,68	76,81	69,8	74,57
		2	22,11	62,93	74,28	84,68	87,86	86,13
		3	50,65	56,72	65,68	49,86	65,32	70,52
	10	1	51,95	43,93	76,81	73,63	67,63	58,09
		2	59,25	38,01	52,6	61,2	80,85	79,19
		3	51,88	39,81	41,33	63,44	75,29	72,76
	11	1	49,28	36,78	81,58	74,06	86,49	91,62
		2	15,25	42,05	53,68	74,49	86,49	61,13
		3	57,51	32,95	83,45	98,7	90,25	93,79
	12	1	37,93	58,53	64,74	76,23	84,68	85,77
		2	39,45	26,01	52,53	44,08	30,85	41,55
		3	55,85	52,46	43,57	88,29	95,16	92,7
	13	1	40,61	67,27	48,19	79,12	91,69	90,32
		2	32,23	49,13	71,53	93,5	77,24	70,52
		3	54,05	58,74	53,47	84,47	88,44	75,43
	14	1	38,22	59,97	51,73	68,79	75,79	70,66
		2	60,98	79,34	50,65	79,48	73,41	75,87
		3	41,76	62,93	58,02	63,22	66,26	56,65
	15	1	22,4	45,38	41,76	86,92	87,28	88,22
		2	52,1	68,35	80,42	88,15	74,78	96,46
		3	41,98	53,83	80,56	100	97,04	100

Fonte: Elaborada pelo autor.

Tabela 10 – Acurácia detalhada por indivíduo/sessão no modelo *LR - feature DCAU*

Feature	indivíduo	sessão	δ	θ	α	β	γ	todas as frequências
DCAU	1	1	29,19	60,91	81,65	74,21	86,27	88,01
		2	47,83	80,42	45,16	70,3	65,17	74,49
		3	49,64	69,44	71,68	68,42	32,08	80,35
	2	1	58,16	28,18	35,4	58,82	71,39	75,29
		2	64,16	42,05	57,95	56,72	69,08	75,79
		3	47,47	60,26	65,75	57,08	44,08	68,57
	3	1	52,31	49,35	55,13	55,92	61,85	81,43
		2	38,37	78,97	56,79	68,21	56,58	79,48
		3	71,03	32,73	48,7	86,34	71,82	93,79
	4	1	72,04	20,01	54,05	48,41	75,29	66,33
		2	65,39	40,75	49,78	53,11	72,11	72,18
		3	60,26	54,05	60,84	66,26	70,66	73,84
	5	1	58,45	57,08	41,04	35,48	39,96	56,79
		2	57,51	56,07	49,49	41,33	81,5	88,51
		3	66,55	50	24,71	52,96	26,08	50,36
	6	1	63,95	82,59	91,11	77,89	72,4	97,98
		2	41,98	57,23	57,73	85,98	89,16	82,66
		3	49,28	67,63	62,64	71,75	71,53	84,9
	7	1	42,77	56,65	56,94	46,03	60,84	61,78
		2	29,77	70,01	56,94	98,84	95,66	98,19
		3	25,43	34,68	61,49	52,31	55,13	68,57
	8	1	44,8	56,14	69,29	96,97	75,22	79,48
		2	35,77	70,45	71,53	100	88,51	93,57
		3	52,75	65,9	43,35	96,39	85,91	88,37
	9	1	75,72	45,01	40,97	73,48	92,56	90,61
		2	47,9	55,64	73,7	90,25	95,3	74,93
		3	66,26	44,36	69,58	51,08	51,01	65,53
	10	1	31,07	82,3	56,14	72,47	71,24	69,36
		2	77,89	35,33	58,09	68,06	82,01	80,64
		3	27,6	43,93	54,12	56,5	67,63	78,4
	11	1	62,79	65,17	84,9	71,75	78,18	77,53
		2	36,34	45,52	79,41	89,38	88,73	84,32
		3	71,39	34,1	92,34	93,42	86,49	97,18
	12	1	74,13	75,36	76,52	80,78	80,49	88,51
		2	35,26	45,59	51,3	59,68	65,61	71,39
		3	44,94	76,81	77,38	91,76	92,41	89,6
	13	1	64,02	82,08	36,27	79,91	90,9	81,94
		2	42,92	59,83	64,81	79,99	86,34	85,62
		3	68,71	59,32	60,98	88,08	93,57	96,46
	14	1	84,32	42,27	51,3	80,64	94,36	81,94
		2	51,66	56,36	59,03	65,53	50,29	90,03
		3	42,41	48,19	74,49	65,46	59,75	64,31
	15	1	55,56	32,3	59,47	71,53	90,61	83,74
		2	64,67	55,78	79,99	100	92,05	98,48
		3	69,44	58,31	73,99	98,92	95,95	100

Fonte: Elaborada pelo autor.

RMSPProp, e o número de épocas foi configurado para 5000.

Os resultados da Tabela 12 indicam que o classificador *DNN* superou o classificador *SVM* obtendo uma acurácia de reconhecimento de emoções de 85,22%. Entre os quatro classificadores avaliados, o *DNN* se mostrou o mais eficaz para a tarefa de reconhecimento de emoções com base em EEG. O tempo de processamento, porém, foi uma dificuldade devido à necessidade de avaliar os melhores hiper parâmetros para o modelo. Para cada indivíduo/sessão foram avaliadas 20 taxas de aprendizagem, com o tempo médio de processamento de 45 minutos para cada taxa, totalizando 15 indivíduos x 3 sessões x 20 taxas de aprendizagem x 45 minutos em aproximadamente 28 horas de processamento. Uma vantagem significativa do modelo *DGCNN* reside no seu tempo de processamento significativamente reduzido em comparação com o modelo *DNN*. Enquanto o modelo *DNN* requer um extenso período de treinamento, o modelo *DGCNN* alcança resultados superiores,

Tabela 11 – Resultados (Acurácia/Desvio Padrão) dos modelos *LR*, *KNN* e *SVM*

Modelo	Feature	δ	θ	α	β	γ	todas as frequências
LR	DE	61,18/13,71	65,32/14,16	67,58/13,74	76,71/14,33	74,34/15,73	82,46/11,11
	PSD	58,66/15,66	66,02/12,92	62,81/17,23	67,87/18,09	67,09/15,92	75,44/15,02
	DASM	45,31/12,83	49,85/15,55	56,42/14,7	71,02/17,92	73,41/16,25	75,34/15,56
	RASM	45,72/12,8	49,93/15,67	56,57/14,54	71,12/17,71	73,39/16,1	75,41/15,53
	ASM	45,36/12,95	50,05/15,56	56,92/14,27	70,71/17,96	73,05/16,59	74,73/15,48
	DCAU	53,77/15,15	55,22/15,72	60,98/14,92	72,19/17,31	73,86/17,74	80,69/11,72
KNN	DE	55,66/13,09	58,41/13,19	60,24/16,26	69,65/15,44	70,08/16,29	75,23/13,37
	PSD	52,9/14,64	60,84/14,77	56,63/16,06	62,57/16,92	61,56/20,8	69,14/16,86
	DASM	43,95/11,7	43,09/13,37	49,42/15,38	64,03/17,66	67,11/16,14	66,24/17,53
	RASM	44,43/11,41	43,41/13,27	49,42/15,8	64,04/17,96	67,05/16,25	65,94/17,35
	ASM	44,09/11,43	43,1/12,99	49,26/15,33	63,84/18,09	67,1/15,57	66,16/17,09
	DCAU	50,27/11,77	49,5/10,38	53,6/11,18	67,8/15,09	68,88/16,44	72,84/12,75
SVM	DE	63,01/12,89	69,61/13,78	71,53/14,22	79,82/13,71	78,25/15,01	84,44/11,58
	PSD	61,91/14,1	69,43/12,41	66,33/16,42	71,04/17,01	71,96/15,02	77,99/13,91
	DASM	48,99/12,89	53,49/14,54	61,21/14,96	74,48/17,64	77,11/15,83	76,88/14,46
	RASM	49,83/12,83	53,53/14,9	61,95/15,02	73,87/17,67	77,22/15,9	76,8/14,44
	ASM	49,09/13,04	53,76/15,03	61,48/14,58	73,44/17,71	76,17/16,07	76,45/14,37
	DCAU	57,49/15,75	60,16/14,62	64,77/14,3	74,9/16,34	77,67/16,85	81,43/11,62

Fonte: Elaborada pelo autor.

