



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA

LUCAS DE OLIVEIRA SANTOS

ANÁLISE DE GRAFOS EM SINAIS DE EEG PARA IDENTIFICAÇÃO DO
TRANSTORNO DEPRESSIVO MAIOR

FORTALEZA

2025

LUCAS DE OLIVEIRA SANTOS

ANÁLISE DE GRAFOS EM SINAIS DE EEG PARA IDENTIFICAÇÃO DO TRANSTORNO
DEPRESSIVO MAIOR

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Sistemas de Energia Elétrica

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Coorientador: Prof. Dr. Aldisio Gonçalves Medeiros

FORTALEZA

2025

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

- S236a Santos, Lucas de Oliveira.
Análise de Grafos em sinais de EEG para identificação do Transtorno Depressivo Maior / Lucas de Oliveira Santos. – 2025.
64 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2025.
Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.
Coorientação: Prof. Dr. Aldisio Gonçalves Medeiros.
1. Teoria dos Grafos. 2. Transtorno Depressivo Maior;. 3. Eletroencefalograma. 4. Redes Neurais Convolucionais. 5. Transferência de Aprendizado. I. Título.

CDD 621.3

À minha esposa Daniele e aos meus pais, Francisco Erinaldo e Maria Pastora.

AGRADECIMENTOS

A Deus, por derramar graça e misericórdia na minha vida sem absolutamente nenhum merecimento. A Ele seja a glória para sempre;

À minha esposa, Daniele Araújo, que deixa os meus dias mais alegres. Agradeço pelo seu apoio diário, pela família que estamos construindo e pelo amor que você faz questão de demonstrar por mim todos os dias;

Aos meus pais, Francisco Erinaldo e Maria Pastora, por todo o sacrifício que me ofereceram com tanto carinho ao longo da minha vida, e pelo simples desejo de me amar. Jamais os esquecerei;

À minha irmã, Nayara e meu cunhado Israel Lopes, por todo apoio e incentivo. Também aos meus pequenos sobrinhos, Yohan e Yan Lopes que tem me proporcionado alegria em tempos de preocupação;

Ao meu primo Igor pelo incentivo e ajuda prestados;

Aos meus amigos de infância Sávio e Kayo pela convivência e incentivo prestados;

Ao Prof. Dr. Pedro Pedrosa, pelo constante incentivo acadêmico e pelas valiosas orientações ao longo desses seis anos de convivência;

Ao Prof. Dr. Aldísio Gonçalves Medeiros, por sua parceria em pesquisas, valiosos conselhos, apoio incansável, contribuições científicas e, acima de tudo, pela amizade;

Aos amigos de laboratório Matheus, Iágson e Solon, pelo incentivo e ajuda concedidos;

Finalmente, ao grupo LAPISCO, minha segunda casa, onde tive a oportunidade de crescer academicamente ao longo dessa jornada.

“Em seu coração o homem planeja o seu caminho,
mas o Senhor determina os seus passos.”

(Provérbios 16:9)

RESUMO

Neste trabalho é proposta uma metodologia baseada na teoria dos grafos para representar sinais de pacientes com Transtorno Depressivo Maior para classificação de amostras em doentes e saudáveis. A abordagem é baseada na representação do sinal produzido pelo paciente em um grafo direcionado, também conhecido como digrafo. Para modelar os diferentes níveis de coeficientes de magnitude e transições foram empregadas análises de marcadores espectrais oriundos do sinal. A representação em digrafos é analisada sob três matrizes (Adjacência, Laplaciana e Laplaciana Combinatória Direcionada). Essa estrutura fomenta o uso de redes neurais convolucionais e técnicas como transferência de aprendizado, uma vez que as matrizes são representadas em formato tensorial. A metodologia foi avaliada em amostras de pacientes reais utilizando sinais de Eletroencefalograma e demonstrou resultados promissores quanto a extração de características relevantes para a classificação de amostras. Os experimentos demonstraram que os tensores espectrais propostos alcançaram um desempenho superior a 91% em todas as tarefas de classificação no Dataset I e acima de 95% no Dataset II. Além disso, a integração desses tensores com a arquitetura ResNet mostrou-se altamente eficaz, evidenciando a capacidade do modelo de se adaptar bem a essa abordagem.

Palavras-chave: Teoria dos Grafos; Transtorno Depressivo Maior; Eletroencefalograma; Redes Neurais Convolucionais; Transferência de Aprendizado.

ABSTRACT

This work introduces a methodology based on graph theory to represent signals from patients with Major Depressive Disorder (MDD) for classifying samples as healthy or diseased. The approach revolves around representing the signal produced by the patient in a directed graph, also known as a digraph. Spectral markers derived from the signal model show the different magnitude coefficients and transition levels. The digraph representation involves three matrices (Adjacency, Laplacian, and Directed Combinatorial Laplacian). This structure encourages convolutional neural networks and techniques such as transfer learning, as the matrices take the form of tensors. The methodology uses actual patient samples with electroencephalogram (EEG) signals and shows promising results in extracting relevant features for sample classification. The experiments reveal that the proposed spectral tensors achieve performance exceeding 91% in all classification tasks analyzed for Dataset I and over 95% for Dataset II. Additionally, integrating the spectral tensors with the ResNet architecture proves highly effective, highlighting the model's ability to adapt well to this approach.

Keywords: Graph Theory; Major Depressive Disorder; Electroencephalogram; Convolutional Neural Networks; Transfer Learning.

LISTA DE FIGURAS

Figura 1 – Matriz de confusão, apresentando os diferentes valores de verdadeiros positivos, falsos positivos, falsos negativos e verdadeiros negativos.	28
Figura 2 – O marcador espectral delta (δ). Este marcador é composto pelos coeficientes de magnitude que ocorrem nos pontos de inflexão	32
Figura 3 – Grafo direcionado <i>DG</i> construído a partir do marcador δ	33
Figura 4 – Fluxograma da metodologia proposta.	34
Figura 5 – Localização dos eletrodos Fp1, Fpz e Fp2 no córtex pré-frontal, área associada a processos emocionais e transtornos psiquiátricos, como o TDM, processados no estudo com dados MODMA.	39
Figura 6 – Fluxo de processamento da metodologia proposta.	41
Figura 7 – Representação do sinal em seus coeficientes de magnitude para a estrutura do grafo direcionado no dataset I.	42
Figura 8 – Representação do sinal em seus coeficientes de magnitude para a estrutura do grafo direcionado no dataset II.	43
Figura 9 – Resultado do p-valor no teste t para a discriminação entre os grupos TDM e CS no dataset I, considerando as seguintes representações: Matriz de Adjacência (A), Matriz Laplaciana (L), Matriz Laplaciana Combinatória (CL) e Matriz Laplaciana Combinatória Direcionada (DL).	45
Figura 10 – Resultado do p-valor no teste t para a discriminação entre os grupos TDM e CS no dataset II, considerando as seguintes representações: Matriz de Adjacência (A), Matriz Laplaciana (L), Matriz Laplaciana Combinatória (CL) e Matriz Laplaciana Combinatória Direcionada (DL).	46
Figura 11 – Análise comparativa das métricas de avaliação utilizando diferentes métodos no Dataset I.	47
Figura 12 – Análise comparativa da métrica de Acurácia utilizando diferentes métodos no Dataset II.	55

LISTA DE TABELAS

Tabela 1 – Detalhamento dos autores, amostras utilizadas, classificadores empregados e metodologias adotadas nos estudos analisados.	20
Tabela 2 – Resultados para o melhor desempenho do método processado, comparado a métodos de ponta, em amostras dos conjuntos de dados I e II, para a classificação do TDM em relação a pacientes saudáveis.	50
Tabela 3 – Tempos de treino e teste do método proposto para as amostras dos <i>datasets</i> I e II.	53

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Cenário	13
1.2	Motivação	15
1.3	Trabalhos relacionados	16
1.3.1	<i>Abordagens relacionadas ao Transtorno Depressivo Maior</i>	17
1.4	Objetivos	20
1.4.1	<i>Objetivos Específicos</i>	21
1.5	Produção científica	21
1.6	Organização da Dissertação	22
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Grafos e Digrafos na modelagem de características cerebrais	23
2.1.1	<i>Matrizes de representação de grafos</i>	23
2.1.2	<i>Aplicação de Redes Neurais na análise de EEG</i>	24
2.2	Transformada Discreta de Fourier (DFT)	24
2.3	Redes Neurais Artificiais	25
2.3.1	<i>Rede neural residual (ResNet)</i>	26
2.4	Avaliação de desempenho	26
2.4.1	<i>O Teste t de Student</i>	26
2.4.2	<i>Avaliação do Modelo de Classificação</i>	28
2.4.3	<i>Conclusão do Capítulo</i>	29
3	MODELAGEM ESPECTRAL E APRENDIZADO PROFUNDO NA DETECÇÃO DO TRANSTORNO DEPRESSIVO MAIOR: A METO- DOLOGIA	30
3.1	Aplicação da DFT nos sinais de EEG	30
3.2	Marcadores de componentes espectrais	31
3.3	Representação dos marcadores espectrais utilizando Digrafo	32
3.3.1	<i>Processamento dos sinais de EEG</i>	33
3.3.1.1	<i>Construção de tensores a partir de digrafos para classificação</i>	35
3.4	Conclusão do Capítulo	35

4	CLASSIFICAÇÃO DE AMOSTRAS DE PACIENTES COM TRANSTORNO DEPRESSIVO MAIOR VIA SINAIS DE EEG.	37
4.1	O Transtorno Depressivo Maior	37
4.2	Trabalhos relacionados	38
4.3	Amostras de pacientes	38
4.3.1	<i>Dataset I</i>	38
4.3.2	<i>Dataset II</i>	39
4.4	Metodologia	40
4.4.1	<i>Análise da distribuição dos dados</i>	42
4.4.1.1	<i>Dataset I</i>	42
4.4.1.2	<i>Dataset II</i>	43
4.4.2	<i>Métricas de avaliação e configuração experimental</i>	44
4.5	Resultados e discussão	44
4.5.1	<i>Aplicação do teste t</i>	45
4.5.2	<i>Análise de resultados para o dataset I</i>	46
4.5.3	<i>Análise de resultados para o dataset II</i>	49
4.6	Conclusões do capítulo	55
5	CONCLUSÕES E TRABALHOS FUTUROS	57
5.0.1	<i>Trabalhos Futuros</i>	58
	REFERÊNCIAS	60

1 INTRODUÇÃO

Este trabalho propõe uma metodologia para a classificação do Transtorno Depressivo Maior (TDM) por meio de um descritor de características baseado em grafos direcionados, aliado à rede neural ResNet. A abordagem consiste no processamento de sinais de eletroencefalograma (EEG) para identificar padrões característicos do transtorno. Neste contexto, este capítulo apresenta uma visão geral da área, discute as motivações e os objetivos da pesquisa e, por fim, destaca os avanços obtidos por estudos científicos recentes.

1.1 Cenário

De acordo com a Organização Mundial da Saúde (OMS) (ORGANIZATION *et al.*, 2017), o Transtorno Depressivo Maior (ou depressão) afeta aproximadamente 4,4% da população ao redor do mundo, totalizando cerca de 322 milhões de pessoas. Além disso, o transtorno é mais frequente entre mulheres (5,1%) do que entre homens (3,6%). Nesse sentido, entre 2005 e 2015, houve um crescimento de 18,4% no número de indivíduos diagnosticados com a doença, especialmente em países de baixa renda (ORGANIZATION *et al.*, 2017). Esse aumento está relacionado tanto ao crescimento populacional quanto à maior vulnerabilidade de certos grupos, como os idosos.

Segundo Keppe e Prado (2022), a depressão é amplamente reconhecida como uma das doenças mais incapacitantes da atualidade. Projeções da OMS indicam que, até 2030, esse transtorno será a principal causa de incapacidade em nível global, superando outras condições crônicas e impactando significativamente a qualidade de vida da população. Além disso, a depressão está entre os principais fatores responsáveis pela carga global de doenças, afetando milhões de pessoas e resultando em prejuízos substanciais para os sistemas de saúde e a economia (ESTATÍSTICA, 2020). O impacto desse transtorno é evidente nas limitações ocupacionais, nas dificuldades de funcionamento diário e na qualidade de vida dos indivíduos, configurando-se como um dos maiores desafios de saúde pública no século XXI.

No Brasil, estima-se que 11,5 milhões de pessoas sofram de depressão, o que representa 5,8% da população nacional, conforme aponta Keppe e Prado (2022). No entanto, esse número pode estar subestimado, já que muitos casos não são identificados por médicos que não atuam na área da psiquiatria. Além disso, segundo a Pesquisa Nacional de Saúde (ESTATÍSTICA, 2020), 78% dos indivíduos com sintomas depressivos relevantes não recebem

tratamento especializado, o que favorece a evolução da doença para quadros crônicos e contribui para o aumento progressivo da prevalência.

Estima-se que 10,2% da população adulta tenha sido diagnosticada com Transtorno Depressivo Maior (TDM) por profissionais de saúde mental, o que equivale a aproximadamente 16,3 milhões de pessoas. As regiões Sul e Sudeste do Brasil apresentam as maiores taxas de diagnóstico, com 15,2% e 11,5%, respectivamente, conforme dados da Pesquisa Nacional da Sapude (ESTATÍSTICA, 2020). Esses números refletem a crescente identificação do transtorno, mas também revelam que ainda há desafios na efetiva detecção, especialmente em áreas com menor acesso a profissionais especializados. A depressão continua a ser subnotificada, o que agrava os impactos desse transtorno. Nesse contexto, o diagnóstico precoce se torna um fator crucial para a melhoria do tratamento e qualidade de vida dos pacientes.

Nesse sentido, diversas pesquisas foram realizadas objetivando métodos de diagnósticos automatizados, sobretudo unindo conhecimentos da neurociência com a grande área da Inteligência Artificial (IA). Sob essa perspectiva, a IA vem ganhando destaque e tem se tornado bastante promissora, dada a capacidade que ela tem de aplicar algoritmos de aprendizado de máquina profundo para identificar padrões que caracterizam transtornos como a depressão e outros mais. Dessa forma, estudos como os de Elnaggar *et al.* (2025), Park *et al.* (2024) e Vasha *et al.* (2023) evidenciaram a eficiência desses algoritmos de IA na detecção da depressão.

O EEG tem se mostrado uma ferramenta crucial na obtenção de dados essenciais para o diagnóstico de condições neurológicas, incluindo transtornos psiquiátricos como a depressão. De acordo com Stam *et al.* (2007), os padrões elétricos do cérebro podem oferecer insights valiosos sobre o funcionamento neural, revelando características específicas associadas a diferentes condições. Estudos como o de Parihar e Swami (2023) destacam a alta sensibilidade do EEG na identificação precoce de alterações elétricas cerebrais, o que facilita intervenções rápidas e mais eficazes. Além disso, Gauthier *et al.* (2013) apontam que a aplicação de algoritmos de aprendizado de máquina no processamento desses sinais tem o potencial de aprimorar o diagnóstico automatizado, possibilitando a análise de padrões complexos que muitas vezes passam despercebidos, melhorando a precisão e a velocidade do diagnóstico.

