

**UNIVERSIDADE FEDERAL DO MARANHÃO CENTRO DE CIÊNCIAS
EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA -
PPGEE**

DIEGO DUTRA SAMPAIO

**ANÁLISE DA CLASSIFICAÇÃO DE CRISES EPILÉPTICAS COM BASE EM
CARACTERÍSTICAS ESTATÍSTICAS DOS MOMENTOS CONJUNTOS DA
DISTRIBUIÇÃO TEMPO-FREQUÊNCIA DE SINAIS EEG UTILIZANDO
TRANSFORMADA WAVELET CONTÍNUA E REDES NEURAS PROFUNDAS**

São Luís - MA

Junho de 2025

DIEGO DUTRA SAMPAIO

**ANÁLISE DA CLASSIFICAÇÃO DE CRISES EPILÉPTICAS COM BASE EM
CARACTERÍSTICAS ESTATÍSTICAS DOS MOMENTOS CONJUNTOS DA
DISTRIBUIÇÃO TEMPO-FREQUÊNCIA DE SINAIS EEG UTILIZANDO
TRANSFORMADA WAVELET CONTÍNUA E REDES NEURAS PROFUNDAS**

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Maranhão, como parte dos requisitos à obtenção do título de Mestre em Engenharia Elétrica na Área de Automação e Controle.

São Luís, 30 de Junho 2025

UNIVERSIDADE FEDERAL DO MARANHÃO CENTRO DE CIÊNCIAS EXATAS E
TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGEE

DIEGO DUTRA SAMPAIO

Dissertação apresentada ao Programa de Programa de Pós-Graduação em Engenharia Elétrica - PPGEE da Universidade Federal do Maranhão, como requisito parcial para obtenção do título de Mestre em Área Automação e Controle, sendo aprovada em sua forma final pela banca examinadora:

Orientador: Prof. Dr. Allan Kardec Duailibe
Barros Filho
Universidade Federal do Maranhão - UFMA

Coorientadora: Prof^ª. Dra. Priscila Lima Rocha
Instituto Federal de Educação, Ciência e Tecnologia
do Maranhão - IFMA

Examinador: Prof. Dr. Francisco das Chagas de Souza
Universidade Federal do Maranhão - UFMA

Examinador: Prof^ª. Dr. Washington Luis Santos Silva
Instituto Federal de Educação, Ciência e Tecnologia
do Maranhão - IFMA

São Luís, 2025

AGRADECIMENTOS

A Deus, em primeiro lugar, por conceder-me força e perseverança ao longo de toda esta jornada acadêmica. Todos os resultados aqui alcançados são, acima de tudo, reflexo de Sua vontade soberana.

Aos meus pais, Jose Raimundo e Gracilene Bogéa, expresso minha sincera gratidão pelo cuidado constante, pelo apoio em todos os momentos e por sempre me incentivarem com seu exemplo de dedicação, esforço e honestidade.

Às minhas irmãs, Daniele Sampaio e Denise Sampaio, pelo carinho, incentivo e companheirismo contínuos. A presença de vocês foi fundamental nos momentos de dificuldade e conquista.

Ao meu orientador, Prof. Dr. Allan Kardec Barros, agradeço pelo suporte técnico, pela orientação e pelo constante estímulo intelectual, que contribuíram significativamente para a realização deste trabalho.

À minha coorientadora, Profa. Dra. Priscila Lima, registro minha sincera gratidão pelas relevantes contribuições metodológicas, pelas discussões teóricas, pela criteriosa revisão dos textos e, sobretudo, pela paciência, dedicação e incentivo ao longo do desenvolvimento desta pesquisa.

Ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Maranhão, agradeço pelo suporte acadêmico e pela oportunidade de desenvolver esta pesquisa em um ambiente de excelência, que proporcionou o crescimento profissional e científico necessário à sua realização.

Agradeço, ainda, a todos aqueles que, de maneira direta ou indireta, contribuíram para o desenvolvimento deste trabalho.