Tabela 12 – Resultados (Acurácia/Desvio Padrão) dos modelos *DNN* e *DGCNN*

Modelo	Feature	δ	θ	α	β	γ	Todas as frequências
DNN	DE	73,35/10,94	74,52/8,38	75,32/12,61	80,47/13,51	83,34/10,13	85,22/9,51
	PSD	66,97/12,13	75,00/9,45	71,05/12,43	76,99/13,41	78,94/12,4	80,56/12,35
	DASM	57,01/7,23	61,91/10,56	67,82/11,67	79,01/13,57	81,85/12,17	79,59/12,15
	RASM	56,68/9,05	60,81/11,02	66,89/13,58	79,2/13,62	81,73/12,16	79,08/12,25
	ASM	55,33/8,25	59,97/10,46	66,96/11,82	78,35/13	80,14/12,38	81,19/11,5
	DCAU	70,07/6,89	68,39/11,6	72,42/9,54	80,94/11,63	83,06/10,74	84,71/9,82
DGCNN	DE	74,81/8,41	69,81/11,6	71,62/13,71	83,83/9,4	83,62/10,76	89,97/5,57
	PSD	70,25/13,41	69,63/8,63	65,26/10,99	71,67/15,5	75,87/18,33	79,39/15,08
	DASM	60,47/9,53	63,23/8,72	63,15/11,68	81,81/11,91	84,73/8,72	85,86/7,41
	RASM	60,14/10,36	62,17/10,09	63,01/11,11	81,92/10,26	84,53/9,29	84,82/7,79
	ASM	62,69/8,18	61,00/9,29	62,20/11,82	82,19/11,74	83,68/10,48	85,46/9,43
	DCAU	71,18/10,85	67,69/10,12	67,08/8,96	81,98/9,72	82,20/9,22	89,36/8,63

Fonte: Elaborada pelo autor.

em termos de melhor acurácia, em um tempo consideravelmente menor, variando entre 3 a 5 horas. Essa eficiência no tempo de processamento aprimora a praticidade e a viabilidade do modelo.

Em relação aos desempenhos em cada banda de frequência, β e γ indicam uma diminuição nas atividades para emoções positivas, neutras e negativas. Isso sugere que as características espectrais associadas a essas faixas de frequência estão correlacionadas com a expressão emocional e variam conforme o estado emocional. Essa observação é coerente com a literatura (ZHENG; ZHU; LU, 2019), que sugere que diferentes estados emocionais podem se refletir em padrões distintos de atividade cerebral em diferentes faixas de frequência.

Para o modelo *DGCNN* os resultados experimentais apresentados na Tabela 12 demonstram que o método proposto alcança um desempenho de reconhecimento melhor

do que os métodos anteriores. A média de acurácia de reconhecimento atingiu 89,97% para o experimento dependente do sujeito devido aos seguintes pontos principais:

- A utilização de uma rede neural não-linear do *DGCNN* o torna mais eficaz para lidar com a aprendizagem de características discriminativas não-lineares.
- A representação em forma de grafo do *DGCNN* proporciona uma maneira útil de caracterizar as relações intrínsecas entre os diversos canais de EEG, sendo vantajosa para extrair as características mais discriminativas para a tarefa de reconhecimento de emoções.
- O modelo *DGCNN* aprende adaptativamente as relações intrínsecas dos canais de EEG por meio da otimização da matriz de adjacência W .

É importante destacar que os elementos diagonais da matriz de adjacência indicam as contribuições dos canais de EEG para o reconhecimento de emoções. Portanto, a matriz de adjacência pode fornecer uma maneira potencial de identificar quais canais de EEG têm maior contribuição para o reconhecimento de emoções, o que pode ser vantajoso para melhorar ainda mais o desempenho do reconhecimento de emoções.

Embora o método *DGCNN* proposto tenha demonstrado ser eficaz no reconhecimento de emoções em EEG, é importante observar que as bases de dados de EEG utilizadas nos experimentos ainda são relativamente pequenas em termos de volume de dados. Isso pode limitar o uso de modelos de redes neurais profundas mais poderosos e, portanto, pode restringir melhorias adicionais no desempenho desse método. Portanto, é desejável contar com bases de dados EEG de maior escala para enfrentar esse desafio, o que também se torna uma tarefa importante para futuras pesquisas.


O resultado para os cinco modelos analisados é sumarizado na Tabela 13 e ressalta o desempenho superior do modelo *DGCNN* frente aos demais, em todas as frequências analisadas. Os resultados destacados apresentam desempenhos superiores em cada característica específica, evidenciando a notável eficácia do modelo baseado em grafos em cinco dos seis atributos analisados. Notavelmente, o modelo *DNN* exibiu uma acurácia superior apenas na Densidade de Espectro de Potência. O PSD é uma representação que captura a distribuição de energia em diversas frequências no sinal EEG e devido a esta distribuição de frequências a capacidade de um modelo em lidar com eficácia pode variar. A análise sugere que a inclusão do mapeamento da topologia dos eletrodos, realizado por meio da matriz de adjacência em grafos, não necessariamente melhora a acurácia para esse atributo específico.

Conforme observado anteriormente no presente estudo através da análise de bandas para os modelos tradicionais de *Machine Learning*, as bandas β e γ possuem considerável relevância no que diz respeito a identificação de estados emocionais. Analisando a banda

Tabela 13 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos por *feature*


<i>Feature</i>	Modelo	δ	θ	α	β	γ	Todas as frequências
DE	LR	61,18/13,71	65,32/14,16	67,58/13,74	76,71/14,33	74,34/15,73	82,46/11,11
	KNN	55,66/13,09	58,41/13,19	60,24/16,26	69,65/15,44	70,08/16,29	75,23/13,37
	SVM	63,01/12,89	69,61/13,78	71,53/14,22	79,82/13,71	78,25/15,01	84,44/11,58
	DNN	73,35/10,94	74,52/8,38	75,32/12,61	80,47/13,51	83,34/10,13	85,22/9,51
	DGCNN	74,81/8,41	69,81/11,60	71,62/13,71	83,83/9,40	83,62/10,76	89,97/5,57
PSD	LR	58,66/15,66	66,02/12,92	62,81/17,23	67,87/18,09	67,09/15,92	75,44/15,02
	KNN	52,9/14,64	60,84/14,77	56,63/16,06	62,57/16,92	61,56/20,8	69,14/16,86
	SVM	61,91/14,1	69,43/12,41	66,33/16,42	71,04/17,01	71,96/15,02	77,99/13,91
	DNN	66,97/12,13	75,00/9,45	71,05/12,43	76,99/13,41	78,94/12,40	80,56/12,35
	DGCNN	70,25/13,41	69,63/8,63	65,26/10,99	71,67/15,50	75,87/18,33	79,39/15,08
DASM	LR	45,72/12,8	49,93/15,67	56,57/14,54	71,12/17,71	73,39/16,1	75,41/15,53
	KNN	44,43/11,41	43,41/13,27	49,42/15,8	64,04/17,96	67,05/16,25	65,94/17,35
	SVM	49,83/12,83	53,53/14,9	61,95/15,02	73,87/17,67	77,22/15,9	76,8/14,44
	DNN	57,01/7,23	61,91/10,56	67,82/11,67	79,01/13,57	81,85/12,17	79,59/12,15
	DGCNN	60,47/9,53	63,23/8,72	63,15/11,68	81,81/11,91	84,73/8,72	85,86/7,41
RASM	LR	45,31/12,83	49,85/15,55	56,42/14,7	71,02/17,92	73,41/16,25	75,34/15,56
	KNN	43,95/11,7	43,09/13,37	49,42/15,38	64,03/17,66	67,11/16,14	66,24/17,53
	SVM	48,99/12,89	53,49/14,54	61,21/14,96	74,48/17,64	77,11/15,83	76,88/14,46
	DNN	56,68/9,05	60,81/11,02	66,89/13,58	79,2/13,62	81,73/12,16	79,08/12,25
	DGCNN	60,14/10,36	62,17/10,09	63,01/11,11	81,92/10,26	84,53/9,29	84,82/7,79
ASM	LR	45,36/12,95	50,05/15,56	56,92/14,27	70,71/17,96	73,05/16,59	74,73/15,48
	KNN	44,09/11,43	43,1/12,99	49,26/15,33	63,84/18,09	67,1/15,57	66,16/17,09
	SVM	49,09/13,04	53,76/15,03	61,48/14,58	73,44/17,71	76,17/16,07	76,45/14,37
	DNN	55,33/8,25	59,97/10,46	66,96/11,82	78,35/13,00	80,14/12,38	81,19/11,50
	DGCNN	62,69/8,18	61,00/9,29	62,2/11,82	82,19/11,74	83,68/10,48	85,46/9,43
DCAU	LR	53,77/15,15	55,22/15,72	60,98/14,92	72,19/17,31	73,86/17,74	80,69/11,72
	KNN	50,27/11,77	49,5/10,38	53,6/11,18	67,8/15,09	68,88/16,44	72,84/12,75
	SVM	57,49/15,75	60,16/14,62	64,77/14,3	74,9/16,34	77,67/16,85	81,43/11,62
	DNN	70,07/6,89	68,39/11,60	72,42/9,54	80,94/11,63	83,06/10,74	84,71/9,82
	DGCNN	71,18/10,85	67,69/10,12	67,08/8,96	81,98/9,72	82,2/9,22	89,36/8,63

Fonte: Elaborada pelo autor.