Nesse sentido, a extração de características e a identificação de padrões nos sinais de EEG são cruciais para uma detecção precisa da depressão. Dessa forma, o EEG fornece informações detalhadas sobre a atividade elétrica do cérebro, e a análise dessas informações permite identificar alterações sutis que podem estar associadas ao transtorno. Logo, ao extrair

características relevantes dos sinais, como frequência, amplitude e regularidade das ondas cerebrais, é possível detectar padrões específicos que indicam a presença de depressão. Portanto, a identificação eficaz desses padrões é essencial para a diferenciação da depressão de outras condições neurológicas, além de permitir um diagnóstico mais precoce e uma intervenção terapêutica mais assertiva. A utilização de métodos automatizados para a análise desses padrões aumenta a precisão e a eficiência do diagnóstico, facilitando uma resposta clínica mais rápida e adequada.

Considerando o exposto, este trabalho propõe uma abordagem inovadora para a classificação do Transtorno Depressivo Maior, baseada no uso de grafos direcionados para descrever as características dos sinais de EEG, com foco nas componentes espectrais que os compõem. Essa metodologia visa capturar de maneira mais precisa as nuances das variações elétricas cerebrais associadas ao transtorno. Além disso, é proposta a utilização da rede neural ResNet para a etapa de classificação, com o objetivo de distinguir de forma eficiente as amostras de pacientes com e sem o transtorno, aproveitando a capacidade da rede em aprender representações complexas e realizar a categorização das condições clínicas.

Sob essa perspectiva, o objetivo deste estudo é ampliar as abordagens de análise dos sinais de EEG em pacientes com depressão, aprimorando a classificação entre indivíduos saudáveis e aqueles acometidos pelo transtorno, com o propósito de fomentar o progresso dessa área de pesquisa.

1.2 Motivação

Diversas pesquisas têm demonstrado uma relação significativa entre depressão e mortalidade na população idosa. A revisão conduzida por Schulz *et al.* (2002), ao analisar 61 estudos publicados entre 1997 e 2001, identificou que 72% desses trabalhos apontaram uma associação positiva entre os dois fatores (SCHULZ *et al.*, 2002). Da mesma forma, Gilman *et al.* (2017) avaliaram 23 estudos focados na mortalidade associada à depressão em indivíduos com mais de 65 anos e concluíram que a chance de óbito era 1,75 vezes maior entre aqueles diagnosticados com a condição. Evidências desses estudos indicam que tanto a intensidade quanto a persistência dos sintomas depressivos influenciam significativamente os índices de mortalidade nessa faixa etária (GILMAN *et al.*, 2017).

Dessa forma, Gilman *et al.* (2017) analisaram os impactos de longo prazo da depressão sobre a mortalidade, revelando que, apesar do risco de morte diminuir ao longo do tempo

em alguns casos, a recorrência de episódios depressivos mantém esse risco elevado. O estudo também destacou a presença de vieses positivos e negativos na análise dos dados.

Diante do aumento da mortalidade relacionada à depressão na população idosa e dos avanços recentes na literatura científica, torna-se essencial explorar novas abordagens para monitoramento e predição de riscos. Métodos baseados em inteligência artificial vêm se destacando como ferramentas promissoras na análise de grandes volumes de dados, permitindo a identificação de padrões sutis que poderiam passar despercebidos em estudos tradicionais. Modelos preditivos alimentados por descritores de características extraídas de exames clínicos e avaliações comportamentais podem contribuir para a detecção precoce de fatores de risco, auxiliando profissionais de saúde na tomada de decisões mais assertivas.

Nesse contexto, o eletroencefalograma se apresenta como uma opção não invasiva e acessível para avaliação da atividade cerebral em pacientes idosos. Com o avanço das técnicas de aprendizado de máquina, é possível processar sinais elétricos do cérebro para identificar padrões associados à depressão e ao risco aumentado de mortalidade. A integração do EEG com algoritmos de inteligência artificial pode fornecer insights valiosos sobre alterações neurológicas relacionadas à doença, possibilitando intervenções mais eficazes e personalizadas.

Essas abordagens tecnológicas têm o potencial de transformar o monitoramento da saúde mental, permitindo uma avaliação mais detalhada da progressão da depressão e de seus impactos no organismo. A combinação de inteligência artificial com exames como o EEG pode melhorar a precisão no diagnóstico, auxiliar no acompanhamento da evolução dos sintomas e possibilitar intervenções mais rápidas e personalizadas, ampliando as opções de cuidado para a população idosa.

1.3 Trabalhos relacionados

O diagnóstico do Transtorno Depressivo Maior tem se beneficiado de avanços significativos no processamento de sinais biomédicos, permitindo a identificação de padrões associados à atividade cerebral. Pesquisas têm explorado diversas metodologias para a extração de atributos relevantes, empregando técnicas sofisticadas para desvendar características que possam apoiar uma avaliação clínica mais precisa. Nesta seção, serão discutidos estudos que oferecem contribuições relevantes para o entendimento desses sinais e para o aprimoramento das estratégias de diagnóstico precoce do TDM.

1.3.1 Abordagens relacionadas ao Transtorno Depressivo Maior

Pesquisadores têm dedicado esforços significativos ao desenvolvimento de sistemas automatizados avançados para a detecção do Transtorno Depressivo Maior com base em sinais de eletroencefalograma. Essas técnicas buscam aprimorar tanto a precisão quanto a eficiência do diagnóstico, utilizando métodos inovadores de análise de sinais cerebrais.

Nesse contexto, Kaya e Tasci (2023) empregaram uma CNN com aprendizado por transferência para a classificação do Transtorno Depressivo Maior. O estudo, publicado no *Turkish Journal of Science and Technology*, utilizou sinais de EEG para diagnosticar o TDM. Trabalhando com o conjunto de dados MODMA, que contém sinais de EEG de pacientes com TDM e controles saudáveis (CS), os autores usaram a ResNet18 CNN para extração de características e o algoritmo ReliefF para seleção de características. Com um classificador KNN, alcançaram uma precisão média de 89,86%.

Já o trabalho de Pratiwi (2023a) realizou uma análise comparativa de sinais de EEG na região do córtex pré-frontal para detectar depressão, utilizando redes Long Short-Term Memory (LSTM). O estudo avaliou as ondas Alpha, Beta, Theta, Delta e Gamma, explorando três grupos de características: lineares, não lineares e a combinação de ambas, destacando a relevância do EEG como recurso para estudos sobre transtornos mentais.

Os resultados destacaram a combinação de características lineares e não lineares, sendo que a integração de características Theta alcançou a maior precisão, com 83,74%, utilizando o classificador LSTM nas ondas Theta (4-8 Hz). Com o avanço contínuo da área, esforços interdisciplinares como esses conectam a neurociência à inteligência artificial, criando novas possibilidades para promover o bem-estar mental globalmente.

No contexto de pesquisas correlatas, Soni *et al.* (2022) propuseram uma metodologia baseada em aprendizado de representação gráfica para a detecção automática de depressão a partir de sinais de EEG. A abordagem começa com a construção de um grafo, onde os nós representam os sujeitos e as arestas, com pesos calculados pela distância euclidiana, refletem as relações entre eles. O algoritmo Node2vec é aplicado para gerar embeddings dos nós, que são usados diretamente por algoritmos de classificação, eliminando a necessidade de extração manual de características. Entre os classificadores testados, o KNN apresentou os melhores resultados.

A metodologia também inclui três tipos de fusão das características extraídas dos canais do EEG: fusão no nível do grafo, fusão no nível das características e fusão no nível da

decisão. Os autores aplicaram essa abordagem em um conjunto de dados com 3 canais de EEG, utilizando os embeddings gerados pelo Node2vec como características para a classificação. Com essa configuração, o modelo alcançou uma precisão média de 82,30% nas métricas de avaliação.

Por outro lado, Mumtaz *et al.* (2017) propuseram um método de aprendizado de máquina para prever a resposta ao tratamento de pacientes diagnosticados com TDM usando dados de EEG. A matriz de dados de EEG foi construída a partir da decomposição de tempo-frequência com transformada wavelet (WT), e a redução de dimensionalidade foi realizada com base em um critério de seleção de características, como a característica operacional do receptor (ROC). As características mais significativas foram então usadas para treinar um modelo de regressão logística (LR), validado com 100 iterações de validação cruzada de 10 vezes (10-CV).

Além disso, os resultados indicaram que a análise baseada em WT teve o melhor desempenho em comparação com outras abordagens de tempo-frequência, como a transformada de Fourier de curta duração (STFT) e a decomposição de modo empírico (EMD), alcançando uma acurácia de 87,5%. O estudo demonstrou que os coeficientes wavelet extraídos de dados de EEG frontal e temporal, especialmente nas bandas de frequência delta e teta, podem ser usados para prever o resultado do tratamento com antidepressivos para pacientes com TDM.

Já o trabalho proposto por Mahato e Paul (2019) analisa a utilização de sinais de EEG para classificar pacientes com TDM e indivíduos saudáveis, empregando características lineares e não lineares. As principais características consideradas incluem a potência das bandas de frequência, como a alfa e a teta, e a assimetria inter-hemisférica, além de características não lineares como a Entropia de Amplitude de Onda (RWE) e a Entropia de Onda (WE). O estudo também investigou a combinação dessas características lineares e não lineares para avaliar seu impacto na acurácia da classificação, utilizando os classificadores MLPNN, RBFN, LDA e QDA.

Dessa forma, o estudo demonstrou que, ao combinar características lineares e não lineares, os classificadores MLPNN, RBFN e LDA apresentaram os melhores resultados do trabalho, com uma acurácia de 93,33%. Sob essa perspectiva, o classificador LDA obteve um valor de acurácia de 93,33% usando a combinação das características RWE e WE. Em contrapartida, na análise das bandas de potência, o LDA obteve uma acurácia de 71,67% para a assimetria teta e 73,33% para a assimetria alfa. Já o classificador QDA alcançou uma acurácia de 71,67% para a assimetria alfa e 71,67% para a assimetria teta. As características não lineares, como RWE e WE, apresentaram um melhor desempenho quando usadas com LDA e QDA.

De maneira similar, o estudo feito por Mahato e Paul (2020) propôs uma metodologia

de classificação baseada na potência das bandas alfa, theta, delta e beta, com foco na combinação da potência da banda alfa2 e a assimetria theta para distinguir pacientes com depressão de indivíduos normais. A pesquisa utilizou uma validação cruzada de 10 vezes para testar o desempenho dos classificadores. A partir dos dados, os autores utilizaram os classificadores: Regressão Logística (LR), Máquinas de Vetores de Suporte (SVM), Naive Bayes (NB) e Árvore de Decisão (DT).

Nesse aspecto, os classificadores foram avaliados para cada conjunto de características extraídas dos sinais EEG dos participantes. Entretanto, o classificador SVM foi o que apresentou o melhor desempenho em todos os testes realizados, atingindo 88,33% de acurácia na combinação da potência alfa2 e a assimetria theta. Além disso, a pesquisa aponta que a escolha do classificador e a combinação das características influenciam diretamente a precisão da classificação entre os grupos de TDM e os indivíduos saudáveis.

Semelhantemente, a pesquisa desenvolvida por Saeedi *et al.* (2021) propõe o uso de métodos de conectividade cerebral efetiva, como GPDC (Generalized Partial Directed Coherence) e dDTF (directed Transfer Function), em combinação com redes neurais profundas para a detecção automatizada de pacientes com depressão e controles saudáveis. A metodologia envolve a transformação dos sinais EEG em imagens de conectividade cerebral, que são então alimentadas em uma arquitetura de rede neural. O modelo de aprendizado profundo utilizado combina CNN com o LSTM para explorar tanto as características espaciais quanto temporais dos dados.

Além disso, o tempo de treinamento variou entre os modelos, impactando os resultados obtidos. O modelo CNN 1D-LSTM, treinado por 100 épocas, alcançou uma acurácia de 99,24% e exigiu mais de 400 segundos para ser treinado. O CNN 2D-LSTM, com 150 épocas, obteve uma acurácia de 96,41% e um tempo de treinamento de 296 segundos. O modelo LSTM, por sua vez, foi treinado por 60 épocas, com acurácia de 89,06%, e demandou 3253 segundos para o treinamento. As versões 1D e 2D do modelo CNN, com 50 e 100 épocas, respectivamente, alcançaram acurácias de 95,29% e 96,23%, com tempos de treinamento de 1030 e 262 segundos.

Por fim, o modelo proposto por Mohammed e Diykh (2023) para a detecção de depressão a partir de sinais de EEG utilizou a expansão em série de Fourier-Bessel (FBSE) para extrair características tanto estatísticas quanto não lineares. Como classificador, os autores utilizaram a técnica de Stacked Ensemble, que combinou diversos classificadores e obteve uma acurácia de 99,11%. Quando analisadas separadamente, as características estatísticas alcançaram

uma acurácia de 93,10%, enquanto as características não lineares, isoladamente, resultaram em uma acurácia de 88,32%.

Além disso, os autores observaram que nem todos os canais de EEG contribuíram de forma eficiente para a classificação, levando à exclusão dos canais P4-LE e F&-LE, que apresentaram baixas taxas de acurácia. O estudo também demonstrou que o uso de técnicas de adaptação de domínio contribuiu para a melhoria da performance geral do modelo.

A Tabela 1 apresenta os autores discutidos nesta seção, juntamente com informações sobre as amostras utilizadas em cada estudo. Além disso, são detalhados os classificadores empregados nas abordagens e a metodologia adotada em cada trabalho.

Tabela 1 – Detalhamento dos autores, amostras utilizadas, classificadores empregados e metodologias adotadas nos estudos analisados.

Autores	Metodologia	Amostras	Modelos
Kaya e Tasci (2023)	Aprendizado por transferência e aprendizado de máquina	26 TDM 29 CS	RESNET-18, KNN
Pratiwi (2023a)	Combinação de características (lineares e não lineares), utilização das ondas Alpha, Beta, Theta, Delta e Gamma para descrever características dos sinais	26 TDM 29 CS	LSTM
Soni <i>et al.</i> (2022)	Combinação de fusão de características utilizando grafos	26 TDM 29 CS	KNN
Mohammed e Diykh (2023)	Extração de características usando FBSE e aprendizado de máquina	34 TDM 30 CS	SVM, LS-SVM, KNN, DECISION TREE, RANDOM FOREST, GRADIENT BOOSTING, BAGGED ENSEMBLE, BOSSTED ENSEMBLE, STACKED ENSEMBLE
Saeedi <i>et al.</i> (2021)	Análise da conectividade cerebral com GPDC e dDTF e aprendizado profundo	34 TDM 30 CS	IDCNN, 2DCNN, 1DCNNLSTM, 2DCNN-LSTM
Mahato e Paul (2020)	Classificação com potência alfa2 e assimetria theta	34 TDM 30 CS	SVM, LR, NB, DECISION TREE
Mahato e Paul (2019)	Combinação de características (lineares e não lineares) e aprendizado de máquina	34 TDM 30 CS	MLPNN, RBFN, LDA, QDA
Mumtaz <i>et al.</i> (2017)	Decomposição tempo-frequência usando transformada Wavalet e aprendizado de máquina	34 TDM 30 CS	LR
Metodologia Proposta	Descritor características usando Grafos e aprendizado profundo	34 TDM 30 CS	RESNET-50
		26 TDM 29 CS	RESNET-101

1.4 Objetivos

Este trabalho tem como objetivo principal avaliar a eficácia da metodologia proposta para a detecção do Transtorno Depressivo Maior em exames de EEG. A metodologia envolve o uso de um descritor de características baseado em grafos direcionados para extrair informações

relevantes dos sinais cerebrais, combinando essas características com uma rede neural ResNet para o treinamento e a classificação dos dados. Dessa forma, o estudo busca demonstrar a aplicabilidade dessa abordagem em múltiplos sinais de EEG, avaliando sua performance na detecção do TDM e destacando o potencial dessa combinação de técnicas para uma melhor acurácia na identificação dos padrões associados a essa condição.