RESUMO

A epilepsia é uma condição neurológica crônica caracterizada por crises recorrentes, decorrentes de descargas elétricas cerebrais anormais, excessivas e sincrônicas. A adequada classificação dessas crises é essencial para a acurácia diagnóstica e a definição de condutas terapêuticas eficazes. Contudo, a análise visual de sinais de eletroencefalograma (EEG) permanece um procedimento laborioso, sujeito à subjetividade e à variabilidade entre observadores. Neste contexto, esta dissertação propõe uma abordagem automatizada baseada em aprendizado profundo para a classificação de quatro tipos de crises epiléticas: *Generalized Non-Specific Seizure (GNSZ)* – crise epilética generalizada não específica, *Complex Partial Seizure (CPSZ)* – crise parcial complexa, *Focal Non-Specific Seizure (FNSZ)* – crise epilética focal não específica e *Tonic-Clonic Seizure (TCSZ)* – crise tônico-clônica, a partir de características estatísticas extraídas de representações tempo-frequência obtidas por meio da Transformada Wavelet Contínua, aplicada a sinais da base pública *Temple University Hospital Seizure Corpus (TUSZ)*. Foram utilizadas três funções wavelet (Morse, Morlet e Bump), e extraíram-se os momentos estatísticos de média, variância, assimetria e curtose nos domínios temporal, espectral e conjunto, os quais serviram de entrada para modelos baseados em Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*), Memória de Longo Curto Prazo (LSTM, do inglês *Long Short-Term Memory*) e em uma arquitetura híbrida CNN-LSTM. Os experimentos indicaram que a combinação da função wavelet Morse com a arquitetura CNN-LSTM e os momentos de variância e curtose resultou no melhor desempenho geral, com acurácia média de 96,8%, precisão de 96,5%, sensibilidade de 96,9% e F1-score de 96,7%. Destaca-se o desempenho na identificação da classe TCSZ, com acurácia de 98,2% e F1-score de 98,0%. A função Morse obteve desempenho superior entre as wavelets avaliadas (acurácia média de 95,2%), superando Bump (93,7%) e Morlet (91,8%), resultado atribuído à sua maior capacidade de representar componentes de baixa frequência. Em relação aos atributos estatísticos, a variância demonstrou maior poder discriminativo (94,3%), seguida pela curtose (92,7%), enquanto a média apresentou desempenho inferior (acurácia abaixo de 84%). Os resultados demonstram o potencial da integração entre análise tempo-frequência e redes neurais profundas no desenvolvimento de sistemas inteligentes de apoio ao diagnóstico clínico da epilepsia.

Palavras-chave: Tipos de epilepsia; sinais EEG; transformada wavelet contínua; redes neurais de aprendizagem profunda; análise tempo-frequência.

ABSTRACT

Epilepsy is a chronic neurological condition characterized by recurrent seizures resulting from abnormal, excessive, and synchronous brain discharges. Accurate classification of these seizures is essential for diagnostic precision and the establishment of effective therapeutic strategies. However, the visual analysis of electroencephalogram (EEG) signals remains a laborious process, subject to subjectivity and inter-observer variability. In this context, this dissertation proposes an automated deep learning-based approach for classifying four types of epileptic seizures: Generalized Non-Specific Seizure (GNSZ), Complex Partial Seizure (CPSZ), Focal Non-Specific Seizure (FNSZ), and Tonic-Clonic Seizure (TCSZ). Statistical features were extracted from time-frequency representations obtained through the Continuous Wavelet Transform (CWT), applied to signals from the public Temple University Hospital Seizure Corpus (TUSZ) database. Three wavelet functions (Morse, Morlet, and Bump) were evaluated, from which statistical moments of mean, variance, skewness, and kurtosis were calculated in temporal, spectral, and joint domains. These features were used as input for models based on Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM) networks, and a hybrid CNN-LSTM architecture. The results showed that the combination of the Morse wavelet with the CNN-LSTM architecture and the variance and kurtosis features achieved the best overall performance, with an average accuracy of 96.8%, precision of 96.5%, sensitivity of 96.9%, and F1-score of 96.7%. The TCSZ class stood out, with accuracy of 98.2% and F1-score of 98.0%. Among the evaluated wavelets, Morse achieved the best performance (95.2%), outperforming Bump (93.7%) and Morlet (91.8%), a result attributed to its greater ability to represent low-frequency components. Regarding statistical features, variance demonstrated the highest discriminative power (94.3%), followed by kurtosis (92.7%), while the mean showed inferior performance (accuracy below 84%). These findings highlight the potential of integrating time-frequency analysis and deep neural networks in the development of intelligent systems to support the clinical diagnosis of epilepsy.