Figura 14 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência δ .


Fonte: Elaborada pelo autor.

Figura 15 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência θ .



Fonte: Elaborada pelo autor.

Figura 16 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência α .




Fonte: Elaborada pelo autor.

β , a superioridade do modelo *DGCNN* mais uma vez se destaca, conforme demonstrado na Figura 17. A habilidade do *DGCNN* em lidar com a complexidade dos padrões de EEG nessa faixa específica resulta em uma interpretação mais precisa das respostas emocionais. Este padrão consistente de desempenho ressalta a robustez do modelo em contextos emocionais diversos. A figura relacionada à banda γ também confirma a consistência do modelo *DGCNN* em apresentar um desempenho superior. Sua capacidade de capturar informações detalhadas e sutilezas nos padrões de EEG nessa faixa de frequência destaca o papel crucial do *DGCNN* na análise de emoções em contextos neurofisiológicos mais

complexos.

Na avaliação das bandas δ , θ e α , apresentadas nas Figuras 14, 15 e 16 respectivamente, é evidente que o modelo *DGCNN* também apresenta uma acurácia consistentemente superior, indicando sua eficácia em identificar padrões nessas faixas de frequência específicas. Contudo, é crucial notar que, apesar da menor acurácia em comparação com outras bandas, essa diminuição não reflete necessariamente uma limitação do modelo, mas sim uma característica intrínseca das próprias bandas. A menor acurácia nessas faixas sugere que δ , θ e α podem ser menos expressivas para a detecção de emoções positivas, negativas e neutras em comparação com outras faixas de frequência. Isso ressalta a importância de uma interpretação contextualizada das métricas de desempenho, reconhecendo que diferentes bandas podem desempenhar papéis variados na codificação de respostas emocionais complexas. Essa análise individual das diferentes bandas de frequência reforça a confiabilidade e a eficácia global do modelo *DGCNN* em todas as faixas, consolidando sua posição como uma escolha robusta para a classificação de emoções em sinais de EEG.


Figura 17 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência β .



Fonte: Elaborada pelo autor.


Por fim uma comparação com a literatura é apresentada na Tabela 15, na qual foram destacados os modelos *SVM* e *DNN* do trabalho de Zheng, Zhu e Lu (2019) e *DGCNN* de Song et al. (2018). É possível notar que ao comparar o desempenho do modelo *SVM* em todas as *features* o modelo proposto no presente trabalho apresentou acurácia superior. Este resultado é justificado pelo busca em grid (*gridsearch*) para cada indivíduo analisado. Uma outra distinção notável entre o presente trabalho e os estudos previamente citados na literatura é a inclusão da análise da característica de Assimetria (*ASM*) em conjunto com *DASM* e *RASM*. Enquanto os trabalhos anteriores se concentraram exclusivamente nas medidas de *DASM* (*Differential Asymmetry*) e *RASM* (*Rational Asymmetry*), a presente

Figura 18 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para frequência γ .



Fonte: Elaborada pelo autor.

Figura 19 – Resultados (Acurácia/Desvio Padrão) de todos os modelos descritos para todas as frequências.



Fonte: Elaborada pelo autor

pesquisa busca uma compreensão mais abrangente das características de assimetria no contexto do EEG. A incorporação de ASM adiciona uma dimensão adicional à avaliação, permitindo uma análise mais refinada das características assimétricas presentes nos padrões de atividade cerebral. Essa abordagem mais completa oferece uma visão mais detalhada e robusta das respostas emocionais capturadas pelos sinais de EEG, destacando a inovação e a contribuição significativa deste trabalho para o avanço da análise de emoções por meio de métodos neurofisiológicos.

O modelo de *DNN* desenvolvido no presente trabalho destaca-se ao superar signifi-

Tabela 14 – Comparação do modelo *DNN* com a literatura.

Feature	Modelo	δ	θ	α	β	γ	Todas as frequências
DE	DNN	73,35/10,94	74,52/8,38	75,32/12,61	80,47/13,51	83,34/10,13	85,22/9,51
	DBN (ZHENG; ZHU; LU, 2019)	64,32/12,45	60,77/10,42	64,01/15,97	78,92/12,48	79,19/14,58	86,08/8,34
PSD	DNN	66,97/12,13	75,00/9,45	71,05/12,43	76,99/13,41	78,94/12,40	80,56/12,35
	DBN (ZHENG; ZHU; LU, 2019)	60,05/16,66	55,03/13,88	52,79/15,38	60,68/21,31	63,42/19,66	61,90/16,65
DASM	DNN	57,01/7,23	61,91/10,56	67,82/11,67	79,01/13,57	81,85/12,17	79,59/12,15
	DBN (ZHENG; ZHU; LU, 2019)	48,79/9,62	51,59/13,98	54,03/17,05	69,51/15,22	70,06/18,14	72,73/15,93
RASM	DNN	56,68/9,05	60,81/11,02	66,89/13,58	79,2/13,62	81,73/12,16	79,08/12,25
	DBN (ZHENG; ZHU; LU, 2019)	48,05/10,37	50,62/14,02	56,15/15,28	70,31/15,62	68,22/18,09	71,30/16,16
ASM	DNN	55,33/8,25	59,97/10,46	66,96/11,82	78,35/13,00	80,14/12,38	81,19/11,50
	DBN (ZHENG; ZHU; LU, 2019)	-	-	-	-	-	-
DCAU	DNN	70,07/6,89	68,39/11,60	72,42/9,54	80,94/11,63	83,06/10,74	84,71/9,82
	DBN (ZHENG; ZHU; LU, 2019)	54,58/12,81	56,94/12,54	57,62/13,58	70,70/16,33	72,27/16,12	77,20/14,24

Fonte: Elaborada pelo autor.

cativamente o modelo DNN proposto por (ZHENG; ZHU; LU, 2019) em muitas features, conforme demonstrado na Tabela 14. Apenas na entropia diferencial o modelo proposto não foi superior. Este avanço pode ser atribuído a melhorias específicas implementadas na arquitetura da DNN, especialmente a taxa de aprendizagem do modelo obtida através um *tunning* de hiper parâmetros, destacando a importância do refinamento e adaptação de modelos existentes para alcançar resultados mais robustos e precisos. A superação do desempenho do modelo DNN anterior destaca a contribuição significativa do presente estudo para o avanço no campo da análise de emoções em sinais de EEG, promovendo um entendimento mais profundo das capacidades e limitações dessas arquiteturas em contextos específicos.

A variação nas métricas de desempenho do modelo *DGCNN* em diferentes características, como *DE* e *PSD* com acurácia inferior e *DASM*, *RASM* e *DCAU* com acurácia superior, quando comparadas a acurácia do trabalho de Song et al. (2018), pode ser atribuída às complexidades inerentes às características específicas do sinal de EEG. O comportamento do modelo pode ser influenciado pela natureza dinâmica e não linear dessas características. Para *DE* e *PSD*, que capturam informações sobre a distribuição de energia e entropia, respectivamente, a capacidade do DGCNN de modelar efetivamente essas nuances pode estar relacionada à complexidade dessas representações. Por outro lado, nas características *DASM*, *RASM* e *DCAU*, que refletem aspectos de assimetria e causalidade no sinal, o modelo proposto no presente trabalho pôde aproveitar melhor sua arquitetura para identificar padrões discriminativos. É importante ressaltar que, apesar das variações nos resultados, os valores de acurácia permanecem próximos aos do trabalho de Song et al. (2018), indicando consistência e validade nos resultados. As camadas de convolução, a taxa de aprendizagem e os parâmetros de regularização (*Weight Decay*) são os principais fatores que justificam as diferenças entre o presente trabalho e a literatura e

essas discrepâncias podem ser valiosas para entender melhor as nuances do sinal de EEG e disponibilizar informações sobre as capacidades e limitações dos modelos em diferentes contextos de análise emocional.