1.4.1 *Objetivos Específicos*

- Utilização de um descritor de características baseado em grafos direcionados para a análise de sinais de EEG de indivíduos com TDM;
- Integrar os grafos direcionados em uma estrutura tensorial e processá-los em uma rede neural profunda para a classificação do TDM;
- Propor uma metodologia para a detecção do TDM a partir do processamento de múltiplos sinais de EEG.
- Avaliar a eficácia da metodologia em um contexto real, analisando amostras de EEG de indivíduos com TDM e investigando a relação entre a extração de atributos e a performance da ResNet na classificação da depressão.

1.5 Produção científica

No período de vigência dessa dissertação, alguns trabalhos científicos foram produzidos. São eles:

- Artigos na mesma linha de pesquisa da metodologia proposta:
 - **Santos, Lucas de O.**, et al. "Graph-Based EEG Analysis for Parkinson's Disease Classification: A Residual Neural Network Approach."2024 International Joint Conference on Neural Networks (IJCNN). IEEE, 2024. (Qualis A1)
 - **Santos, Lucas De O.**, et al. "Efficient Classification of Depression using EEG through Spectral Graph Analysis."2024 IEEE 37th International Symposium on Computer-Based Medical Systems (CBMS). IEEE, 2024. (Qualis A3)
 - Medeiros, A. G., Silva, F. H., **Santos, L. D. O.**, Rebouças Filho, P. P. (2023, June). Bi-Dimensional Approach Based on Graph Neural Network for Alcoholism Predisposition Detection via EEG signals. In 2023 International Joint Conference on Neural Networks (IJCNN) (pp. 1-8). IEEE. (Qualis A1)

- **Santos, Lucas de O.**, et al. "EEG-Based Major Depressive Disorder Detection Using Spectral Graph Tensors and Deep Residual Networks." 2025 International Joint Conference on Neural Networks (IJCNN). IEEE, 2025 (Artigo submetido para IJCNN 2025 com Qualis A1)
- Contribuições em outras áreas:
 - Nascimento, J. J. D. C., Marques, A. G., Dos Santos, M. A., **De Oliveira, L.**, Chaves, J. M., Souza, L. F. D. F., Rebouças Filho, P. P. (2023, June). New health of things approach to classification and detection of brain tumors using transfer learning for segmentation in imr images. In 2023 International Joint Conference on Neural Networks (IJCNN) (pp. 1-8). IEEE. (Qualis A1)
 - MEDEIROS, ALDÍSIO GONÇALVES ; **DE OLIVEIRA SANTOS, LUCAS** ; Filho, Pedro Pedrosa Rebouças . Fast Stroke Lesions Segmentation Based on Parzen Estimation and Non-uniform Bit Allocation in Skull CT Images. Lecture Notes in Networks and Systems. 22ed.: Springer Nature Switzerland, 2023, v. , p. 99-109. (Qualis B1)
 - de F. Souza, Luís Fabrício ; DA COSTA NASCIMENTO, JOSÉ JEROVANE ; Sabóia, Cyro M. G. ; Marques, Adriell G. ; Brilhante, Guilherme Freire ; **DE OLIVEIRA SANTOS, LUCAS** ; REGO, PAULO A. L. ; Filho, Pedro Pedrosa Rebouças . New Approach in LPR Systems Using Deep Learning to Classify Mercosur License Plates with Perspective Adjustment. Lecture Notes in Networks and Systems. 22ed.: Springer Nature Switzerland, 2023, v. , p. 31-41. (Qualis B1)

1.6 Organização da Dissertação

Este trabalho, na Seção 1.3, revisita as investigações recentes sobre o uso de sinais para a classificação de pacientes com Transtorno Depressivo Maior. A Seção examina as abordagens que utilizam sinais de EEG para identificar padrões associados a essa condição. No Capítulo 2, são discutidos os conceitos essenciais que formam a base teórica para o desenvolvimento da abordagem proposta. O Capítulo 3 detalha a metodologia, explicando como o descritor de características processa os sinais e introduzindo a proposta de marcadores espectrais utilizados ao longo da pesquisa bem como a utilização da rede ResNet para classificação do transtorno. Finalmente, o Capítulo 4 propõe a aplicação do método no diagnóstico do TDM, utilizando sinais de EEG coletados de pacientes reais.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, são apresentados os conceitos fundamentais para este estudo. Inicialmente, são discutidos grafos e digrafos, utilizados para modelar redes cerebrais a partir de sinais de EEG, além das matrizes de representação, que estruturam essas conexões de forma computacional.

Também é abordada a Transformada de Fourier Discreta, essencial na análise de sinais, pois permite a conversão dos dados para o domínio da frequência, proporcionando um estudo mais preciso das relações presentes nos sinais. Por fim, será apresentada a rede neural artificial ResNet, um modelo de aprendizado profundo aplicado à identificação de padrões em sinais de EEG, sendo amplamente utilizado em diversos estudos da literatura relacionados à análise de EEG e suas aplicações na área da saúde (SANTOS *et al.*, 2024b; SANTOS *et al.*, 2024a; CUKIC *et al.*, 2020).

2.1 Grafos e Digrafos na modelagem de características cerebrais

Os grafos são estruturas matemáticas que modelam sistemas interconectados, sendo amplamente utilizados na modelagem de redes neurais (SILVA *et al.*, 2021). No caso da análise de EEG, os grafos permitem visualizar e estudar as interações entre diferentes regiões do cérebro. Nessa representação, os vértices do grafo correspondem a áreas cerebrais e as arestas representam as conexões funcionais entre essas regiões, com base na atividade elétrica registrada pelo EEG (HANDIRU *et al.*, 2021).

Além dos grafos convencionais, os digrafos (ou grafos direcionados) são utilizados quando há uma relação de direção na interação entre regiões cerebrais. Isso significa que não apenas a existência de uma conexão entre duas áreas é considerada, mas também o fluxo de informação entre elas. Esse tipo de análise é útil para compreender como a comunicação neural é afetada pela depressão. Estudos como o de Cukic *et al.* (2020) e Santos *et al.* (2024b) exploraram essa abordagem para investigar a comunicação neural e suas alterações em condições como a depressão.

2.1.1 Matrizes de representação de grafos

Para viabilizar o processamento computacional dessas redes, os grafos podem ser representados por matrizes matemáticas, que organizam e estruturam de forma eficiente as

informações sobre suas conexões. Nesse contexto, estudos como os de Santos *et al.* (2024b), Santos *et al.* (2024a) e Medeiros *et al.* (2023) utilizaram essas representações matriciais para investigar transtornos neurológicos. Entre as principais matrizes empregadas na modelagem de redes cerebrais, destacam-se:

- **Matriz de Adjacência (A):** Representa a conectividade entre os vértices de um grafo. Cada elemento da matriz indica se há (ou não) uma conexão entre duas regiões cerebrais. No caso de um grafo ponderado, essa matriz pode incluir valores que indicam a força dessas conexões (HERMUCHE, 2019).
- **Matriz Laplaciana (L):** Utilizada para estudar as propriedades estruturais do grafo, essa matriz é derivada da matriz de adjacência e auxilia na análise da conectividade e na identificação de agrupamentos neurais (CHUNG, 1997).
- **Matriz Laplaciana Combinatória (CL):** A Matriz Laplaciana Combinatória é amplamente utilizada no processamento de sinais em grafos, pois permite analisar a propagação e a difusão de informações na estrutura do grafo, facilitando a extração de características relevantes (CHUNG, 1997).
- **Matriz Laplaciana Combinatorial Direcionada (DL):** Aplicada especialmente em digrafos, permitindo a análise de redes onde a direção das conexões é fundamental para entender os padrões cerebrais (MIEGHEM, 2011).

2.1.2 Aplicação de Redes Neurais na análise de EEG

Além das representações gráficas e suas matrizes associadas, o estudo de sinais de EEG para a identificação do TDM tem-se beneficiado do uso de redes neurais profundas. Modelos como a ResNet (discutida na seção 2.3.1) são empregados para processar esses sinais e extrair características relevantes para o diagnóstico. A combinação da teoria dos grafos com aprendizado profundo permite uma análise mais precisa e automatizada, ampliando o potencial de ferramentas computacionais na detecção da depressão.

2.2 Transformada Discreta de Fourier (DFT)

Sinais originais em EEG são registrados no domínio do tempo, mas a análise de transtornos como o Transtorno Depressivo Maior requer a investigação das frequências associadas às atividades cerebrais. Nesse sentido, a Transformada Discreta de Fourier (DFT) é uma

ferramenta matemática essencial para essa análise, pois converte sinais do domínio do tempo para o domínio da frequência, possibilitando a identificação de padrões específicos relacionados ao TDM (SANTOS *et al.*, 2024b).

Ao aplicar a DFT, é possível examinar as características espectrais do sinal EEG, facilitando a detecção de alterações associadas ao TDM. Essas alterações são fundamentais para entender como a atividade elétrica do cérebro está modificada em indivíduos com esse transtorno. Nesse aspecto, a DFT, sendo uma versão discreta da Transformada de Fourier contínua, é amplamente utilizada em diversas áreas, incluindo processamento de sinais provenientes de exames médicos, e se torna particularmente importante na análise de EEGs para estudar condições neurológicas como o TDM (SANTOS *et al.*, 2024b).

Matematicamente, a DFT de um sinal discreto $x[n]$, onde n representa os índices de tempo discretos, é definida como segue:

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-j(2\pi/N)kn} \quad (2.1)$$

Onde $X[k]$ representa o componente de frequência na posição k , $x[n]$ denota o valor do sinal no tempo n , N é o número total de amostras no sinal, e j representa a unidade imaginária (i).

2.3 Redes Neurais Artificiais

Os modelos de Redes Neurais Artificiais (RNA) foram desenvolvidos com inspiração no funcionamento do cérebro humano, sendo amplamente utilizados para resolver problemas de aprendizado e reconhecimento de padrões. Nesse sentido, uma de suas possíveis aplicações está na área da saúde, onde podem auxiliar na análise de sinais biomédicos e no suporte ao diagnóstico de transtornos como a depressão. A unidade fundamental dessas redes é o neurônio artificial, que pode ser descrito matematicamente como uma combinação ponderada de entradas. Modelos iniciais, como o Perceptron e o neurônio idealizados por McCulloch e Pitts (1943) e Rosenblatt (1958), foram essenciais para a evolução das redes neurais modernas.

O aprendizado em redes neurais ocorre por meio do ajuste dos coeficientes associados às conexões entre os neurônios, representados pelo vetor w , de forma a tornar a saída da rede compatível com os resultados esperados. Esse refinamento é realizado por métodos baseados na propagação reversa do erro, onde os pesos são modificados iterativamente para minimizar discrepâncias nos resultados. Para isso, utilizam-se técnicas de otimização, como o algoritmo do gradiente descendente, que permite a adaptação progressiva da rede ao problema analisado.

2.3.1 Rede neural residual (ResNet)

As Redes Neurais Residuais (ResNets), descritas por He *et al.* (2016), foram criadas para superar desafios no treinamento de redes profundas, como o desaparecimento do gradiente. Sua principal inovação é o uso de conexões residuais, que permitem que a entrada de uma camada seja somada à sua saída, facilitando a propagação do gradiente. O termo "residual", neste caso, refere-se à diferença entre a entrada e a saída desejada, representando o ajuste que a rede precisa aprender.

Seja x a entrada e $F(x)$ a transformação aplicada, a formulação residual é dada por:

$$y = F(x) + x \quad (2.2)$$

O bloco residual, elemento fundamental da ResNet, é composto por duas camadas convolucionais e uma conexão de atalho que permite que a entrada seja somada à saída. Esse mecanismo preserva características importantes dos dados, facilitando o aprendizado em redes profundas (HE *et al.*, 2016). Dessa forma, a rede ajusta apenas a diferença entre a entrada e a saída desejada, conhecida como mapeamento residual. Isso ajuda a manter o gradiente ativo durante o treinamento, evitando sua atenuação e tornando o aprendizado mais eficiente.

2.4 Avaliação de desempenho

Nesta seção, apresentamos as métricas utilizadas para avaliar o desempenho da metodologia proposta para classificação de TDM em sinais de EEG. Dessa forma, a seção é estruturada em duas partes: na primeira, abordamos o uso do teste t de Student, que desempenha um papel crucial na análise estatística das amostras, permitindo discriminar as diferenças entre as classes (com e sem TDM) e dentro de cada classe. Na segunda parte, discutimos as métricas utilizadas para avaliar o desempenho do modelo de classificação, que integra um descritor baseado em grafo e uma ResNet, proporcionando uma análise robusta dos sinais para a classificação.

2.4.1 O Teste t de Student

O Teste t de Student para duas variáveis, também conhecido como teste t para duas amostras independentes, é amplamente utilizado para comparar as médias de dois grupos distintos

e verificar se há uma diferença estatisticamente significativa entre eles. Esse teste é especialmente útil em experimentos onde se deseja avaliar o impacto de uma variável independente sobre uma variável dependente (STUDENT, 1908).

Considerando duas amostras independentes, o teste t parte da suposição de que os dados seguem uma distribuição normal e que as variâncias dos grupos comparados são aproximadamente iguais. Nesse sentido, a estatística do teste t é dada pela Equação 2.3.

$$t = \frac{m_A - m_B}{\sqrt{\frac{R^2}{n_A} + \frac{R^2}{n_B}}} \quad (2.3)$$

Onde m_A e m_B são os valores médios das amostras A e B, R^2 representa a variância combinada dos dados. Já n_A e n_B representam o número de amostras de cada classe.

Nesse sentido, a variância combinada R^2 é uma medida de dispersão que combina as variâncias de ambas as amostras A e B. Ela é calculada levando em consideração as somas dos quadrados das diferenças entre os dados (x) e suas médias (m_A e m_B). A fórmula para R^2 é dada pela Equação 2.4.

$$R^2 = \frac{\sum(x - m_A)^2 + \sum(x - m_B)^2}{n_A + n_B - 2} \quad (2.4)$$

Essa variância combinada é usada para calcular a estatística t , que, por sua vez, é utilizada para testar a hipótese de que as médias das duas amostras são diferentes. Quanto maior o valor de t , maior a evidência de que existe uma diferença significativa entre as médias das duas amostras. Além disso, o valor-p é uma medida que quantifica a evidência contra a hipótese nula. Ele indica a probabilidade de obter os dados observados ou algo mais extremo, assumindo que a hipótese nula seja verdadeira. O valor-p nos ajuda a decidir se devemos ou não rejeitar a hipótese nula.