Keywords: *Epilepsy types; EEG signals; continuous wavelet transform; deep learning neural networks; time-frequency analysis.*

LISTA DE FIGURAS

Figura 1 – Anatomia básica do neurônio.	15
Figura 2 – Principais estruturas neuronais.	26
Figura 3 – Propagação do impulso nervoso e fases do potencial de ação.	27
Figura 4 – Sistema Internacional 10-20 de localização dos eletrodos.....	29
Figura 5 – Diagrama simplificado do sistema de aquisição de sinais biopotenciais.	30
Figura 6 – Esquema de aquisição de EEG através de eletrodos e amplificação do sinal.....	30
Figura 7 – Decomposição do sinal EEG em bandas de frequência.....	34
Figura 8 – Classificação operacional das crises epiléticas segundo a IIAE (2017)	38
Figura 9 – Esquemático da classificação do tipo de epilepsia.....	39
Figura 10 – Representação da f nos domínios do tempo e frequência.....	42
Figura 11 – Representação da g nos domínios do tempo e da frequência.	43
Figura 12 – Comparativo de resoluções no domínio temporal e de frequência.	45
Figura 13 – Plano resolução tempo-frequência Transformada de Fourier de Curto-Prazo.	46
Figura 14 – Distribuição da resolução tempo-frequência na Transformada Wavelet.....	48
Figura 15 – Representação da resolução tempo-frequência na Transformada Wavelet.....	48
Figura 16 – Estrutura típica de uma Rede Neural Convolutiva (CNN).	57
Figura 17 – Operação de convolução entre uma imagem de entrada e um filtro.	58
Figura 18 – Operações de pooling: max pooling e <i>average pooling</i> com janela	61
Figura 19 – Representação esquemática de uma Rede Neural Recorrente (RNN) e seu desdobramento temporal.....	63
Figura 20 – Estrutura de repetição em uma arquitetura LSTM.	66
Figura 21 – Esquema interno da célula LSTM, destacando o estado da célula (C_t) e o fluxo regulado de informações.	68

Figura 22 – Estrutura funcional de uma porta LSTM: camada densa com ativação sigmoide seguida por operação de multiplicação ponto a ponto.	68
Figura 23 – Porta de esquecimento em uma unidade LSTM.	69
Figura 24 – Porta de entrada em uma unidade LSTM.	70
Figura 25 – Atualização do estado da célula em uma unidade LSTM.	70
Figura 26 – Cálculo da saída de uma unidade LSTM.	71
Figura 27 – Arquitetura de um modelo CNN-LSTM.	73
Figura 28 – Diagrama Esquemático.	76
Figura 29 – Representação esquemática da formação do conjunto de matrizes M_j	80
Figura 30 – Modelo CNN.....	84
Figura 31 – Modelo LSTM.	85
Figura 32 – Modelo CNN-LSTM.	86

LISTA DE TABELAS

Tabela 1 – Desempenho do modelo CNN aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	89
Tabela 2 – Desempenho do modelo CNN aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	89
Tabela 3 – Desempenho do modelo CNN aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	90
Tabela 4 – Desempenho do modelo LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	92
Tabela 5 – Desempenho do modelo LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	92
Tabela 6 – Desempenho do modelo LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	92
Tabela 7 – Desempenho do modelo CNN-LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	95
Tabela 8 – Desempenho do modelo CNN-LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	95
Tabela 9 – Desempenho do modelo CNN-LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	95
Tabela 10 – Desempenho do modelo CNN aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	97
Tabela 11 – Desempenho do modelo CNN aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	97
Tabela 12 – Desempenho do modelo CNN aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	100

Tabela 13 – Desempenho do modelo LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	100
Tabela 14 – Desempenho do modelo LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	100
Tabela 15 – Desempenho do modelo LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	104
Tabela 16 – Desempenho do modelo CNN-LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	104
Tabela 17 – Desempenho do modelo CNN-LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	104
Tabela 18 – Desempenho do modelo CNN-LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	104
Tabela 19 – Desempenho do modelo CNN aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	106
Tabela 20 – Desempenho do modelo CNN aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	106
Tabela 21 – Desempenho do modelo CNN aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	106
Tabela 22 – Desempenho do modelo LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	109
Tabela 23 – Desempenho do modelo LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.....	109