Tabela 15 – Comparativo de resultados com a literatura.

Feature	Modelo	δ	θ	α	β	γ	Todas as frequências
DE	LR	61,18/13,71	65,32/14,16	67,58/13,74	76,71/14,33	74,34/15,73	82,46/11,11
	KNN	55,66/13,09	58,41/13,19	60,24/16,26	69,65/15,44	70,08/16,29	75,23/13,37
	SVM	63,01/12,89	69,61/13,78	71,53/14,22	79,82/13,71	78,25/15,01	84,44/11,58
	SVM	60,50/14,14	60,95/10,20	66,64/14,41	80,76/11,56	79,56/11,38	83,99/9,72
	(ZHENG; ZHU; LU, 2019)						
	DNN	73,35/10,94	74,52/8,38	75,32/12,61	80,47/13,51	83,34/10,13	85,22/9,51
	DBN	64,32/12,45	60,77/10,42	64,01/15,97	78,92/12,48	79,19/14,58	86,08/8,34
	(ZHENG; ZHU; LU, 2019)						
	DGCNN	74,81/8,41	69,81/11,60	71,62/13,71	83,83/9,40	83,62/10,76	89,97/5,57
	DGCNN	74,25/11,42	71,52/5,99	74,43/12,16	83,65/10,17	85,73/10,64	90,40/8,49
	(SONG et al., 2018)						
PSD	LR	58,66/15,66	66,02/12,92	62,81/17,23	67,87/18,09	67,09/15,92	75,44/15,02
	KNN	52,9/14,64	60,84/14,77	56,63/16,06	62,57/16,92	61,56/20,8	69,14/16,86
	SVM	61,91/14,1	69,43/12,41	66,33/16,42	71,04/17,01	71,96/15,02	77,99/13,91
	SVM	58,03/15,39	57,26/15,09	59,04/15,75	73,34/15,20	71,24/16,38	59,60/15,93
	(ZHENG; ZHU; LU, 2019)						
	DNN	66,97/12,13	75,00/9,45	71,05/12,43	76,99/13,41	78,94/12,40	80,56/12,35
	DBN	60,05/16,66	55,03/13,88	52,79/15,38	60,68/21,31	63,42/19,66	61,90/16,65
	(ZHENG; ZHU; LU, 2019)						
	DGCNN	70,25/13,41	69,63/8,63	65,26/10,99	71,67/15,50	75,87/18,33	79,39/15,08
	DGCNN	71,23/11,42	71,20/8,99	73,45/12,25	77,45/10,81	76,60/11,83	81,73/9,94
	(SONG et al., 2018)						
DASM	LR	45,72/12,8	49,93/15,67	56,57/14,54	71,12/17,71	73,39/16,1	75,41/15,53
	KNN	44,43/11,41	43,41/13,27	49,42/15,8	64,04/17,96	67,05/16,25	65,94/17,35
	SVM	49,83/12,83	53,53/14,9	61,95/15,02	73,87/17,67	77,22/15,9	76,8/14,44
	SVM	48,87/10,49	53,02/12,76	59,81/14,67	75,03/15,72	73,59/16,57	72,81/16,57
	(ZHENG; ZHU; LU, 2019)						
	DNN	57,01/7,23	61,91/10,56	67,82/11,67	79,01/13,57	81,85/12,17	79,59/12,15
	DBN	48,79/9,62	51,59/13,98	54,03/17,05	69,51/15,22	70,06/18,14	72,73/15,93
	(ZHENG; ZHU; LU, 2019)						
	DGCNN	60,47/9,53	63,23/8,72	63,15/11,68	81,81/11,91	84,73/8,72	85,86/7,41
	DGCNN	55,93/9,14	56,12/7,86	64,27/12,72	73,61/14,35	73,50/16,6	78,45/11,84
	(SONG et al., 2018)						
RASM	LR	45,31/12,83	49,85/15,55	56,42/14,7	71,02/17,92	73,41/16,25	75,34/15,56
	KNN	43,95/11,7	43,09/13,37	49,42/15,38	64,03/17,66	67,11/16,14	66,24/17,53
	SVM	48,99/12,89	53,49/14,54	61,21/14,96	74,48/17,64	77,11/15,83	76,88/14,46
	SVM	47,75/10,59	51,40/12,53	60,71/14,57	74,59/16,18	74,61/15,57	74,74/14,79
	(ZHENG; ZHU; LU, 2019)						
	DNN	56,68/9,05	60,81/11,02	66,89/13,58	79,2/13,62	81,73/12,16	79,08/12,25
	DBN	48,05/10,37	50,62/14,02	56,15/15,28	70,31/15,62	68,22/18,09	71,30/16,16
	(ZHENG; ZHU; LU, 2019)						
	DGCNN	60,14/10,36	62,17/10,09	63,01/11,11	81,92/10,26	84,53/9,29	84,82/7,79
	DGCNN	57,79/6,90	55,79/8,10	61,58/12,63	75,79/13,07	82,32/11,54	85,00/12,47
	(SONG et al., 2018)						
ASM	LR	45,36/12,95	50,05/15,56	56,92/14,27	70,71/17,96	73,05/16,59	74,73/15,48
	KNN	44,09/11,43	43,1/12,99	49,26/15,33	63,84/18,09	67,1/15,57	66,16/17,09
	SVM	49,09/13,04	53,76/15,03	61,48/14,58	73,44/17,71	76,17/16,07	76,45/14,37
	SVM	-	-	-	-	-	-
	(ZHENG; ZHU; LU, 2019)						
	DNN	55,33/8,25	59,97/10,46	66,96/11,82	78,35/13,00	80,14/12,38	81,19/11,50
	DBN	-	-	-	-	-	-
	(ZHENG; ZHU; LU, 2019)						
	DGCNN	62,69/8,18	61,00/9,29	62,2/11,82	82,19/11,74	83,68/10,48	85,46/9,43
	DGCNN	-	-	-	-	-	-
	(SONG et al., 2018)						
DCAU	LR	53,77/15,15	55,22/15,72	60,98/14,92	72,19/17,31	73,86/17,74	80,69/11,72
	KNN	50,27/11,77	49,5/10,38	53,6/11,18	67,8/15,09	68,88/16,44	72,84/12,75
	SVM	57,49/15,75	60,16/14,62	64,77/14,3	74,9/16,34	77,67/16,85	81,43/11,62
	SVM	55,92/14,62	57,16/10,77	61,37/15,97	75,17/15,58	76,44/15,41	77,38/11,98
	(ZHENG; ZHU; LU, 2019)						
	DNN	70,07/6,89	68,39/11,60	72,42/9,54	80,94/11,63	83,06/10,74	84,71/9,82
	DBN	54,58/12,81	56,94/12,54	57,62/13,58	70,70/16,33	72,27/16,12	77,20/14,24
	(ZHENG; ZHU; LU, 2019)						
	DGCNN	71,18/10,85	67,69/10,12	67,08/8,96	81,98/9,72	82,2/9,22	89,36/8,63
	DGCNN	63,18/13,48	62,55/7,96	67,71/10,74	78,68/10,81	80,05/13,03	81,91/10,06
	(SONG et al., 2018)						

Fonte: Elaborada pelo autor.

5 Conclusões

Ao investigar as relações entre os registros de EEG e as emoções humanas por meio da aplicação de técnicas de aprendizado de máquina, este trabalho disponibiliza informações essenciais para a área da neurociência emocional, promovendo uma expansão significativa do entendimento acerca das conexões entre a atividade cerebral e estados emocionais específicos. Os resultados alcançados neste estudo estão em conformidade com os trabalhos referenciados e indicam a viabilidade e potencial de aplicação de Redes Profundas para análise de emoções em sinais de Eletroencefalografia. O potencial de aprimorar sistemas de saúde mental, permitindo diagnósticos mais precisos e tratamentos personalizados, é notável. Além disso, a possibilidade de utilizar esses modelos em interfaces cérebro-computador pode aperfeiçoar a interação humano-máquina, tornando-a mais intuitiva e eficiente.

À medida que são realizadas análises em dados sensíveis como o EEG, é essencial considerar as implicações éticas e sociais subjacentes. A utilização dessas técnicas levanta preocupações relacionadas à privacidade, segurança e potencial manipulação inadequada das informações neurofisiológicas. Portanto, é crucial abordar essas questões de maneira responsável e ética, garantindo que o uso dessas tecnologias seja benéfico e não prejudicial.