O nível de significância (α) é um valor pré-determinado que define a probabilidade de cometer um erro **tipo I**, ou seja, rejeitar a hipótese nula quando ela é verdadeira. Um valor comum utilizado para α é 0,05, o que significa que existe uma chance de 5% de cometer um erro ao rejeitar a hipótese nula. Se o valor-p obtido do teste t for menor que o nível de significância ($p < \alpha$), rejeita-se a hipótese nula, concluindo que existe uma diferença significativa entre as médias das amostras. Caso contrário, se o valor-p for maior que α , não há evidências suficientes para rejeitar a hipótese nula, sugerindo que as médias das amostras são semelhantes.

2.4.2 Avaliação do Modelo de Classificação

A avaliação de desempenho em modelos de classificação é essencial para a análise e seleção de algoritmos. Para isso, utilizamos a matriz de confusão, que resume a performance do modelo ao comparar os valores reais e preditos, identificando acertos e erros por meio de Verdadeiros Positivos (TP), Verdadeiros Negativos (TN), Falsos Positivos (FP) e Falsos Negativos (FN). Com base nessa matriz, são calculadas métricas como Acurácia, Precisão, Recall e F1-Score, permitindo uma avaliação abrangente do modelo, conforme descrito por Vásquez-Correa *et al.* (2021).

Figura 1 – Matriz de confusão, apresentando os diferentes valores de verdadeiros positivos, falsos positivos, falsos negativos e verdadeiros negativos.

		Predição	
		P	N
Real	p	TP	FN
	n	FP	TN

Fonte: Adaptado de Statplace (2024).

A acurácia indica a proporção de previsões corretas feitas pelo modelo em relação ao total de instâncias analisadas. Dessa forma, a Equação 2.5 mostra o cálculo da acurácia.

$$Acc = \frac{TP + TN}{TP + FN + FP + TN} \quad (2.5)$$

A precisão avalia a proporção de previsões positivas corretas em relação ao total de previsões positivas feitas pelo modelo. A fórmula da precisão é dada pela Equação 2.6.

$$Prec = \frac{TP}{TP + FP} \quad (2.6)$$

O recall, ou sensibilidade, avalia a habilidade do modelo em detectar todas as instâncias positivas reais. A fórmula do recall é dada pela Equação 2.7.

$$Recall = \frac{TP}{TP + FN} \quad (2.7)$$

O F1-Score combina precisão e recall em uma única métrica, equilibrando a exatidão das previsões positivas e a capacidade de identificar todas as instâncias relevantes, sendo útil em

cenários com classes desbalanceadas. A fórmula do F1-Score é dada pela Equação 2.8.

$$F1-Score = \frac{2 \cdot Prec \cdot Recall}{Prec + Recall} \quad (2.8)$$

Neste estudo, foi adotada a validação cruzada com amostragem estratificada durante a classificação dos tensores espectrais. Essa técnica assegura que cada divisão do conjunto de dados represente adequadamente todos os grupos presentes, garantindo uma distribuição balanceada das classes em cada etapa de teste. A abordagem tem sido empregada em pesquisas recentes focadas na classificação de doenças. (MOHAMMED; DIYKH, 2023; SAEEDI *et al.*, 2021)

2.4.3 Conclusão do Capítulo

Neste capítulo, os conceitos fundamentais que sustentam a pesquisa foram abordados, com destaque para a Teoria dos Grafos, que fornece uma base matemática para modelar relações e estruturas complexas. Isso permite representar grafos e digrafos por meio de matrizes, facilitando a análise das complexidades presentes em sinais de EEG. Aliado a isso, a DFT é apresentada como uma ferramenta essencial para converter sinais de EEG para o domínio da frequência, garantindo maior robustez no processamento e uma melhor representação dos padrões característicos da depressão.

Além disso, o modelo de classificação ResNet e as métricas de desempenho são discutidos para permitir uma avaliação dos resultados obtidos. Esse embasamento teórico estabelece as bases para as próximas etapas do estudo, direcionando a implementação da metodologia e a interpretação dos resultados. Com a combinação dessas abordagens, é possível avançar na análise dos sinais de EEG, oferecendo uma compreensão mais aprofundada dos padrões e facilitando a identificação de características relacionadas ao TDM.

3 MODELAGEM ESPECTRAL E APRENDIZADO PROFUNDO NA DETECÇÃO DO TRANSTORNO DEPRESSIVO MAIOR: A METODOLOGIA

A metodologia apresentada neste capítulo aborda o processamento de sinais de EEG relacionados à saúde mental, com ênfase na construção de uma representação única em forma de um grafo direcionado. O objetivo é capturar as características desses sinais, desde sua conversão para o domínio da frequência, sob o ponto de vista da análise das componentes espectrais, até a construção de tensores espectrais, apresentados em três diferentes perspectivas. Esse processo visa identificar padrões específicos que podem refletir mudanças no estado neurofisiológico de pacientes com Transtorno Depressivo Maior.

Nesse sentido, a construção do digrafo visa representar as relações entre os diferentes sinais coletados ao longo do tempo, focando na análise dos dados dos pacientes com TDM para que, em etapas subsequentes, esses sinais possam ser classificados e analisados com base em características relevantes para o diagnóstico do transtorno. A Figura 4 ilustra o processamento do sinal de EEG.

Dessa forma, o fluxo proposto resume as etapas que começam com a obtenção dos sinais a partir dos pacientes (Etapa 1). Em seguida, ocorre a conversão para o domínio da frequência, com a identificação dos coeficientes espectrais que podem ser indicadores-chave para o diagnóstico do TDM (Etapas 2-3). O processo continua com a construção dos grafos que possuem arestas ponderadas (Etapas 4-5). Por fim, os digrafos são combinados em uma única estrutura, resultando na produção e união de matrizes em um tensor espectral, ferramenta crucial para a análise de sinais relacionados ao TDM (Etapas 6-8). Por fim, o tensor gerado é utilizado como base para o treinamento de uma rede ResNet-50, dando continuidade à metodologia com a classificação de pacientes com o transtorno (Etapa 9).

Nas seções seguintes, cada uma dessas etapas será detalhada, mostrando como essa abordagem pode contribuir para uma melhor compreensão dos mecanismos neurofisiológicos subjacentes ao Transtorno Depressivo Maior, auxiliando no aprimoramento do diagnóstico e acompanhamento dos pacientes.

3.1 Aplicação da DFT nos sinais de EEG

Ao analisar um sinal de EEG, o estudo do espectro de frequência oferece uma visão mais detalhada sobre a estrutura dos dados, o que é particularmente relevante quando se investiga o Transtorno Depressivo Maior. Em contraste com o domínio do tempo, onde a interpretação de

padrões é mais complexa, a decomposição do sinal em espectros permite identificar componentes que podem indicar alterações na atividade cerebral associadas ao TDM. Estudos indicam que pacientes com depressão frequentemente apresentam alterações significativas no padrão de atividade elétrica cerebral, como a diminuição da atividade nas regiões associadas ao alerta e maior concentração de padrões característicos de estados de letargia ou dificuldade de concentração (SIULY *et al.*, 2016; TATUM, 2021).

Contudo, a utilização da DFT em EEGs de indivíduos com TDM não está isenta de desafios. A presença de ruídos nos sinais coletados, frequentemente decorrentes de artefatos musculares ou interferências externas, pode distorcer as análises espectrais e dificultar a identificação precisa dos padrões de frequência. Nesse contexto, a aplicação de técnicas de filtragem adequadas torna-se essencial para mitigar a influência do ruído e garantir uma análise mais assertiva dos dados.

Dessa forma, a análise no domínio da frequência é mais eficaz do que no domínio do tempo para identificar alterações sutis na atividade cerebral associadas ao TDM. No domínio do tempo, as flutuações rápidas e não-linearidades do sinal dificultam a interpretação, enquanto a decomposição em frequências permite observar a distribuição do sinal ao longo do tempo de forma mais clara. Isso facilita a identificação das mudanças cerebrais no TDM, proporcionando uma compreensão mais profunda do transtorno e aprimorando o diagnóstico do paciente (SIULY *et al.*, 2016).


3.2 Marcadores de componentes espectrais

A aplicação da DFT aos sinais de EEG permite uma representação mais detalhada no domínio da frequência, facilitando a análise dos dados. Nesse contexto, Medeiros (2024) propôs quatro tipos de marcadores espectrais — *alpha* (α), *beta* (β), *gamma* (γ) e *delta* (δ) — para caracterizar os sinais de EEG, destacando o marcador δ como o mais eficaz. Além disso, o autor empregou esse marcador na classificação de doenças neurodegenerativas, como Parkinson e Alzheimer, evidenciando sua relação com padrões de disfunção neuronal e alterações na conectividade cerebral. Diante dessa relevância, este estudo adota o marcador δ para investigar padrões cerebrais em indivíduos com TDM, reforçando sua adequação para o estudo do transtorno.

Nesse sentido, o marcador espectral δ utiliza pontos de inflexão (LEITHOLD, 1994) para detectar mudanças na curvatura do sinal, ajudando a identificar transições nas suas características, como aponta Medeiros (2024). Esses pontos refletem variações abruptas na

estrutura espectral do sinal, consolidando informações sobre as mudanças na intensidade de seus componentes ao longo do tempo. Com isso, o marcador δ contribui para uma análise mais detalhada das variações no sinal, destacando as transições importantes em suas características espectrais. A figura 2 ilustra o marcador espectral δ .

Figura 2 – O marcador espectral delta (δ). Este marcador é composto pelos coeficientes de magnitude que ocorrem nos pontos de inflexão




Fonte: Adaptado de Medeiros (2024)

3.3 Representação dos marcadores espectrais utilizando Digrafo

Como discutido na Seção 2.1, os digrafos são utilizados para representar relações entre diferentes elementos por meio de conexões direcionadas. No contexto deste estudo, cada nó n_i representa um intervalo específico de magnitude espectral, e a transição entre dois intervalos distintos é representada por uma aresta direcionada w_{ij} , que conecta um nó n_i a um nó n_j . O peso dessa aresta indica a frequência com que as magnitudes espectrais transitam do intervalo n_i para o intervalo n_j . Dessa forma, a estrutura do digrafo permite mapear padrões de variação na atividade espectral, o que pode contribuir para a identificação de características associadas ao Transtorno Depressivo Maior.

A Figura 3 ilustra o processo de análise do sinal e a construção do digrafo DG . Nela, são destacados os coeficientes espectrais correspondentes aos máximos locais, representados em vermelho, e aos mínimos locais, em roxo, uma vez que ambos são considerados extremos — máximos locais e pontos de inflexão. Além disso, o coeficiente espectral δ é associado às mudanças de concavidade do sinal no domínio da frequência, caracterizando pontos de inflexão, que são destacados em laranja. Embora esses pontos não sejam máximos locais, eles indicam frequências com magnitude intermediária e são essenciais para o marcador δ .

Figura 3 – Grafo direcionado DG construído a partir do marcador δ .



Fonte: Adaptada de Medeiros (2024)


3.3.1 Processamento dos sinais de EEG

A abordagem proposta tem como objetivo processar os sinais provenientes de múltiplos eletrodos que formam um mesmo exame de EEG. Cada eletrodo registra uma série temporal específica, e para cada um desses sinais que compõem uma única amostra de um paciente, foi modelado um digrafo individual, conforme descrito na Seção 3.3. Esse processo permite representar as relações de transição das componentes espectrais dentro de cada canal de EEG de forma estruturada. Em seguida, todos os digrafos gerados são integrados em uma única estrutura DG^* , que sintetiza as características globais de cada indivíduo. Essa unificação possibilita a extração de padrões de conectividade mais abrangentes, considerando a interação entre os diferentes canais do EEG.

Dessa forma, a construção do digrafo segue a Equação 3.1, na qual DG_i representa o grafo correspondente ao eletrodo i , e k indica o número total de eletrodos no exame de EEG. A partir dessa estrutura consolidada, são geradas as matrizes de Adjacência (A), Laplaciana (L) e Laplaciana Combinatória Direcionada (CL), que descrevem diferentes aspectos das conexões presentes no digrafo generalizado DG^* . Essas matrizes capturam aspectos essenciais da estrutura do sinal, viabilizando a identificação de padrões característicos e possibilitando inferências sobre sua relação com a depressão.

$$DG^* = \bigcup_{i=1}^k DG_i \quad (3.1)$$

Figura 4 – Fluxograma da metodologia proposta.



Fonte: Elaborada pelo autor.

3.3.1.1 Construção de tensores a partir de digrafos para classificação

A teoria dos grafos (DIESTEL; DIESTEL, 2017) fornece diferentes representações matriciais para modelar as relações entre vértices e arestas. Entre as principais, destacam-se a matriz de adjacência, que captura conexões diretas entre os vértices, a matriz laplaciana, que expressa a conectividade estrutural do grafo, e a matriz laplaciana combinatória direcionada, que descreve a estrutura sem considerar a orientação das arestas. Cada uma dessas representações oferece uma perspectiva distinta da topologia do grafo, sendo escolhida de acordo com o tipo de análise desejada. A combinação dessas matrizes possibilita uma visão mais abrangente da estrutura do grafo, permitindo a extração de características relevantes para aplicações em aprendizado de máquina.

No contexto da detecção de depressão, uma abordagem eficiente consiste em organizar essas matrizes em uma estrutura tridimensional, formando um tensor. Esse tensor consolida as informações estruturais do digrafo, permitindo a análise conjunta das relações entre diferentes aspectos da conectividade neuronal ou de padrões comportamentais extraídos de múltiplos sinais de EEG. A representação tensorial viabiliza o aprendizado profundo ao preservar as informações estruturais e facilitar a extração de características associadas a estados depressivos.

Para a classificação dos padrões extraídos desse tensor, utilizamos redes neurais convolucionais profundas, especificamente a ResNet. A arquitetura ResNet se destaca por sua capacidade de capturar representações hierárquicas complexas, permitindo que padrões sutis indicativos de depressão sejam identificados de forma eficiente. Essa abordagem otimiza o processamento de dados em frameworks como *PyTorch*, viabilizando a extração automática de atributos relevantes e melhorando a acurácia na detecção de depressão. Ao consolidar as informações do digrafo em um único descritor estruturado, o tensor espectral se torna uma ferramenta poderosa para análise de dados médicos e psicológicos, contribuindo para o desenvolvimento de modelos mais robustos e adaptáveis no diagnóstico precoce da depressão.