Além disso, os resultados alcançados por meio da arquitetura *GCNN* destacaram sua eficácia e superioridade em relação a outras abordagens de aprendizado de máquina em detecção de emoções a partir de EEG. Os atributos Entropia Diferencial e Causalidade Diferencial foram os atributos que obtiveram o melhor desempenho em todas as bandas de frequência para o modelo citado, alcançando uma acurácia de 89,97% e 89,36% respectivamente. O modelo *DNN* por sua vez, apresentou uma acurácia de 85,22% e 84,71% para estas *features*. Um outro resultado importante do referido modelo refere-se ao atributo *PSD* no qual obteve-se uma acurácia de 80,56%, superando o modelo *GCNN*, com acurácia de 79,39%. A partir da avaliação destes resultados é possível concluir que os modelos de aprendizado profundo, sobretudo o modelo em grafos, são viáveis para classificação de emoções e que principalmente a entropia diferencial e atributos de assimetria são os mais adequados para a correta classificação de emoções positivas, negativas e neutras.

No que diz respeito as bandas de frequência analisadas de forma individual, é notável que os valores de acurácia são maiores para as frequências β e γ . Na frequência γ , as duas maiores acurácias foram obtidas através modelo *GCNN* ao analisar os atributos de Assimetria *DASM* e *RASM*, com valores de 84,73% e 84,53%, confirmando a relevância das características assimétricas do EEG para classificação de emoções. Na frequência β os melhores resultados de acurácia também foram obtidos para o mesmo modelo, mas

desta vez para as *features* *DE* e *ASM*, com valores de 83,83% e 82,19%, o que confirma a importância de analisar as não-linearidades do sinal de EEG para a classificação de emoções. Portanto, conclui-se que além de analisar todo o espectro de frequências do sinal do EEG, a análise de bandas de frequência específicas β e γ , por exemplo, pode auxiliar a classificação de emoções em sinais de EEG.

Este trabalho não apenas demonstrou a capacidade do modelo em lidar com dados complexos e em múltiplas bandas de frequência, mas também evidenciou seu potencial para aprimorar a precisão e a robustez dessas tarefas, contribuindo assim para o panorama acadêmico e prático da detecção de emoções. A pesquisa representa uma base sólida para futuras investigações e desenvolvimentos na área. No entanto, apesar da abordagem abrangente, algumas limitações merecem consideração. A generalização dos resultados pode ser afetada pela natureza específica do conjunto de dados SEED, que consiste em estímulos audiovisuais chineses, limitando a extensão desses resultados para outras populações ou estímulos culturais. Além disso, a escolha dos atributos do sinal de EEG pode não capturar completamente a complexidade e variabilidade dos estados emocionais, destacando a necessidade contínua de pesquisa e aprimoramento das técnicas de classificação de sinais de EEG para uma detecção mais precisa de emoções.

No encerramento deste capítulo, é evidente que o presente estudo contribuiu significativamente para o campo da detecção de emoções em sinais EEG. A análise aprofundada dos resultados e a discussão sobre os principais pontos demonstram a eficácia da abordagem adotada através de *GCNN*, bem como os desafios enfrentados. Essa conclusão global fornece uma perspectiva abrangente do trabalho realizado, destacando suas contribuições para a ciência e sua aplicabilidade prática.

5.1 Trabalhos Futuros

Diante das descobertas e avanços obtidos, há várias direções futuras de pesquisa que podem ser exploradas. A investigação de diferentes arquiteturas de rede, incluindo a combinação de modelos (*Ensemble*) pode fornecer insights sobre a otimização do desempenho da *DGCNN* ou a comparação com outros modelos de aprendizado profundo. Além disso, a exploração de técnicas avançadas de processamento de sinais, como filtragem adaptativa, pode enriquecer a qualidade das características extraídas dos sinais EEG. Investigar a generalização dos modelos para diferentes populações e contextos também é um caminho importante para garantir a aplicabilidade em cenários diversos. Essas sugestões de pesquisa futura destacam o potencial contínuo deste trabalho e a busca por melhorias e inovações na área de detecção de emoções em sinais de EEG.

Referências

ABHANG, P. A.; GAWALI, B. W.; MEHROTRA, S. C. Chapter 2 - Technological Basics of EEG Recording and Operation of Apparatus. In: ABHANG, P. A.; GAWALI, B. W.; MEHROTRA, S. C. (Ed.). **Introduction to EEG- and Speech-Based Emotion Recognition**. Academic Press, 2016. p. 19–50. ISBN 978-0-12-804490-2. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128044902000026>>.

ADOLPHS, R. et al. A mechanism for impaired fear recognition after amygdala damage. **Nature**, v. 433, n. 7021, p. 68–72, jan. 2005. ISSN 1476-4687. Number: 7021 Publisher: Nature Publishing Group. Disponível em: <<https://www.nature.com/articles/nature03086>>.

AFTANAS, L. I.; GOLOCHEIKINE, S. A. Human anterior and frontal midline theta and lower alpha reflect emotionally positive state and internalized attention: high-resolution EEG investigation of meditation. **Neuroscience Letters**, v. 310, n. 1, p. 57–60, set. 2001. ISSN 0304-3940.

AHMED, M. Z. I. et al. Automated Feature Extraction on AsMap for Emotion Classification Using EEG. **Sensors**, v. 22, n. 6, p. 2346, jan. 2022. ISSN 1424-8220. Number: 6 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/22/6/2346>>.

AHMEDT-ARISTIZABAL, D. et al. Graph-Based Deep Learning for Medical Diagnosis and Analysis: Past, Present and Future. **Sensors**, v. 21, n. 14, p. 4758, jan. 2021. ISSN 1424-8220. Number: 14 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/21/14/4758>>.

ALARCAO, S. M.; FONSECA, M. J. Emotions Recognition Using EEG Signals: A Survey. **IEEE Transactions on Affective Computing**, Institute of Electrical and Electronics Engineers (IEEE), v. 10, n. 3, p. 374–393, 2019. ISSN 1949-3045. Disponível em: <<http://10.0.4.85/taffc.2017.2714671https://dx.doi.org/10.1109/TAFFC.2017.2714671>>.

ALARCAO, S. M.; FONSECA, M. J. Emotions Recognition Using EEG Signals: A Survey. **IEEE Transactions on Affective Computing**, v. 10, n. 3, p. 374–393, jul. 2019. ISSN 1949-3045, 2371-9850. Disponível em: <<https://ieeexplore.ieee.org/document/7946165/>>.

ALHALASEH, R.; ALASASFEH, S. Machine-Learning-Based Emotion Recognition System Using EEG Signals. **Computers**, v. 9, n. 4, p. 95, dez. 2020. ISSN 2073-431X. Number: 4 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/2073-431X/9/4/95>>.

AZMI, J. et al. A systematic review on machine learning approaches for cardiovascular disease prediction using medical big data. **Medical Engineering & Physics**, v. 105, p. 103825, jul. 2022. ISSN 1350-4533. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350453322000741>>.

BABAYAN, A. et al. A mind-brain-body dataset of MRI, EEG, cognition, emotion, and peripheral physiology in young and old adults. **Scientific Data**, v. 6, n. 1, p. 180308, fev.

2019. ISSN 2052-4463. Number: 1 Publisher: Nature Publishing Group. Disponível em: <<https://www.nature.com/articles/sdata2018308>>.

BALCONI, M.; VANUTELLI, M. E. Emotions and BIS/BAS components affect brain activity (ERPs and fNIRS) in observing intra-species and inter-species interactions. **Brain Imaging and Behavior**, v. 10, n. 3, p. 750–760, set. 2016. ISSN 1931-7565.

BENGIO, Y. Practical Recommendations for Gradient-Based Training of Deep Architectures. In: MONTAVON, G.; ORR, G. B.; MÜLLER, K.-R. (Ed.). **Neural Networks: Tricks of the Trade: Second Edition**. Berlin, Heidelberg: Springer, 2012, (Lecture Notes in Computer Science). p. 437–478. ISBN 978-3-642-35289-8. Disponível em: <https://doi.org/10.1007/978-3-642-35289-8_26>.

BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation Learning: A Review and New Perspectives. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 8, p. 1798–1828, ago. 2013. ISSN 1939-3539. Conference Name: IEEE Transactions on Pattern Analysis and Machine Intelligence.

BERGSTRA, J. et al. Algorithms for Hyper-Parameter Optimization. In: **Advances in Neural Information Processing Systems**. Curran Associates, Inc., 2011. v. 24. Disponível em: <https://papers.nips.cc/paper_files/paper/2011/hash/86e8f7ab32cfd12577bc2619bc635690-Abstract.html>.

BISHOP, C. **Pattern Recognition and Machine Learning**. Springer New York, 2016. (Information Science and Statistics). ISBN 978-1-4939-3843-8. Disponível em: <<https://books.google.com.br/books?id=kOXDtAEACAAJ>>.

BONDY, J.; MURTY, U. **Graph Theory with Applications**. American Elsevier Publishing Company, 1976. ISBN 978-0-444-19451-0. Disponível em: <<https://books.google.com.br/books?id=4bwrAAAAYAAJ>>.

BOTA, P. J. et al. A Review, Current Challenges, and Future Possibilities on Emotion Recognition Using Machine Learning and Physiological Signals. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 140990–141020, 2019. ISSN 2169-3536. Disponível em: <<http://10.0.4.85/access.2019.2944001https://dx.doi.org/10.1109/ACCESS.2019.2944001>>.

BRONSTEIN, M. M. et al. Geometric Deep Learning: Going beyond Euclidean data. **IEEE Signal Processing Magazine**, v. 34, n. 4, p. 18–42, jul. 2017. ISSN 1558-0792. Conference Name: IEEE Signal Processing Magazine.

BRUNA, J. et al. **Spectral Networks and Locally Connected Networks on Graphs**. arXiv, 2014. ArXiv:1312.6203 [cs]. Disponível em: <<http://arxiv.org/abs/1312.6203>>.

CAO, Y. et al. Fair and accurate age prediction using distribution aware data curation and augmentation. **2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)**, p. 2867–2877, 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9706963>>.

CHUNG, F. **Spectral Graph Theory**. Conference Board of the Mathematical Sciences, 1997. (CBMS Regional Conference Series, Nº 92). ISBN 978-0-8218-8936-7. Disponível em: <https://books.google.com.br/books?id=YUc38_MCuhAC>.

- CORREA, A. G. et al. Artifact removal from EEG signals using adaptive filters in cascade. **Journal of Physics: Conference Series**, v. 90, n. 1, p. 012081, nov. 2007. ISSN 1742-6596. Disponível em: <<https://dx.doi.org/10.1088/1742-6596/90/1/012081>>.
- DEFFERRARD, M.; BRESSON, X.; VANDERGHEYNST, P. Convolutional neural networks on graphs with fast localized spectral filtering. In: **Proceedings of the 30th International Conference on Neural Information Processing Systems**. Red Hook, NY, USA: Curran Associates Inc., 2016. (NIPS'16), p. 3844–3852. ISBN 9781510838819.
- DU, X. et al. An Efficient LSTM Network for Emotion Recognition From Multichannel EEG Signals. **IEEE Transactions on Affective Computing**, v. 13, n. 3, p. 1528–1540, jul. 2022. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.
- EKMAN, P. An argument for basic emotions. **Cognition and Emotion**, v. 6, n. 3-4, p. 169–200, maio 1992. ISSN 0269-9931. Publisher: Routledge _eprint: <https://doi.org/10.1080/02699939208411068>. Disponível em: <<https://doi.org/10.1080/02699939208411068>>.
- FAUST, O. et al. Deep learning for healthcare applications based on physiological signals: A review. **Computer Methods and Programs in Biomedicine**, Elsevier BV, v. 161, p. 1–13, 2018. ISSN 0169-2607. Disponível em: <<http://10.0.3.248/j.cmpb.2018.04.005https://dx.doi.org/10.1016/j.cmpb.2018.04.005>>.
- FENG, L. et al. EEG-Based Emotion Recognition Using Spatial-Temporal Graph Convolutional LSTM With Attention Mechanism. **IEEE Journal of Biomedical and Health Informatics**, v. 26, n. 11, p. 5406–5417, nov. 2022. ISSN 2168-2208. Conference Name: IEEE Journal of Biomedical and Health Informatics.
- FINK, M. EEG and Human Psychopharmacology. **Annual Review of Pharmacology**, v. 9, n. 1, p. 241–258, abr. 1969. ISSN 0066-4251. Publisher: Annual Reviews. Disponível em: <<https://www-annualreviews-org.ez138.periodicos.capes.gov.br/doi/10.1146/annurev.pa.09.040169.001325>>.
- GAN, L. et al. A Cross-Culture Study on Multimodal Emotion Recognition Using Deep Learning. In: GEDEON, T.; WONG, K. W.; LEE, M. (Ed.). **Neural Information Processing**. Cham: Springer International Publishing, 2019. (Communications in Computer and Information Science), p. 670–680. ISBN 978-3-030-36808-1.
- GOLDBERG, Y. **Neural Network Methods for Natural Language Processing**. Cham: Springer International Publishing, 2017. (Synthesis Lectures on Human Language Technologies). ISBN 978-3-031-01037-8 978-3-031-02165-7. Disponível em: <<https://link.springer.com/10.1007/978-3-031-02165-7>>.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. (Adaptive Computation and Machine Learning series). ISBN 978-0-262-03561-3. Disponível em: <<https://books.google.com.br/books?id=Np9SDQAAQBAJ>>.
- GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. O'Reilly Media, 2019. ISBN 978-1-4920-3261-8. Disponível em: <<https://books.google.com.br/books?id=HHetDwAAQBAJ>>.

- HAGEMANN, D. et al. The latent state-trait structure of resting EEG asymmetry: replication and extension. **Psychophysiology**, v. 42, n. 6, p. 740–752, nov. 2005. ISSN 0048-5772.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. New York, NY: Springer, 2009. (Springer Series in Statistics). ISBN 978-0-387-84857-0 978-0-387-84858-7. Disponível em: <<http://link.springer.com/10.1007/978-0-387-84858-7>>.
- HENAFF, M.; BRUNA, J.; LECUN, Y. **Deep Convolutional Networks on Graph-Structured Data**. arXiv, 2015. ArXiv:1506.05163 [cs]. Disponível em: <<http://arxiv.org/abs/1506.05163>>.
- HERNANDEZ, J. et al. AutoEmotive: bringing empathy to the driving experience to manage stress. **MIT web domain**, jun. 2014. Accepted: 2014-12-18T19:20:21Z ISBN: 9781450329033 Publisher: Association for Computing Machinery. Disponível em: <<https://dspace.mit.edu/handle/1721.1/92388>>.
- HINTON, G. E.; OSINDERO, S.; TEH, Y.-W. A fast learning algorithm for deep belief nets. **Neural Computation**, v. 18, n. 7, p. 1527–1554, jul. 2006. ISSN 0899-7667.
- JENKE, R.; PEER, A.; BUSS, M. Feature Extraction and Selection for Emotion Recognition from EEG. **IEEE Transactions on Affective Computing**, v. 5, n. 3, p. 327–339, jul. 2014. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.
- JIANG, X.; BIAN, G.-B.; TIAN, Z. Removal of Artifacts from EEG Signals: A Review. **Sensors (Basel, Switzerland)**, v. 19, n. 5, p. 987, fev. 2019. ISSN 1424-8220. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6427454/>>.
- JIN, J. et al. Correlation-based channel selection and regularized feature optimization for MI-based BCI. **Neural Networks**, v. 118, p. 262–270, 2019. ISSN 0893-6080. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0893608019301960>>.
- JIRAYUCHAROENSAK, S.; PAN-NGUM, S.; ISRASENA, P. EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation. **TheScientificWorldJournal**, v. 2014, p. 627892, 2014. ISSN 1537-744X.
- KATSIGIANNIS, S.; RAMZAN, N. DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices. **IEEE Journal of Biomedical and Health Informatics**, v. 22, n. 1, p. 98–107, jan. 2018. ISSN 2168-2208. Conference Name: IEEE Journal of Biomedical and Health Informatics.
- KIPF, T. N.; WELLING, M. **Semi-Supervised Classification with Graph Convolutional Networks**. arXiv, 2017. ArXiv:1609.02907 [cs, stat]. Disponível em: <<http://arxiv.org/abs/1609.02907>>.
- KLEM, G. H. et al. The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology. **Electroencephalography and Clinical Neurophysiology. Supplement**, v. 52, p. 3–6, 1999. ISSN 0424-8155.
- KNYAZEY, G. G. Motivation, emotion, and their inhibitory control mirrored in brain oscillations. **Neuroscience & Biobehavioral Reviews**, v. 31, n. 3, p. 377–395, jan. 2007. ISSN 0149-7634. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0149763406001163>>.