3.4 Conclusão do Capítulo

Este capítulo apresenta uma metodologia inovadora para a detecção do transtorno depressivo maior, unindo análise espectral de sinais e aprendizado profundo. O processo inicia-se com a Transformada Discreta de Fourier, que converte o sinal para o domínio da frequência. A estrutura resultante é modelada como um grafo direcionado, cujas conexões são definidas com

base nos coeficientes espectrais. Para representar essa estrutura de forma eficiente, utilizamos três matrizes fundamentais — adjacência, laplaciana e laplaciana combinatória direcionada — que, combinadas, formam um tensor espectral. Diferentemente de abordagens anteriores, esta metodologia foca exclusivamente no marcador espectral δ , comprovado como o mais eficaz na extração de padrões relevantes.

O grande diferencial dessa proposta está na fusão entre o modelo tensorial do digrafo e uma rede neural profunda do tipo ResNet. Essa combinação potencializa a detecção de padrões sutis relacionados à depressão, explorando tanto a estrutura espectral do sinal quanto a capacidade da rede convolucional de aprender representações complexas. Com isso, a abordagem não apenas aprimora a análise de sinais no domínio da frequência, mas também fortalece o uso de aprendizado profundo no diagnóstico de transtornos mentais, oferecendo um método mais robusto e eficiente para a classificação automática de dados fisiológicos.

4 CLASSIFICAÇÃO DE AMOSTRAS DE PACIENTES COM TRANSTORNO DEPRESSIVO MAIOR VIA SINAIS DE EEG.

Neste capítulo, o processamento do descritor de sinais será analisado em amostras provenientes de indivíduos saudáveis e de pacientes diagnosticados com Transtorno Depressivo Maior, com foco na classificação de múltiplos sinais obtidos a partir de exames de EEG. Inicialmente, apresentamos uma visão geral sobre o transtorno e sua relevância clínica na seção 4.1. Em seguida, discutimos trabalhos relacionados que fundamentam a abordagem adotada na seção 4.2. Também detalhamos as amostras utilizadas na pesquisa, descrevendo os dados dos pacientes na seção 4.3. A metodologia é abordada na seção 4.4, incluindo a modelagem dos sinais, a construção do tensor espectral e a utilização da ResNet para classificação. Por fim, analisamos os resultados obtidos na seção 4.5 e discutimos suas implicações, concluindo com uma síntese das principais contribuições deste estudo na seção 4.6.

4.1 O Transtorno Depressivo Maior

O Transtorno Depressivo Maior, comumente chamado de depressão, é uma condição de saúde mental que acomete uma parte significativa da população, destaca Wang *et al.* (2024). Contudo, para um terço dos adultos que enfrentam o TDM, o processo de recuperação apresenta muitos desafios; alguns não alcançam melhorias clinicamente significativas mesmo após vários tratamentos sequenciais com antidepressivos e são diagnosticados com depressão resistente ao tratamento (DRT), conforme relatado no American Journal of Psychiatry Jha e Mathew (2023). Isso evidencia a necessidade crítica de métodos diagnósticos mais precisos e confiáveis.

O diagnóstico de transtornos depressivos, tradicionalmente, é baseado em sessões de aconselhamento conduzidas por médicos ou psicólogos, nas quais os pacientes respondem a perguntas específicas. Entretanto, esses diagnósticos podem ser suscetíveis a erros, especialmente devido à inexperiência do avaliador, menciona Sandmire *et al.* (1976). Visando contornar tais limitações e assim aprimorar a precisão diagnóstica, pesquisadores têm investido no uso de técnicas avançadas, como aprendizado de máquina e redes neurais.

Recentemente, técnicas avançadas, que utilizam aprendizado de máquina e redes neurais, têm sido aplicadas na detecção e classificação de transtornos depressivos utilizando sinais de EEG. Kaya e Tasci (2023) utilizaram redes neurais convolucionais com aprendizado por transferência para classificar o TDM, alcançando resultados promissores. Soni *et al.* (2022) propuseram um método baseado em grafos para a classificação de sinais de EEG, demonstrando

desempenho consistente em diferentes conjuntos de dados. Já Pratiwi (2023b) destacou a relevância de combinar características lineares e não lineares para aumentar a precisão na detecção de depressão baseada em EEG.

Os avanços em aprendizado de máquina e redes neurais apresentam caminhos promissores para diagnósticos mais precisos e eficientes do TDM, com potencial para transformar os cuidados em saúde mental. Em vista disso, este estudo contribui para esse campo ao analisar sinais de EEG com o objetivo de identificar o TDM, oferecendo uma abordagem mais precisa e eficaz para o diagnóstico médico.

4.2 Trabalhos relacionados

No capítulo inicial desta dissertação, mais precisamente na Seção 1.3.1, são discutidas diversas abordagens para a extração de atributos em análises de sinais de EEG, as quais fundamentam a pesquisa apresentada neste capítulo. Além disso, são descritos os trabalhos relacionados que servem como referência para fins comparativos nos resultados desta aplicação.

4.3 Amostras de pacientes

4.3.1 Dataset I


O MODMA, disponibilizado por Cai *et al.* (2022), é um banco de dados aberto e multimodal projetado para a análise de transtornos mentais, contendo sinais de EEG de 3 canais. A escolha desses canais se baseia na forte associação entre o córtex pré-frontal e processos emocionais, bem como transtornos psiquiátricos como a depressão. Os sinais foram coletados por meio de um dispositivo de EEG pervasivo, utilizando três eletrodos localizados no córtex pré-frontal: Fp1, Fpz e Fp2. A localização dos eletrodos está ilustrada na Figura 5.

Os dados de EEG foram amostrados a 250 Hz e armazenados em arquivos TXT com uma matriz $M \times N$, onde $M = 8$ (número de eletrodos) e N é o número de pontos de amostragem. Os três primeiros eletrodos correspondem aos sinais Fp1, Fpz e Fp2, enquanto os cinco canais restantes são de referência, caso não sejam usados. O experimento foi conduzido em uma sala silenciosa e controlada, com ruído ambiente abaixo de 60 dB. Os dados de EEG foram registrados com os participantes calmos e de olhos fechados durante 90 segundos. Além disso, gravações de fala foram coletadas utilizando microfones Neumann TLM102 e interface RME FIREFACE UCX, com taxa de amostragem de 44,1 kHz e profundidade de 24 bits, no formato WAV não

compactado.

O conjunto de dados inclui 55 participantes: 26 pacientes com diagnóstico de depressão e 29 controles saudáveis. As gravações de fala foram segmentadas e etiquetadas manualmente, com 29 gravações para cada participante, divididas entre entrevistas, leitura de trechos, leitura de palavras e descrições de imagens.

Figura 5 – Localização dos eletrodos Fp1, Fpz e Fp2 no córtex pré-frontal, área associada a processos emocionais e transtornos psiquiátricos, como o TDM, processados no estudo com dados MODMA.



Fonte: Adaptado de IBNeuro (2023) e Dreamstime (2023)

4.3.2 Dataset II

O conjunto de dados disponibilizado por Mumtaz *et al.* (2017) é composto por 34 pacientes diagnosticados com transtorno depressivo maior, com idade média de 40,3 anos, distribuídos igualmente entre homens e mulheres. Os diagnósticos foram realizados com base nos critérios do DSM-IV, e todos os pacientes passaram por um período de washout de duas semanas antes de iniciar o tratamento com inibidores seletivos da recaptação de serotonina (ISRS). Para controle, o estudo incluiu 30 participantes saudáveis, pareados por idade e gênero, que foram avaliados para confirmar a ausência de condições psiquiátricas.

Os dados de EEG foram adquiridos utilizando uma touca com 19 sensores de eletrogel posicionados de acordo com o sistema internacional 10–20, cobrindo regiões específicas do couro cabeludo. Os sensores foram distribuídos entre as áreas frontal (Fp1, F3, F7, Fz, Fp2, F4 e F8), central (C3, C4 e Cz), parietal (P3, Pz e P4), occipital (O1 e O2) e temporal (T3, T4, T5 e T6). Os eletrodos de eletrogel exigiram menos ajustes durante o uso, permitindo gravações mais longas e confortáveis para os pacientes. As gravações incluíram sessões de EEG com olhos

abertos e olhos fechados, além de potenciais relacionados a eventos (event-related potentials, ERP) registrados durante uma tarefa oddball visual.

Os sinais de EEG foram digitalizados a uma frequência de amostragem de 256 Hz, utilizando um filtro passa-banda de 0,1–70 Hz e um filtro notch de 50 Hz para remover ruídos da linha de energia. O pré-processamento dos dados incluiu a remoção de artefatos relacionados a movimentos oculares, piscadas, atividades musculares e cardíacas, utilizando o software BESA e técnicas semiautomáticas de correção, como a correção ocular de múltiplas fontes (MSEC). Esses procedimentos garantiram a qualidade dos dados para análise posterior.

4.4 Metodologia


No capítulo 3 desta dissertação, a metodologia proposta é discutida mais detalhadamente. Nesse sentido, os pontos de inflexão no sinal de EEG, que representam mudanças abruptas na magnitude espectral ao longo das frequências são abordados. Esses pontos definem o marcador espectral δ , que foi validado por Medeiros (2024) em uma abordagem similar. Embora não seja comum na análise do domínio de frequência, detectar essas mudanças é crucial para entender as variações nas características do sinal de EEG, como na detecção precoce da depressão. Uma vez que o marcador δ captura as características de inflexão do sinal de EEG, determinamos seu processamento nos pontos do domínio de frequência. Essa análise visa criar uma representação estruturada e direcionada do grafo da amostra.

Nessa abordagem, ao processar o sinal de EEG, ele é transformado para o domínio da frequência utilizando a Transformada de Fourier Discreta, conforme ilustrado na Figura 6 (Passos 1 e 2). Em seguida, dependendo do tipo de marcador espectral, examinamos o sinal para identificar os coeficientes de magnitude (Passo 3). Esses processos, detalhadamente descritos na seção 3.3, incluem a construção do mapa de transição com base nas transições identificadas.

Desse modo, o número de vezes que uma transição específica ocorre determina o peso das arestas (w_{ij}), representando a intensidade ou frequência da conexão entre os nós. Assim, cada transição de um marcador do nível i para o nível j representa uma conexão entre os nós n_i e n_j . Portanto, cada sinal de EEG registrado pelo paciente é processado dessa forma. Posteriormente, construímos um grafo direcionado, ou digrafo, com arestas ponderadas para cada um dos eletrodos manipulados (Passo 4).

Dentro desse contexto, a metodologia realiza uma operação de união para mesclar as estruturas representando os sinais de cada eletrodo. Essa operação combina cada um dos grafos,

Figura 6 – Fluxo de processamento da metodologia proposta.



Fonte: Elaborada pelo autor.

gerando um que representa as características coletivas, denominado grafo DG (Passo 5). Assim, considerando a equação 3.1, define-se DG_i como o grafo correspondente ao sinal do eletrodo i , enquanto k representa o número de eletrodos. Com isso, DG é resultante dessa operação.

Em seguida, a matriz de adjacência (A), que é derivada do grafo DG^* , delineia os vértices diretamente conectados, e a presença das arestas é crucial para compreender a topologia geral das arestas. Já a matriz Laplaciana (L) retrata a conectividade entre os vértices e arestas direcionadas, destacando os componentes fortemente conectados no grafo DG . Por fim, a matriz Laplaciana Combinatória (CL) descreve de maneira simples a estrutura de conectividade do grafo sem enfatizar a direcionalidade dos vértices (Passo 6).

Em seguida, o tensor tridimensional ($N \times N \times 3$), que representa as três estruturas do digrafo com N vértices, combina essas representações matriciais. Cada uma oferece uma perspectiva distinta para analisar o digrafo DG^* . Consequentemente, obtemos um tensor espectral unificado que descreve a amostra do paciente (Passo 7). Por último, avançamos para a análise do modelo de classificação para esses tensores, com o objetivo de classificar as amostras nas categorias saudável e patológica (Passos 8-10).

Neste estudo, para o treinamento e teste do modelo de classificação, uma rede


ResNet50 foi processada. Nesse contexto, o tensor de entrada possui dimensões finais de $(72 \times 72 \times 3)$, resultado da fusão dos grafos de cada canal processado. Assim, o tensor espectral é formado empilhando essas três matrizes, preservando as dimensões de $(72 \times 72 \times 3)$.

4.4.1 Análise da distribuição dos dados

4.4.1.1 Dataset I

As amostras na Figura 7 com linhas verticais tracejadas indicam os resultados médios da extração de características no conjunto de dados. Logo, uma separação visual pode ser observada entre as duas classes de amostras: o Grupo 0, que representa amostras com o TDM, e o Grupo 1, que consiste em amostras de controle saudável. Essas linhas definem uma fronteira aparente entre as distribuições das características extraídas para cada grupo que constitui o banco de dados analisado.

Figura 7 – Representação do sinal em seus coeficientes de magnitude para a estrutura do grafo direcionado no dataset I.



Fonte: Elaborada pelo autor.


A clara distinção entre essas linhas sugere que o processo de extração de características foi capaz de capturar diferenças significativas nos atributos espectrais que distinguem amostras com TDM de amostras saudáveis. Isso fortalece a inferência de que as características extraídas possuem a capacidade discriminativa para separar as duas classes dentro do mesmo espaço amostral. Em resumo, as linhas verticais tracejadas representam visualmente a

separabilidade das classes com base nas características extraídas.

4.4.1.2 Dataset II

A Figura 8 ilustra a distribuição estatística das características extraídas a partir do segundo conjunto de dados analisado. As linhas verticais tracejadas representam as médias das distribuições obtidas para cada grupo, permitindo uma visualização clara da separação entre as classes. O Grupo 0 corresponde a pacientes com TDM, enquanto o Grupo 1 refere-se a indivíduos saudáveis.

Figura 8 – Representação do sinal em seus coeficientes de magnitude para a estrutura do grafo direcionado no dataset II.



Fonte: Elaborada pelo autor.

Observa-se que essas linhas tracejadas marcam uma distinção evidente entre as distribuições, indicando que o descritor de características utilizado foi eficaz na captação de diferenças significativas nos atributos espectrais. Essa separação reforça a capacidade discriminativa das características extraídas, sugerindo que elas são representativas para diferenciar as duas classes no espaço amostral. Assim, a presença dessas linhas não apenas ilustra a separabilidade das distribuições, mas também valida a relevância das características extraídas no contexto da análise estatística.

4.4.2 Métricas de avaliação e configuração experimental

Esta metodologia avalia várias métricas: acurácia, precisão, recall e F1-Score para comparar os resultados com métodos alternativos. Nesse contexto, a acurácia é escolhida devido ao seu uso amplo em estudos anteriores sobre transtornos mentais, garantindo consistência na análise de desempenho. Além disso, precisão, recall e pontuação F1 são selecionados para avaliar os modelos, pois fornecem uma medida abrangente do desempenho, considerando diferentes aspectos na identificação de casos positivos.

Em relação ao processo de classificação, são utilizadas duas abordagens distintas de validação cruzada, dependendo da amostra de dados empregada. Para o *dataset I*, utiliza-se a estratégia de validação cruzada Stratified K-Folds com $K=5$, alocando 20% das amostras para validação e 80% para treinamento e teste. Esse algoritmo garante que a mesma amostra não apareça em diferentes pastas na mesma rodada. Por outro lado, para o *dataset II*, a validação cruzada é realizada alocando 90% das amostras para treinamento e 10% para teste. Isso foi feito para que o experimento replicasse as mesmas condições de treino e teste utilizadas pelos métodos comparativos.