- KOELSTRA, S. et al. DEAP: A Database for Emotion Analysis ;Using Physiological Signals. **IEEE Transactions on Affective Computing**, v. 3, n. 1, p. 18–31, jan. 2012. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.
- KREIBIG, S. D. Autonomic nervous system activity in emotion: a review. **Biological Psychology**, v. 84, n. 3, p. 394–421, jul. 2010. ISSN 1873-6246.
- LAMM, C.; DECETY, J.; SINGER, T. Meta-analytic evidence for common and distinct neural networks associated with directly experienced pain and empathy for pain. **NeuroImage**, v. 54, n. 3, p. 2492–2502, fev. 2011. ISSN 1095-9572.
- LE, Q. V. et al. **Building high-level features using large scale unsupervised learning**. arXiv, 2012. ArXiv:1112.6209 [cs]. Disponível em: <<http://arxiv.org/abs/1112.6209>>.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, maio 2015. ISSN 1476-4687. Number: 7553 Publisher: Nature Publishing Group. Disponível em: <<https://www.nature.com/articles/nature14539>>.
- LEE, K. et al. Real-time seizure detection using eeg: A comprehensive comparison of recent approaches under a realistic setting. **Proceedings of the Conference on Health, Inference, and Learning**, PMLR, v. 174, p. 311–337, 07–08 Apr 2022. Disponível em: <<https://proceedings.mlr.press/v174/lee22a.html>>.
- LI, X. et al. A Deep Learning Approach for Mild Depression Recognition Based on Functional Connectivity Using Electroencephalography. **Frontiers in Neuroscience**, v. 14, 2020. ISSN 1662-453X. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fnins.2020.00192>>.
- LI, X. et al. Eeg based emotion recognition: A tutorial and review. **ACM Comput. Surv.**, Association for Computing Machinery, New York, NY, USA, v. 55, n. 4, nov 2022. ISSN 0360-0300. Disponível em: <<https://doi.org/10.1145/3524499>>.
- LI, Y. et al. A Novel Bi-Hemispheric Discrepancy Model for EEG Emotion Recognition. **IEEE Transactions on Cognitive and Developmental Systems**, v. 13, n. 2, p. 354–367, jun. 2021. ISSN 2379-8939. Conference Name: IEEE Transactions on Cognitive and Developmental Systems.
- LIN, Y.-P. et al. EEG-based emotion recognition in music listening. **IEEE transactions on bio-medical engineering**, v. 57, n. 7, p. 1798–1806, jul. 2010. ISSN 1558-2531.
- LITJENS, G. et al. A survey on deep learning in medical image analysis. **Medical Image Analysis**, v. 42, p. 60–88, dez. 2017. ISSN 1361-8423.
- LIU, W. et al. Identifying similarities and differences in emotion recognition with EEG and eye movements among Chinese, German, and French People. **Journal of Neural Engineering**, v. 19, n. 2, mar. 2022. ISSN 1741-2552.
- LIU, X.; DENG, Z.; YANG, Y. Recent progress in semantic image segmentation. **Artificial Intelligence Review**, v. 52, n. 2, p. 1089–1106, ago. 2019. ISSN 1573-7462. Disponível em: <<https://doi.org/10.1007/s10462-018-9641-3>>.

LOTTE, F. et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. **Journal of Neural Engineering**, IOP Publishing, v. 15, n. 3, p. 31005, 2018. ISSN 1741-2560. Disponível em: <<http://10.0.4.64/1741-2552/aab2f2https://dx.doi.org/10.1088/1741-2552/aab2f2>>.

LOTTE, F. et al. A review of classification algorithms for EEG-based brain-computer interfaces. **Journal of Neural Engineering**, v. 4, n. 2, p. R1–R13, jun. 2007. ISSN 1741-2560.

META AI. **PyTorch documentation — PyTorch 1.13 documentation**. 2023. Disponível em: <<https://pytorch.org/docs/1.13/>>. Acesso em: 21 jul. 2023.

MICHEL, C. M.; MURRAY, M. M. Towards the utilization of EEG as a brain imaging tool. **NeuroImage**, v. 61, n. 2, p. 371–385, jun. 2012. ISSN 1095-9572.

MONTI, F. et al. **Geometric deep learning on graphs and manifolds using mixture model CNNs**. arXiv, 2016. ArXiv:1611.08402 [cs]. Disponível em: <<http://arxiv.org/abs/1611.08402>>.

MURPHY, K. **Probabilistic Machine Learning: An Introduction**. MIT Press, 2022. (Adaptive Computation and Machine Learning series). ISBN 978-0-262-04682-4. Disponível em: <<https://books.google.com.br/books?id=wrZNEAAQBAJ>>.

MUSHA, T. et al. Feature extraction from EEGs associated with emotions. **Artificial Life and Robotics**, v. 1, n. 1, p. 15–19, mar. 1997. ISSN 1614-7456. Disponível em: <<https://doi.org/10.1007/BF02471106>>.

NEWMAN, M. **Networks: An Introduction**. OUP Oxford, 2010. ISBN 978-0-19-150070-1. Disponível em: <<https://books.google.com.br/books?id=LrFaU4XCsUoC>>.

NIEDERMEYER, E.; SILVA, F. da. **Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. Lippincott Williams & Wilkins, 2005. (LWW Doody's all reviewed collection). ISBN 9780781751261. Disponível em: <<https://books.google.com.br/books?id=tndqYGPHQdEC>>.

PARK, J. et al. An Optimized DNN Model for Real-Time Inferencing on an Embedded Device. **Sensors**, v. 23, n. 8, p. 3992, jan. 2023. ISSN 1424-8220. Number: 8 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/23/8/3992>>.

PAUL, M. **INFO-4604: Web and Cloud Data Technologies**. 2018. University of Colorado Boulder. Disponível em: <<https://cmci.colorado.edu/classes/INFO-4604/index.html>>.

PENG, H.; LONG, F.; DING, C. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. **IEEE transactions on pattern analysis and machine intelligence**, v. 27, n. 8, p. 1226–1238, ago. 2005. ISSN 0162-8828.

PHAN, K. L. et al. Functional neuroanatomy of emotion: a meta-analysis of emotion activation studies in PET and fMRI. **NeuroImage**, v. 16, n. 2, p. 331–348, jun. 2002. ISSN 1053-8119.

PHAN, T.-D.-T. et al. EEG-Based Emotion Recognition by Convolutional Neural Network with Multi-Scale Kernels. **Sensors**, v. 21, n. 15, p. 5092, jan. 2021. ISSN 1424-8220. Number: 15 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <https://www.mdpi.com/1424-8220/21/15/5092>.

PICARD, R. W. et al. Affective Learning — A Manifesto. **BT Technology Journal**, v. 22, n. 4, p. 253–269, out. 2004. ISSN 1573-1995. Disponível em: <https://doi.org/10.1023/B:BTTJ.0000047603.37042.33>.

PLUTCHIK, R. The Nature of Emotions. **American Scientist**, v. 89, p. 344, jul. 2001. ISSN 0003-0996. ADS Bibcode: 2001AmSci..89..344P. Disponível em: <https://ui.adsabs.harvard.edu/abs/2001AmSci..89..344P>.

Python.org. **Welcome to Python.org**. 2023. Disponível em: <https://www.python.org/doc/>. Acesso em: 21 jul. 2023.

RAJWAL, S.; AGGARWAL, S. Convolutional Neural Network-Based EEG Signal Analysis: A Systematic Review. **Archives of Computational Methods in Engineering**, v. 30, n. 6, p. 3585–3615, jul. 2023. ISSN 1886-1784. Disponível em: <https://doi.org/10.1007/s11831-023-09920-1>.

ROY, Y. et al. Deep learning-based electroencephalography analysis: a systematic review. **Journal of Neural Engineering**, IOP Publishing, v. 16, n. 5, p. 51001, 2019. ISSN 1741-2552. Disponível em: <http://10.0.4.64/1741-2552/ab260><https://dx.doi.org/10.1088/1741-2552/ab260>.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, out. 1986. ISSN 1476-4687. Number: 6088 Publisher: Nature Publishing Group. Disponível em: <https://www.nature.com/articles/323533a0>.

SAEED, S. M. U. et al. EEG Based Classification of Long-Term Stress Using Psychological Labeling. **Sensors**, v. 20, n. 7, p. 1886, jan. 2020. ISSN 1424-8220. Number: 7 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <https://www.mdpi.com/1424-8220/20/7/1886>.

SANEI, S.; CHAMBERS, J. **EEG Signal Processing**. Wiley, 2013. ISBN 978-1-118-69123-6. Disponível em: <https://books.google.com.br/books?id=f44hLefOz6UC>.

SCARSELLI, F. et al. The Graph Neural Network Model. **IEEE Transactions on Neural Networks**, v. 20, n. 1, p. 61–80, jan. 2009. ISSN 1941-0093. Conference Name: IEEE Transactions on Neural Networks.

SCHIRRMESTER, R. T. et al. Deep learning with convolutional neural networks for EEG decoding and visualization. **Human Brain Mapping**, v. 38, n. 11, p. 5391–5420, nov. 2017. ISSN 1065-9471. Publisher: John Wiley & Sons, Ltd. Disponível em: <https://onlinelibrary-wiley.ez138.periodicos.capes.gov.br/doi/10.1002/hbm.23730>.

SCHMIDHUBER, J. Deep Learning in Neural Networks: An Overview. **Neural Networks**, v. 61, p. 85–117, jan. 2015. ISSN 08936080. ArXiv:1404.7828 [cs]. Disponível em: <http://arxiv.org/abs/1404.7828>.

- SCHOMER, D. L.; SILVA, F. H. Lopes da. **Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. Oxford University Press, 2017. ISBN 9780190228484. Disponível em: <<https://doi.org/10.1093/med/9780190228484.001.0001>>.
- SCHÖLKOPF, B. et al. Estimating the support of a high-dimensional distribution. **Neural Computation**, v. 13, n. 7, p. 1443–1471, jul. 2001. ISSN 0899-7667.
- SCIKIT-LEARN.org. **scikit-learn: machine learning in Python documentation**. 2023. Disponível em: <<https://scikit-learn.org/dev/index.html>>. Acesso em: 21 jul. 2023.
- SHU, L. et al. A Review of Emotion Recognition Using Physiological Signals. **Sensors**, v. 18, n. 7, p. 2074, jul. 2018. ISSN 1424-8220. Number: 7 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/18/7/2074>>.
- SOLEYMANI, M. et al. A Multimodal Database for Affect Recognition and Implicit Tagging. **IEEE Transactions on Affective Computing**, v. 3, n. 1, p. 42–55, jan. 2012. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.
- SONG, T. et al. Graph-Embedded Convolutional Neural Network for Image-Based EEG Emotion Recognition. **IEEE Transactions on Emerging Topics in Computing**, v. 10, n. 3, p. 1399–1413, jul. 2022. ISSN 2168-6750. Conference Name: IEEE Transactions on Emerging Topics in Computing.
- SONG, T. et al. EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks. **IEEE Transactions on Affective Computing**, v. 11, n. 3, p. 532–541, jul. 2018. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.
- TORRES, E. P. et al. EEG-Based BCI Emotion Recognition: A Survey. **Sensors**, v. 20, n. 18, p. 5083, jan. 2020. ISSN 1424-8220. Number: 18 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/20/18/5083>>.
- TOĞAÇAR, M.; ERGEN, B.; CÖMERT, Z. Detection of lung cancer on chest CT images using minimum redundancy maximum relevance feature selection method with convolutional neural networks. **Biocybernetics and Biomedical Engineering**, v. 40, n. 1, p. 23–39, 2020. ISSN 0208-5216. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0208521619304759>>.
- VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York, NY: Springer, 2000. ISBN 978-1-4419-3160-3 978-1-4757-3264-1. Disponível em: <<http://link.springer.com/10.1007/978-1-4757-3264-1>>.
- VIGÁRIO, R. N. Extraction of ocular artefacts from EEG using independent component analysis. **Electroencephalography and Clinical Neurophysiology**, v. 103, n. 3, p. 395–404, set. 1997. ISSN 0013-4694. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0013469497000428>>.
- WANG, J.; WANG, M. Review of the emotional feature extraction and classification using EEG signals. **Cognitive Robotics**, v. 1, p. 29–40, jan. 2021. ISSN 2667-2413. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2667241321000033>>.
- WANG, X. et al. Deep learning-based EEG emotion recognition: Current trends and future perspectives. **Frontiers in Psychology**, v. 14, 2023. ISSN 1664-1078. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpsyg.2023.1126994>>.

- WANG, X.-h. et al. EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks and Broad Learning System. **2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)**, p. 1240–1244, 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8621147>>.
- WANG, X.-W.; NIE, D.; LU, B.-L. Emotional state classification from EEG data using machine learning approach. **Neurocomputing**, v. 129, p. 94–106, abr. 2014. ISSN 0925-2312. Publisher: Elsevier. Disponível em: <<https://www.sciencedirect.ez138.periodicos.capes.gov.br/science/article/pii/S0925231213009867>>.
- WU, S.-Y. et al. Neural patterns between Chinese and Germans for EEG-based emotion recognition. In: **2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)**. [S.l.: s.n.], 2017. p. 94–97. ISSN: 1948-3554.
- YANG, F. et al. Multi-method Fusion of Cross-Subject Emotion Recognition Based on High-Dimensional EEG Features. **Frontiers in Computational Neuroscience**, v. 13, 2019. ISSN 1662-5188. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fncom.2019.00053>>.
- YONGQIANG, Y. EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM. **Applied Soft Computing**, v. 100, p. 106954, mar. 2021. ISSN 1568-4946. Publisher: Elsevier. Disponível em: <<https://www.sciencedirect.ez138.periodicos.capes.gov.br/science/article/pii/S1568494620308929>>.
- ZHANG, D. et al. Cascade and Parallel Convolutional Recurrent Neural Networks on EEG-based Intention Recognition for Brain Computer Interface. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 32, n. 1, abr. 2018. ISSN 2374-3468. Number: 1. Disponível em: <<https://ojs.aaai.org/index.php/AAAI/article/view/11496>>.
- ZHANG, F. A hybrid structured deep neural network with Word2Vec for construction accident causes classification. **International Journal of Construction Management**, v. 22, n. 6, p. 1120–1140, abr. 2022. ISSN 1562-3599. Publisher: Taylor & Francis. Disponível em: <<https://www.tandfonline.ez138.periodicos.capes.gov.br/doi/full/10.1080/15623599.2019.1683692>>.
- ZHANG, G. et al. SparseDGCNN: Recognizing Emotion From Multichannel EEG Signals. **IEEE Transactions on Affective Computing**, v. 14, n. 1, p. 537–548, jan. 2023. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.
- ZHANG, J. et al. An EEG/EMG/EOG-based multimodal human-machine interface to real-time control of a soft robot hand. **Frontiers in Neurorobotics**, v. 13, n. March, 2019. ISSN 16625218.
- ZHANG, J. et al. Emotion recognition using multi-modal data and machine learning techniques: A tutorial and review. **Information Fusion**, Elsevier B.V., v. 59, n. March 2019, p. 103–126, 2020. ISSN 15662535. Disponível em: <<https://doi.org/10.1016/j.inffus.2020.01.011>>.
- ZHANG, T. et al. GCB-Net: Graph Convolutional Broad Network and Its Application in Emotion Recognition. **IEEE Transactions on Affective Computing**, v. 13, n. 1, p. 379–388, jan. 2022. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.

ZHANG, T. et al. Spatial–Temporal Recurrent Neural Network for Emotion Recognition. **IEEE Transactions on Cybernetics**, v. 49, n. 3, p. 839–847, mar. 2019. ISSN 2168-2275. Conference Name: IEEE Transactions on Cybernetics.

ZHENG, W.-L.; LU, B.-L. Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks. **IEEE Transactions on Autonomous Mental Development**, v. 7, n. 3, p. 162–175, set. 2015. ISSN 1943-0612. Conference Name: IEEE Transactions on Autonomous Mental Development.

ZHENG, W.-L.; ZHU, J.-Y.; LU, B.-L. Identifying Stable Patterns over Time for Emotion Recognition from EEG. **IEEE Transactions on Affective Computing**, v. 10, n. 3, p. 417–429, jul. 2019. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.

ZHONG, P.; WANG, D.; MIAO, C. EEG-Based Emotion Recognition Using Regularized Graph Neural Networks. **IEEE Transactions on Affective Computing**, v. 13, n. 3, p. 1290–1301, jul. 2022. ISSN 1949-3045. Conference Name: IEEE Transactions on Affective Computing.

ZHOU, Y. et al. Progressive graph convolution network for EEG emotion recognition. **Neurocomputing**, v. 544, p. 126262, 2023. ISSN 0925-2312. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0925231223003855>.