Em ambas as abordagens, o modelo é treinado utilizando a Função de Custo Cross-Entropy, o otimizador AdaGrad, uma taxa de aprendizado de 0.0001 e 50 épocas. Por fim, a configuração computacional do ambiente de desenvolvimento é composta por um processador Intel Core i7 2.2GHz e 16GB de RAM, e a linguagem de programação utilizada é o Python 3.7, juntamente com as bibliotecas Torch 1.10 e Scikit-learn 1.0.2.

4.5 Resultados e discussão

Esta seção apresenta e discute os resultados obtidos neste trabalho para as duas bases de dados processadas: os *datasets I e II* (4.3). Inicialmente, será abordada a aplicação do teste t para avaliar a significância estatística das diferenças entre as distribuições das características extraídas. Em seguida, os resultados serão comparados com outros métodos encontrados na literatura que utilizam os mesmos conjuntos e subconjuntos de dados em experimentos de classificação semelhantes.


4.5.1 Aplicação do teste t

A Figura 9 apresenta os resultados obtidos com a aplicação da Análise de Variância (teste t). Observa-se que a matriz de Adjacência (A) obteve o melhor desempenho em um cenário com 30 nós no digrafo, alcançando um valor-p de 0.048. Dessa forma, a metodologia proposta atende à condição de $p < \alpha$ em pelo menos uma configuração para a matriz de Adjacência.

O teste t pressupõe que os dados seguem uma distribuição normal e que as variâncias entre as classes são homogêneas. No entanto, a presença de ruídos nos sinais de EEG das amostras do dataset I comprometeu o cumprimento desses requisitos, impactando a validade da análise de variância do teste t. Diante disso, a utilização de testes estatísticos alternativos, como o teste U de Mann-Whitney (MCKNIGHT; NAJAB, 2010), que não assume normalidade, pode ser mais apropriada para complementar a avaliação dos resultados.

Entretanto, apesar dessas limitações inerentes ao desempenho frente ao teste t, a metodologia proposta ainda supera os métodos do estado da arte (Seção 4.5.2), demonstrando um desempenho robusto e consistente na identificação dos padrões relevantes nos sinais de EEG, o que reforça a eficácia e a inovação da abordagem.

Figura 9 – Resultado do p-valor no teste t para a discriminação entre os grupos TDM e CS no dataset I, considerando as seguintes representações: Matriz de Adjacência (A), Matriz Laplaciana (L), Matriz Laplaciana Combinatória (CL) e Matriz Laplaciana Combinatória Direcionada (DL).



Fonte: Elaborada pelo autor.


Com relação ao dataset II, a Figura 10 apresenta os resultados da comparação realizada por meio do teste t. Os resultados indicam que as matrizes Matriz Laplaciana Combinatória Direcionada (DL), Laplaciana Combinatória (CL) e Laplaciana (L) tiveram os melhores desem-

penhos para a rejeição da hipótese nula, com p-valores variando entre $1,44 \cdot 10^{-5}$ e 0,035. Esses valores sugerem que essas representações foram capazes de capturar diferenças estatisticamente significativas entre as distribuições das características extraídas, evidenciando sua eficácia na distinção entre os grupos analisados.

Por outro lado, a matriz de Adjacência (A) apresentou instabilidade no cenário com 30 nós — configuração utilizada por ter produzido os melhores resultados da metodologia —, o que pode indicar uma maior variabilidade nos dados e uma menor confiabilidade na separação das classes nesse caso específico. No entanto, no cenário com 21 nós ($p = 0,00075$), a matriz demonstrou um desempenho mais consistente, reforçando sua relevância para esse contexto.

A metodologia adotada considerou as três melhores representações do grafo DG^* , garantindo um tempo médio de extração inferior a 1 segundo, o que evidencia sua eficiência e robustez nos cenários analisados.

Figura 10 – Resultado do p-valor no teste t para a discriminação entre os grupos TDM e CS no dataset II, considerando as seguintes representações: Matriz de Adjacência (A), Matriz Laplaciana (L), Matriz Laplaciana Combinatória (CL) e Matriz Laplaciana Combinatória Direcionada (DL).




Fonte: Elaborada pelo autor.

4.5.2 Análise de resultados para o dataset I

A Tabela 2 mostra a metodologia apresentada em relação a outras abordagens de trabalhos relacionados. Nesse sentido, a combinação do descritor de características com a rede ResNet-101 resulta em mais de 90% de desempenho em cada uma das métricas de avaliação, além de tempos reduzidos para treinamento e teste.

Figura 11 – Análise comparativa das métricas de avaliação utilizando diferentes métodos no Dataset I.



Fonte: Elaborada pelo autor.

Dentro desse contexto, é possível observar que a metodologia proposta, utilizando o marcador espectral δ com 24 vértices em conjunto com o classificador ResNet-101, alcança uma acurácia média de 91,03% com um leve desvio padrão de 0,07%, provando consistência para discriminar entre pacientes com depressão e indivíduos saudáveis. Ademais, os valores exatos para a métrica de recall (ou sensibilidade) indicam que o modelo é capaz de identificar corretamente indivíduos com depressão, o que é fundamental no campo médico.

Além disso, os resultados médios de 91,81% para precisão e 90,96% para o F1-score indicam um desempenho promissor, reforçando a eficácia geral da abordagem adotada. Os baixos desvios padrão observados aumentam ainda mais a confiabilidade do método, tornando-o mais robusto para uso geral. Dessa forma, o processamento proposto se destaca em comparação com

métodos de última geração, apresentando uma melhoria substancial na classificação da depressão, conforme as métricas avaliadas. A principal vantagem deste estudo em relação a outros é o descritor baseado em grafos, que possibilita uma análise mais eficiente do sinal, facilitando uma classificação profunda e precisa.

Por outro lado, diferentes métodos na literatura utilizaram aprendizado profundo para extrair os sinais, além de alguns métodos de seleção de características. Vale ressaltar que Soni *et al.* (2022) também empregaram um modelo baseado em grafo, utilizando o algoritmo Node2vec, mas alcançaram apenas 82,30% de acurácia. Além disso, alguns autores não utilizaram precisão e recall na análise de seus métodos, enquanto outros deixaram de utilizar o F1-Score. Também não foram apresentados desvios-padrão ou tempos de treinamento e teste, o que levanta questões sobre a estabilidade dos métodos. Em contraste, a abordagem utilizada neste estudo demonstra robustez nos resultados, podendo servir como um sistema de apoio eficaz para especialistas.

Além disso, os tempos de processamento apresentados na Tabela 3 evidenciam um desempenho de 12.43 segundos no treinamento e 45.1 segundos no teste. Essa diferença ocorre porque, no treinamento, as amostras podem ser processadas em lote, enquanto no teste o processamento é feito individualmente. Esses resultados demonstram a eficiência computacional da abordagem, destacando seu potencial para aplicação prática, ao possibilitar classificações rápidas e precisas que podem agilizar diagnósticos e melhorar o atendimento aos pacientes.

Dentro desse contexto, a Figura 11 mostra que o método de Kaya e Tasci (2023) obteve uma média de 89% nas métricas de avaliação, empregando o ReliefF como descritor de características e a ResNet-18 como classificador. Por outro lado, a metodologia proposta, que utiliza grafos para processar os sinais de EEG, apresentou um desempenho mais consistente, alcançando uma média de 91%, superando os autores em 2%. Além disso, a abordagem deste trabalho apresenta um baixo desvio padrão (0.07% em média), indicando uniformidade nos resultados. Vale ressaltar que o extrator adotado por Kaya e Tasci (2023) não conseguiu captar de forma eficiente as nuances presentes nos sinais de EEG relacionadas à depressão.

Essa mesma análise se estende para o trabalho apresentado por Pratiwi (2023a), que obteve 83% de acurácia e F1-score, conforme pode ser visto na Figura 11. No entanto, os autores não forneceram informações detalhadas sobre precisão e recall, o que limita uma avaliação mais completa do desempenho do modelo. O estudo utilizou características divididas em lineares, não lineares e uma combinação de ambas, juntamente com redes LSTM para classificar sinais de EEG na detecção de depressão. Nesse sentido, a utilização das diferentes bandas (Alpha,

Beta, Theta, Delta e Gamma) de forma separada pode ter dificultado a captura de interações mais complexas entre elas, limitando a capacidade do modelo de explorar os padrões presentes no sinal de EEG.

Em contraste, a metodologia proposta, baseada em grafos para extração de características, oferece uma representação mais rica e contextual dos sinais de EEG, permitindo capturar relações complexas. Além disso, o uso de uma ResNet-101 como classificador garante maior capacidade de aprendizado e generalização, especialmente para dados complexos como os de EEG. Essa combinação resultou em um melhor desempenho, alcançando 91% nas métricas de avaliação, o que representa uma melhoria de 8% em relação ao trabalho de Pratiwi (2023a). O modelo proposto demonstrou maior consistência e menor desvio padrão, destacando a melhor performance da abordagem na representação e interpretação dos sinais cerebrais.

Ainda da Figura 11, observa-se que Soni *et al.* (2022) alcançou, em média, 80% nos resultados utilizando o classificador KNN em conjunto com a metodologia de aprendizado de representação gráfica para a detecção automática de depressão a partir de sinais de EEG. O desempenho limitado pode ser atribuído à simplicidade do classificador KNN e à abordagem de fusão das características, que, embora eficaz, não explorou de maneira mais complexa as interações entre as diferentes oscilações do sinal, afetando a precisão final.

Em contraste, a metodologia proposta, também fundamentada em grafos para a extração de características, utiliza uma ResNet-101 para classificar as amostras, oferecendo uma representação mais específica dos dados. Essa abordagem permite capturar interações complexas entre as características extraídas, o que resultou em uma média de 91% nas métricas de avaliação, superando em 11% os resultados obtidos pelos autores.

4.5.3 Análise de resultados para o dataset II

A Tabela 2 apresenta os resultados alcançados pela metodologia proposta neste trabalho. Nesse sentido, ao combinar o extrator de características baseado em grafos com a rede neural ResNet-50, a abordagem superou 95% em todas as métricas de avaliação.

Em relação aos métodos comparativos, Mumtaz *et al.* (2017) obteve uma acurácia de 87,5%, mas com um alto desvio padrão de 7,1%, o que indica uma instabilidade nos resultados. Valores elevados de desvio padrão refletem uma maior volatilidade na distribuição dos dados, sugerindo que o modelo apresentou variação significativa nos resultados. Para as outras métricas, os autores alcançaram 95% de recall e 81% de F1-Score, com desvios padrão de 4,3% e 2,1%,

Tabela 2 – Resultados para o melhor desempenho do método processado, comparado a métodos de ponta, em amostras dos conjuntos de dados I e II, para a classificação do TDM em relação a pacientes saudáveis.

Dataset	Subset	Pesquisa	Classificador	ACC	Pre.	Recall	F1-Score		
Dataset I	TDM vs CS	Proposta (δ -24 vértices)	RESNET-101	91.03 $\pm$ 0.07	91.81 $\pm$ 0.06	91.03 $\pm$ 0.07	90.96 $\pm$ 0.07		
		Kaya e Tasci (2023)	RESNET-18	89.86	89.88	89.78	-		
		Pratiwi (2023a)	LSTM	83.74	-	-	83.12		
		Soni <i>et al.</i> (2022)	KNN	82.30	78.90	81.80	80.30		
		Proposta (δ -30 vértices)	RESNET-50	95.83 $\pm$ 0.12	95.86 $\pm$ 0.12	95.83 $\pm$ 0.12	95.80 $\pm$ 0.12		
		Mohammed e Diykh (2023)	STACKED ENSEMBLE - NON-LINEAR FEATURES	88.32	88.06	88.65	89.84		
			STACKED ENSEMBLE - STATISTICAL FEATURES	93.10	92.74	92.74	92.73		
			STACKED ENSEMBLE - COMBINED FEATURES	99.11	98.30	98.00	98.30		
		Dataset II	TDM vs CS	Saeedi <i>et al.</i> (2021)	CNN 1D-LSTM	99.24 $\pm$ 1.15	98.14 $\pm$ 1.85	98.52 $\pm$ 2.46	99.04 $\pm$ 0.94
					CNN 2D-LSTM	96.41 $\pm$ 3.42	97.73 $\pm$ 2.77	98.52 $\pm$ 1.81	96.55 $\pm$ 1.80
CNN 1D	95.28 $\pm$ 2.11				97.37 $\pm$ 2.40	91.48 $\pm$ 4.07	95.23 $\pm$ 1.23		
CNN 2D	96.27 $\pm$ 1.21				97.37 $\pm$ 2.25	94.81 $\pm$ 2.46	96.57 $\pm$ 1.41		
LSTM	89.06 $\pm$ 1.85				89.31 $\pm$ 1.77	84.81 $\pm$ 4.52	88.75 $\pm$ 1.92		
Mahato e Paul (2020)	SVM			88.33	-	90.81	-		
Mahato e Paul (2019)	MLPNN			93.33 $\pm$ 1.67	-	94.44 $\pm$ 3.68	-		
	RBFN			93.33 $\pm$ 1.67	-	94.44 $\pm$ 3.68	-		
	LDA			93.33	-	86.67	-		
	QDA			86.67	-	93.33	-		
Mumtaz <i>et al.</i> (2017)	LR	87.50 $\pm$ 7.1	-	95.00 $\pm$ 4.3	81.00 $\pm$ 2.1				

Fonte: Elaborada pelo autor.

respectivamente. Nesse contexto, a metodologia proposta neste trabalho superou o método de Mumtaz *et al.* (2017) em 8% na acurácia e em 14% no F1-Score. Isso indica que o extrator de características baseado em grafos foi mais eficaz na captura de informações relevantes e características do TDM, quando comparado aos coeficientes wavelet utilizados pelos autores.

Além disso, Mumtaz *et al.* (2017) aplica uma redução de dimensionalidade com o intuito de eliminar redundâncias no sinal, mas esse processo pode ser ineficaz ao remover dados não ruidosos das amostras, prejudicando a representatividade dos dados. Os autores também utilizaram um classificador de regressão logística, que não conseguiu capturar de forma eficiente as tendências não lineares nos dados, o que limita a capacidade do modelo em aprender padrões mais complexos, influenciando negativamente o desempenho geral.

O método de Mahato e Paul (2019) envolve a extração manual de características lineares e não-lineares, utilizando transformadas de Fourier, Wavelet e estatísticas de ordem superior, seguidas de classificadores como MLPNN, RBFN, LDA e QDA. Contudo, esse processo enfrenta limitações ao lidar com a complexidade e não-linearidade dos sinais cerebrais, dificultando a captura de interações sutis e complexas nos dados. Além disso, a aplicação da redução de dimensionalidade por PCA aplicada não foi eficaz, possivelmente devido à incapacidade do PCA em capturar interações não-lineares presentes nos sinais de EEG, o que compromete a representação completa dos dados e afeta a performance do modelo.

Em comparação, a abordagem proposta, que combina grafos e a ResNet-50, elimina

a extração manual de características, permitindo que o modelo aprenda diretamente dos dados brutos. Isso melhora a identificação de padrões complexos nos sinais de EEG, resultando em maior precisão e capacidade de generalização, superando o trabalho de Mahato e Paul (2020) em 2,5% e 1,39% nas métricas de acurácia e recall. A eliminação da necessidade de engenharia manual de características torna a abordagem mais adaptável e eficaz, capturando interações complexas entre os dados.

Além disso, a ResNet-50 proporciona uma solução escalável, eficiente e capaz de lidar com grandes volumes de dados de EEG, aprendendo representações hierárquicas e melhorando a generalização do modelo. Em termos de eficiência computacional, a abordagem proposta também apresenta vantagens: os autores não informam os tempos de treino e teste obtidos pelo modelo desenvolvido em seu trabalho, mas a metodologia proposta nesta tese apresenta um tempo médio de treino de aproximadamente 237 segundos e apenas 18 segundos para inferência em novos dados conforme mostrado na Tabela 3.

Dentro desse contexto, o método proposto por Mahato e Paul (2020) utiliza características extraídas dos sinais de EEG, especificamente a potência das bandas alfa e a assimetria theta, para classificar pacientes com TDM. O melhor desempenho foi obtido com o classificador SVM, alcançando 88,33% de acurácia e 90,81% de sensibilidade. No entanto, a abordagem dos autores depende de uma extração de características relativamente simples, como potência de bandas alfa e assimetria theta, o que limita a capacidade do modelo em capturar representações mais complexas, tais como oscilações que não representam ruídos nos sinais de EEG e devem ser consideradas como informações relevantes.

Em contraste, a metodologia proposta neste trabalho apresentou um desempenho superior, com mais de 95% de acurácia e sensibilidade em todas as métricas avaliadas. Esse modelo superou significativamente o método dos autores, alcançando um aumento de mais de 7% na acurácia e 4% na sensibilidade. A principal razão para essa diferença de desempenho está na capacidade da ResNet-50 em aprender representações profundas e complexas dos dados, permitindo uma classificação mais robusta e precisa. Além disso, o processo de extração de características demonstrou maior eficácia ao capturar relações mais complexas e sutis nos dados, proporcionando uma análise mais detalhada e consistente.

Por outro lado, Saeedi *et al.* (2021) apresentou diversas arquiteturas, incluindo LSTM, CNN 1D, CNN 2D, CNN 1D-LSTM e CNN 2D-LSTM, para analisar dados de EEG. Os modelos foram treinados com diferentes quantidades de épocas: 60, 50, 150 e 100, respectivamente. Ao

comparar a abordagem baseada em grafos com os modelos LSTM e CNN 1D (que possuem um número de épocas de treinamento mais próximo), observa-se que o modelo LSTM foi superado em 6% no que diz respeito à acurácia e precisão, em 11% no recall e em 7% no F1-Score. Em relação ao modelo CNN 1D, o método baseado em grafos mostrou-se competitivo, superando o modelo em até 4% no recall e 3% no F1-Score.

No que diz respeito aos modelos que combinam redes CNN e LSTM, os autores observaram resultados um pouco mais altos. O modelo CNN 1D-LSTM, que obteve uma acurácia de 99%, foi treinado com 100 épocas, o que lhe proporcionou mais tempo para aprender as relações presentes nos dados de EEG. Por outro lado, ao analisar o desvio padrão apresentado na Tabela 2, é possível notar que a abordagem proposta apresenta resultados mais consistentes, com uma variabilidade de apenas 0,12%. Em contrapartida, os modelos propostos por Saeedi *et al.* (2021) apresentaram variações superiores a 1% em todas as métricas, chegando a até 4% nas combinações LSTM e CNN 1D.

Dessa forma, considerando os valores de desvio padrão apresentados na Tabela 2, os modelos CNN 1D e CNN 2D alcançam acurácias de 93,17% e 95,06%, respectivamente, enquanto o método proposto atinge 95,71%, destacando-se como superior nessa análise. Ao estender a comparação para outras métricas, a abordagem proposta obtém 95,74% em precisão, superando os modelos CNN 1D e 2D, que alcançam 94,97% e 95,12%, respectivamente.

Replicando a análise para o modelo CNN 2D-LSTM, considerado o segundo mais robusto por Mohammed e Diyk (2023), os resultados mostram 92,99% de acurácia, 94,96% de precisão, 96,71% de recall e 94,75% no F1-Score. Em comparação, o método proposto se destaca com melhorias de 2,72% na acurácia, 0,75% na precisão e 0,93% no F1-Score. Na métrica de recall, ambos os modelos demonstram desempenho competitivo. Em relação ao modelo CNN 1D-LSTM, a metodologia proposta mantém um desempenho competitivo. No entanto, vale destacar que o CNN 1D-LSTM foi treinado por 100 épocas, enquanto a abordagem proposta utilizou apenas 50 épocas no treinamento da ResNet-50.

Quanto ao tempo de treinamento dos modelos (Tabela 3), o LSTM necessitou de aproximadamente 3253 segundos para ser treinado, enquanto o modelo CNN 1D levou 1030 segundos. O modelo CNN 2D foi o mais rápido, com 262 segundos, seguido pelo CNN 2D-LSTM, que levou 296 segundos. A abordagem mais eficiente sugerida pelos autores exigiu 405 segundos, e eles não informaram os tempos de inferência dos modelos em novos dados. Em comparação, a metodologia proposta obteve 237 segundos na etapa de treinamento e apenas

Tabela 3 – Tempos de treino e teste do método proposto para as amostras dos *datasets* I e II.

Dataset	Subconjunto	Pesquisa	Classificador	Treino(s)	Teste(s)
Dataset I	TDM vs CS	Proposta (δ -24 vértices)	RESNET-101	12.43	45.10
		Kaya e Tasci (2023)	RESNET-18	-	-
		Pratiwi (2023a)	LSTM	-	-
		Soni <i>et al.</i> (2022)	KNN	-	-
		Proposta (δ -30 vértices)	RESNET-50	237.93	18.72
Dataset II	TDM vs CS	Mohammed e Diykh (2023)	STACKED ENSEMBLE - NON-LINEAR FEATURES	-	-
			STACKED ENSEMBLE - STATISTICAL FEATURES	-	-
			STACKED ENSEMBLE - COMBINED FEATURES	-	-
		Saeedi <i>et al.</i> (2021)	CNN 1D-LSTM	405.52	-
			CNN 2D-LSTM	296.89	-
			CNN 1D	1030.78	-
			CNN 2D	262.51	-
			LSTM	3253.17	-
		Mahato e Paul (2020)	SVM	-	-
		Mahato e Paul (2019)	MLPNN	-	-
			RBFN	-	-
			LDA	-	-
			QDA	-	-
Mumtaz <i>et al.</i> (2017)	LR		-	-	

Fonte: Elaborada pelo autor.

18 segundos para a inferência em novos dados. Assim, em termos de otimização, a abordagem proposta se mostrou a mais rápida em relação às melhores combinações apresentadas pelos autores.

Já o trabalho proposto por Mohammed e Diykh (2023) optou por excluir os canais P4-LE e F&-LE devido à baixa acurácia obtida quando se consideram esses canais, sugerindo que tais canais não contribuem de forma significativa para a classificação de TDM. Em contraste, o modelo proposto neste estudo processou todos os 19 canais disponíveis, indicando que o extrator de características baseado em grafos direcionados foi capaz de identificar as melhores características dos sinais, mesmo nos canais excluídos pelos autores. Essa capacidade do extrator pode ter sido um fator decisivo para o bom desempenho do modelo.

Nesse contexto, o modelo proposto por Mohammed e Diykh (2023) foi avaliado em três cenários: características estatísticas, características não lineares e uma combinação das duas. Os cenários 1 e 2 isoladamente apresentaram resultados limitados, com o cenário 1 atingindo uma acurácia de 91.10% e o cenário 2, 88.32%. Já o terceiro cenário, combinando as duas abordagens, obteve uma acurácia de 99.11%. Em comparação, o modelo proposto por este trabalho obteve uma acurácia de 95.83%, superando os cenários 1 e 2 em todas as métricas. Dessa forma, a acurácia foi 2.73% superior ao cenário 1 e 7.51% superior ao cenário 2.

Além disso, o modelo apresentado neste estudo obteve um desvio padrão de apenas

0.12%, indicando uma baixa dispersão dos resultados, o que denota uma consistência elevada no resultado das classificações. Por outro lado, no trabalho de Mohammed e Diykh (2023), não é mencionado o desvio padrão das métricas, o que limita a análise de estabilidade de seus resultados em comparação com os resultados apresentados pelo método proposto.

Para reforçar a discussão anterior, a Figura 12 apresenta os resultados obtidos pelos diferentes métodos na métrica de acurácia. Observa-se que a abordagem proposta supera o método de Mumtaz *et al.* (2017) em até 8,33%, além de apresentar um desempenho superior de 2,5% em relação aos melhores classificadores apresentados por Mahato e Paul (2019), como o MLPNN e o RBFN. No estudo de Saeedi *et al.* (2021), a metodologia proposta também se destaca, superando o classificador LSTM em até 6,77%. No entanto, quando comparada aos classificadores CNN 1D, CNN 2D e CNN 2D-LSTM, a abordagem proposta mantém um desempenho competitivo.


Nesse contexto, ao analisar o desvio padrão dos classificadores baseados em CNN, observa-se que o método proposto supera o classificador CNN 1D em 2,54% e o CNN 2D-LSTM em até 2,72%, que é o segundo melhor modelo apresentado por Saeedi *et al.* (2021). Além disso, em relação ao trabalho de Mohammed e Diykh (2023), a metodologia proposta se mantém consistente, superando as abordagens baseadas em características não lineares e estatísticas em 7,51% e 2,73%, respectivamente.

É válido destacar que uma acurácia melhor implica em uma maior capacidade do modelo de fazer previsões corretas, refletindo um desempenho superior ao identificar padrões e classificações. Isso traz implicações importantes, como maior confiabilidade e eficiência, além de um desempenho competitivo frente a outros modelos. Logo, com um modelo mais preciso, há uma maior possibilidade de generalização para novos dados, o que garante que o modelo seja eficaz em diferentes cenários.

Neste trabalho, o método proposto demonstrou um bom desempenho, com destaque para o baixo desvio padrão nas métricas de avaliação, o que indica uma alta consistência nos resultados e uma boa generalização do modelo. Dessa forma, a abordagem de extração de características baseada em grafos se mostrou eficaz ao capturar os padrões relacionados à depressão nos sinais de EEG, representando as interações complexas entre as componentes de onda dos sinais de EEG de maneira robusta. Além disso, os tempos de treinamento e teste foram significativamente baixos, tornando o método eficiente do ponto de vista computacional.

Além disso, foi realizada uma comparação com métodos presentes na literatura, e o

Figura 12 – Análise comparativa da métrica de Acurácia utilizando diferentes métodos no Dataset II.



Fonte: Elaborada pelo autor.

modelo se mostrou competitivo, alcançando resultados semelhantes aos métodos mais recentes e de ponta. No entanto, um ponto a ser considerado é a falta de filtragem de ruídos nos sinais, o que pode estar impactando a qualidade das previsões, sendo uma área promissora para aumentar ainda mais a precisão dos resultados.

4.6 Conclusões do capítulo

Neste capítulo, foi aplicada a metodologia de análise de sinais de EEG ao cenário de classificação de depressão, utilizando duas bases de dados distintas. Os conjuntos de dados de pacientes com TDM foram processados com base no método descrito no Capítulo 3. Os índices de desempenho obtidos foram bastante promissores, destacando a acurácia (BD I: 91,03%, BD II: 95.83%), a precisão (BD I: 91,81%, BD II: 95.86%), o recall (BD I: 91,03%, BD II: 95.83%) e o F1-Score (BD I: 90,96%, BD II: 95.80%). Esses resultados evidenciam a eficácia da combinação de técnicas avançadas de aprendizado de máquina com a análise de sinais de EEG, contribuindo

para um diagnóstico mais preciso e eficiente do TDM.

Além disso, a abordagem se destaca por várias contribuições significativas, como o uso de um descritor de atributos baseado em grafos dirigidos para extrair dados de múltiplos sinais EEG, o que representa um avanço substancial na análise desse tipo de informação. Como resultado, o método demonstrou excelente desempenho na classificação, superando métodos comparativos em termos de precisão, sensibilidade, especificidade e F1-Score, com valores superiores a 90%. A estabilidade e robustez da técnica também foram evidentes, com variações mínimas nas taxas de precisão, garantindo sua confiabilidade para aplicação em diferentes amostras.

Outro ponto positivo foi a eficiência no tempo de predição, com o método alcançando tempos abaixo de um segundo por amostra, o que o torna adequado para uso em ambientes clínicos reais, onde a rapidez é fundamental. Além disso, a abordagem ressaltou a importância da extração de características específicas dos sinais de EEG, destacando aquelas mais relevantes para a classificação do TDM. Esse foco resultou em um processo de classificação tanto rápido quanto preciso. Esses resultados sugerem que a metodologia pode ser uma ferramenta valiosa na detecção e na classificação do TDM, com grande potencial para aprimorar os processos de diagnóstico clínico e, eventualmente, ser aplicada em cenários de saúde mental em tempo real.

5 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho, foi utilizada uma metodologia para representar sinais de eletroencefalograma a partir de grafos direcionados. Essa abordagem emprega um digrafo, onde os vértices correspondem aos níveis dos coeficientes de magnitude e as arestas indicam as transições, que são identificadas pelo marcador espectral δ . Esse marcador, contribui para uma análise robusta a ruídos e de baixo custo computacional, pois são definidos a partir de operações matemáticas simples.

Nesse contexto, o digrafo gerado é representado por três diferentes perspectivas: Matriz de Adjacência, Matriz Laplaciana e Matriz Laplaciana Combinatória Direcionada. Essas perspectivas são unificadas em uma estrutura tensorial denominada tensor espectral. Assim, o tensor espectral reúne as três abordagens do grafo, representadas pelas três matrizes mencionadas. Essa abordagem facilita a aplicação de redes neurais baseadas em tensores, tais como a ResNet.

Dentro dessa narrativa, a metodologia demonstrou flexibilidade ao processar múltiplos sinais, sendo utilizada para analisar sinais relacionados ao Transtorno Depressivo Maior, com foco na extração de características relevantes para o diagnóstico da condição. Essa abordagem comprovou sua eficácia e adaptabilidade, mostrando-se valiosa em diferentes contextos de aplicação.

Além disso, os resultados indicaram que a metodologia processada apresenta um grande potencial para a representar diferentes classes, em um cenário de processamento de múltiplos sinais, conforme descrito no Capítulo 4. Dessa forma, o potencial discriminatório da abordagem foi avaliado por meio de um teste estatístico teste t, que demonstrou a rejeição da hipótese nula na maioria das aplicações analisadas, evidenciando a eficácia da metodologia na diferenciação das classes em questão.

Dentro desse contexto, esta pesquisa combinou um descritor de características em conjunto com uma rede ResNet para processar sinais de EEG em dois conjuntos de dados, compostos por indivíduos diagnosticados com depressão e pessoas saudáveis. Essa primeira aplicação teve como foco a classificação de pacientes com TDM, utilizando sinais de três canais específicos (Fp1, Fp2 e Fpz), obtidos por eletrodos. Para isso, foi utilizada a base de dados MODMA (CAI *et al.*, 2022) em um cenário de classificação binária (doentes vs. saudáveis). Os resultados obtidos evidenciaram o alto desempenho da abordagem proposta, com índices de acurácia, precisão, recall e F1-Score de 91,03%, 91,81%, 91,03% e 90,96%, respectivamente.

A segunda aplicação utilizou uma base de dados distinta, porém as classes alvo

permaneceram as mesmas (TDM vs. CS). Diferentemente da primeira aplicação, esta análise processou sinais de EEG provenientes de 19 canais, incluindo Fp1, F3, F7, Fz, Fp2, F4, F8, C3, C4, Cz, P3, Pz, P4, O1, O2, T3, T4, T5 e T6. Os resultados obtidos demonstraram a robustez da metodologia proposta, evidenciando sua eficiência na distinção entre indivíduos com TDM e pessoas saudáveis. Os índices das métricas de avaliação alcançaram 91,03% de acurácia, 91,81% de precisão, 91,03% de recall e 90,96% de F1-Score, reforçando a eficácia do método.

Com base nos resultados obtidos nos experimentos, verifica-se que os tensores espectrais propostos alcançaram desempenho superior a 91% em todas as aplicações analisadas na tarefa de classificação. Além disso, a integração dos tensores espectrais com a arquitetura ResNet mostrou-se eficaz, evidenciando uma forte adaptação do modelo a essa abordagem. Esse resultado sugere que a estratégia residual empregada na ResNet contribui para um treinamento mais estável e eficiente, permitindo a captura de diferentes perspectivas dos tensores e favorecendo o aprendizado, mesmo em cenários com gradientes reduzidos.

Por fim, a metodologia proposta demonstrou sua eficácia na classificação do Transtorno Depressivo Maior, evidenciando seu potencial na análise dos sinais de EEG dos pacientes. Esses resultados indicam que a abordagem pode contribuir para o desenvolvimento de tecnologias de suporte ao diagnóstico, auxiliando na identificação da depressão de forma mais precisa e automatizada.

5.0.1 *Trabalhos Futuros*

Futuros estudos dessa metodologia buscarão ampliar o número de amostras, utilizando bases de dados de depressão mais diversas, com o objetivo de avaliar o desempenho da proposta em um conjunto de dados mais heterogêneo. O foco principal, entretanto, será aprofundar a combinação do digrafo com a rede neural proposta, uma abordagem inovadora que integra a modelagem estrutural dos dados com aprendizado profundo, visando aprimorar a detecção de transtornos depressivos e melhorar a generalização do modelo. Assim, as possíveis linhas de pesquisa para dar seguimento ao estudo proposto são:

- Aplicar técnicas de redução de ruído nos sinais resultantes da Transformada Discreta de Fourier;
- Aplicar técnicas de poda no digrafo gerado para minimizar o impacto de ruídos indesejados.
- Avaliar a eficácia da metodologia proposta para a detecção do Transtorno Depressivo Maior em exames de EEG abre a possibilidade de explorar outras condições psiquiátricas

relacionadas, como o Transtorno de Ansiedade Generalizada (TAG), Transtorno Bipolar e Transtorno do Estresse Pós-Traumático (TEPT);

- Avaliar o impacto da redução de dimensionalidade por algoritmos como o PCA nos dados pode melhorar a eficiência dos modelos, preservando as características relevantes para a classificação;
- Avaliar a aplicação de compressão de dados por meio de equações logarítmicas nos tensores espectrais pode reduzir o tamanho das matrizes geradas, evidenciando a diminuição do espaço de armazenamento necessário.

REFERÊNCIAS

- CAI, H.; YUAN, Z.; GAO, Y.; SUN, S.; LI, N.; TIAN, F.; XIAO, H.; LI, J.; YANG, Z.; LI, X. *et al.* A multi-modal open dataset for mental-disorder analysis. **Scientific Data**, Nature Publishing Group UK London, v. 9, n. 1, p. 178, 2022.
- CHUNG, F. R. K. **Spectral Graph Theory**. [S.l.]: American Mathematical Society, 1997. v. 92. (CBMS Regional Conference Series in Mathematics, v. 92).
- CUKIC, M.; RADENKOVIC, S.; STOKIC, M.; SAVIC, D. Transfer entropy applied on eeg in depression reveals aberrated dynamics. **arXiv preprint arXiv:2008.13625**, 2020.
- DIESTEL, R.; DIESTEL, R. Extremal graph theory. **Graph theory**, Springer, p. 173–207, 2017.
- DREAMSTIME. **EEG Recording**. 2023. Acessado: 2025-01-17. Disponível em: <<https://www.dreamstime.com/illustration/eeg-recording.html>>.
- ELNAGGAR, K.; EL-GAYAR, M. M.; ELMOGY, M. Depression detection and diagnosis based on electroencephalogram (eeg) analysis: A systematic review. **Diagnostics**, v. 15, n. 2, p. 210, 2025.
- ESTATÍSTICA, M. da Saúde; Instituto Brasileiro de Geografia e. **Pesquisa Nacional de Saúde 2019: percepção do estado de saúde, estilos de vida, doenças crônicas e saúde bucal**. Rio de Janeiro: IBGE, 2020. Disponível em: <<https://biblioteca.ibge.gov.br/visualizacao/livros/liv101764.pdf>>.
- GAUTHIER, S.; LEUZY, A.; RACINE, E.; ROSA-NETO, P. Diagnosis and management of alzheimer's disease: past, present and future ethical issues. **Progress in neurobiology**, Elsevier, v. 110, p. 102–113, 2013.
- GILMAN, S. E.; SUCHA, E.; KINGSBURY, M.; HORTON, N. J.; MURPHY, J. M.; COLMAN, I. Depression and mortality in a longitudinal study: 1952–2011. **Cmaj**, Can Med Assoc, v. 189, n. 42, p. E1304–E1310, 2017.
- HANDIRU, V. S.; ALIVAR, A.; HOXHA, A.; SALEH, S.; SUVISESHAMUTHU, E. S.; YUE, G. H.; ALLEXANDRE, D. Graph-theoretical analysis of eeg functional connectivity during balance perturbation in traumatic brain injury: A pilot study. **Human Brain Mapping**, Wiley Online Library, v. 42, n. 14, p. 4427–4447, 2021.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. **Proceedings of the IEEE conference on computer vision and pattern recognition**, IEEE, p. 770–778, 2016.
- HERMUCHE, A. Teoria dos grafos — introdução, definições, matriz e lista de adjacência. **Medium**, 2019. Disponível em: <<https://medium.com/@anwarhermuche/teoria-dos-grafos-introdução-definições-matriz-e-lista-de-adjacência-2252d4800a44>>.
- IBNEURO. **Córtex Pré-Frontal Medial Envolvido Quando um Comportamento Continua**. 2023. Acessado: 2025-01-17. Disponível em: <<https://ibneuro.com.br/blogs/noticias/cortex-pre-frontal-medial-envolvido-quando-um-comportamento-continua>>.

JHA, M. K.; MATHEW, S. J. Pharmacotherapies for treatment-resistant depression: How antipsychotics fit in the rapidly evolving therapeutic landscape. **American Journal of Psychiatry**, v. 180, n. 3, p. 190–199, 2023. PMID: 36855876. Disponível em: <<https://doi.org/10.1176/appi.ajp.20230025>>.

KAYA, ; TASCI, B. Electroencephalogram-based major depressive disorder classification using convolutional neural network and transfer learning. **Turkish Journal of Science and Technology**, Firat University, v. 18, n. 1, p. 207–214, 2023.

KEPPE, V. R.; PRADO, J. de A. Entrevista: Absenteísmo doença e transtorno depressivo maior e suas relações com o trabalho o trabalho. **Revista Laborativa**, v. 11, n. 2, p. 130–137, 2022.

LEITHOLD, L. **O Cálculo Com Geometria Analítica**. São Paulo: Harbra, 1994. v. 2.

MAHATO, S.; PAUL, S. Detection of major depressive disorder using linear and non-linear features from eeg signals. **Microsystem Technologies**, Springer, v. 25, p. 1065–1076, 2019.

MAHATO, S.; PAUL, S. Classification of depression patients and normal subjects based on electroencephalogram (eeg) signal using alpha power and theta asymmetry. **Journal of medical systems**, Springer, v. 44, p. 1–8, 2020.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943.

MCKNIGHT, P. E.; NAJAB, J. Mann-whitney u test. **The Corsini encyclopedia of psychology**, Wiley Online Library, p. 1–1, 2010.

MEDEIROS, A. G. Descritor de características em componentes espectrais baseado em dígrafo para detecção de doenças neurodegenerativas. 2024.

MEDEIROS, A. G.; SILVA, F. H. S.; SANTOS, L. D. O.; FILHO, P. P. R. Bi-dimensional approach based on graph neural network for alcoholism predisposition detection via eeg signals. In: **2023 International Joint Conference on Neural Networks (IJCNN)**. [S.l.: s.n.], 2023. p. 1–8.

MIEGHEM, P. V. **Graph Spectra for Complex Networks**. [S.l.]: Cambridge University Press, 2011.

MOHAMMED, H.; DIYKH, M. Improving eeg major depression disorder classification using fbse coupled with domain adaptation method based machine learning algorithms. **Biomedical Signal Processing and Control**, Elsevier, v. 85, p. 104923, 2023.

MUMTAZ, W.; XIA, L.; YASIN, M. A. M.; ALI, S. S. A.; MALIK, A. S. A wavelet-based technique to predict treatment outcome for major depressive disorder. **PloS one**, Public Library of Science San Francisco, CA USA, v. 12, n. 2, p. e0171409, 2017.

ORGANIZATION, W. H. *et al.* Depression and other common mental disorders: global health estimates. 2017.

PARIHAR, A.; SWAMI, P. D. Eeg classification of alzheimer's disease, frontotemporal dementia and control normal subjects using supervised machine learning algorithms on various eeg frequency bands. **International Journal Of Science Technology Management**, 2023.

PARK, Y.; PARK, S.; LEE, M. Effectiveness of artificial intelligence in detecting and managing depressive disorders: Systematic literature review. **Journal of Affective Disorders**, Elsevier, 2024.

PRATIWI, M. Comparative analysis of brain waves for eeg-based depression detection in the prefrontal cortex lobe using lstm. In: IEEE. **2023 7th International Conference on New Media Studies (CONMEDIA)**. [S.l.], 2023. p. 173–178.

PRATIWI, M. Comparative analysis of brain waves for eeg-based depression detection in the prefrontal cortex lobe using lstm. In: **2023 7th International Conference on New Media Studies (CONMEDIA)**. [S.l.: s.n.], 2023. p. 173–178.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

SAEEDI, A.; SAEEDI, M.; MAGHSOUDI, A.; SHALBAF, A. Major depressive disorder diagnosis based on effective connectivity in eeg signals: a convolutional neural network and long short-term memory approach. **Cognitive Neurodynamics**, Springer, v. 15, n. 2, p. 239–252, 2021.

SANDMIRE, H. F.; AUSTIN, S. D.; BECHTEL, R. C. Experience with 40,000 papanicolaou smears. **Obstetrics and Gynecology**, v. 48, n. 1, p. 56–60, 1976.

SANTOS, L. d. O.; MEDEIROS, A. G.; REGO, P. A.; FILHO, P. P. R. Graph-based eeg analysis for parkinson's disease classification: A residual neural network approach. In: IEEE. **2024 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2024. p. 1–8.

SANTOS, L. D. O.; SILVA, I. C. L.; SANTOS, M. A. D.; MEDEIROS, A. G.; FILHO, P. P. R. Efficient classification of depression using eeg through spectral graph analysis. In: IEEE. **2024 IEEE 37th International Symposium on Computer-Based Medical Systems (CBMS)**. [S.l.], 2024. p. 537–542.

SCHULZ, R.; DRAYER, R. A.; ROLLMAN, B. L. Depression as a risk factor for non-suicide mortality in the elderly. **Biological psychiatry**, Elsevier, v. 52, n. 3, p. 205–225, 2002.

SILVA, T.; Souza Jr., A. H.; MESQUITA, D. P. P. Uma introdução amigável às redes neurais para grafos. **Learning & Nonlinear Models**, SBIC, v. 19, n. 2, p. 69–81, 2021.

SIULY, S.; LI, Y.; ZHANG, Y. Eeg signal analysis and classification. **IEEE Trans Neural Syst Rehabil Eng**, Springer, v. 11, p. 141–144, 2016.

SONI, S.; SEAL, A.; YAZIDI, A.; KREJCAR, O. Graphical representation learning-based approach for automatic classification of electroencephalogram signals in depression. **Computers in Biology and Medicine**, v. 145, p. 105420, 2022. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482522002128>>.

STAM, C. J.; JONES, B.; NOLTE, G.; BREAKSPEAR, M.; SCHELTENS, P. Small-world networks and functional connectivity in alzheimer's disease. **Cerebral cortex**, Oxford University Press, v. 17, n. 1, p. 92–99, 2007.

Statplace. **Uma visão geral sobre Machine Learning**. 2024. Acesso em: 29 jan. 2025. Disponível em: <<https://statplace.com.br/blog/uma-visao-geral-sobre-machine-learning/>>.

STUDENT. The probable error of a mean. **Biometrika**, JSTOR, p. 1–25, 1908.

TATUM, W. O. **Handbook of EEG interpretation**. [S.l.]: Springer Publishing Company, 2021.

VASHA, Z. N.; SHARMA, B.; ESHA, I. J.; NAHIAN, J. A.; POLIN, J. A. Depression detection in social media comments data using machine learning algorithms. **Bulletin of Electrical Engineering and Informatics**, v. 12, n. 2, p. 987–996, 2023.

VÁSQUEZ-CORREA, J. C.; RIOS-URREGO, C. D.; ARIAS-VERGARA, T.; SCHUSTER, M.; RUSZ, J.; NÖTH, E.; OROZCO-ARROYAVE, J. R. Transfer learning helps to improve the accuracy to classify patients with different speech disorders in different languages. **Pattern Recognition Letters**, Elsevier, v. 150, p. 272–279, 2021.

WANG, B.; LI, M.; HAIHAMBO, N.; QIU, Z.; SUN, M.; GUO, M.; ZHAO, X.; HAN, C. Characterizing major depressive disorder (mdd) using alpha-band activity in resting-state electroencephalogram (eeg) combined with matrices consensus cognitive battery (mccb). **Journal of Affective Disorders**, v. 355, p. 254–264, 2024. ISSN 0165-0327. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016503272400569X>>.