Tabela 24 – Desempenho do modelo LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.....	109
Tabela 25 – Desempenho do modelo CNN-LSTM aplicado as conjuntas condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morse.....	111
Tabela 26 – Desempenho do modelo CNN-LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Bump.	111
Tabela 27 – Desempenho do modelo CNN-LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas Wavelet Morlet.	112

LISTA DE GRÁFICOS

Gráfico 1 – Comparação dos Resultados do Modelo CNN com Transformadas Wavelet com Base nas Médias das Características Estatísticas Temporais.	91
Gráfico 2 – Comparação dos Resultados do Modelo LSTM com Transformadas Wavelet com Base nas Médias das Características Estatísticas Temporais.....	94
Gráfico 3 – Comparação dos Resultados do Modelo CNN-LSTM com Transformadas Wavelet com Base nas Médias das Características Estatísticas Temporais.	97
Gráfico 4 – Comparação dos Resultados do Modelo CNN com Transformadas Wavelet com Base nas Médias das Características Estatísticas Espectrais.....	100
Gráfico 5 – Comparação dos Resultados do Modelo LSTM com Transformadas Wavelet com Base nas Médias das Características Estatísticas espectrais.....	102
Gráfico 6 – Comparação dos Resultados do Modelo CNN com Transformadas Wavelet com Base nas Médias das Características Estatísticas Espectrais.....	105
Gráfico 7 – Comparação dos Resultados do Modelo CNN com Transformadas Wavelet com Base nas Médias das Características Estatísticas conjuntas.....	108
Gráfico 8 – Comparação dos Resultados do Modelo CNN com Transformadas Wavelet com Base nas Médias das Características Estatísticas conjuntas.	111
Gráfico 09 – Comparação dos Resultados do Modelo CNN com Transformadas Wavelet com Base nas Médias das Características Estatísticas conjuntas.	113
Gráfico 10 – Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da média	114
Gráfico 11 – Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da variância.	114
Gráfico 12 – Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da curtose	115
Gráfico 13 – Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da assimetria.....	115
Gráfico 14 – Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência.....	116

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Revisão bibliográfica	17
1.2 Justificativa	21
1.3 Objetivos	22
1.3.1 Objetivo geral.....	22
1.3.2 Objetivos específicos.....	22
2. REFERENCIAL TEÓRICO	24
2.2 Aquisição do Sinal EEG.	28
2.3 Características do sinal EEG.	31
2.3.1 Características Temporais do Sinal EEG.....	32
2.3.2 Características Espectrais do Sinal EEG.....	33
2.3.3 Características Tempo-Frequência do Sinal EEG	35
2.4 Epilepsia	36
2.5 Extração de características.	39
2.5.1 Processamento de Sinal no Domínio Tempo-Frequência.....	39
2.5.1.1 <i>Transformada de Fourier</i>	41
2.5.1.2 <i>Transformada Wavelet</i>	44
2.5.1.3 <i>Momentos Condicionais e Conjuntos da Distribuições Tempo-Frequência</i>	51
2.6 Classificação	56
2.6.1 Redes Neurais Convolucionais	56
2.6.1.1 <i>Camada Convolucional</i>	58
2.6.1.2 <i>Camadas de Pooling</i>	60
2.6.1.3 <i>Camadas Totalmente Conectadas</i>	62
2.6.2 RNN	63
2.6.3 LSTM.....	65
2.6.3.1 <i>Arquitetura Funcional e Mecanismos de Controle de Memória nas Redes LSTM</i>	67
2.6.3.2 <i>Etapas do Processamento Sequencial na Célula LSTM.</i>	67
2.6.4 Modelos Híbridos.....	71

3. METODOLOGIA.	75
3.1 Banco de dados EEG.....	77
3.2 Pré-processamento do sinal de EEG.....	78
3.3 Extração de características do sinal de EEG	79
3.4 Modelos de classificação das crises epilépticas.....	82
4. RESULTADOS E DISCUSSÃO	88
4.1 Análise temporal.	88
4.2.1 Análise Temporal utilizando Redes Neurais Convolucionais (CNN).....	88
4.2.2 Análise Temporal utilizando Redes Neurais LSTM.....	91
4.2.3 Análise Temporal utilizando a Rede Neural Híbrida CNN-LSTM.	94
4.2 Análise espectral.	97
4.2.1 Análise Espectral utilizando Redes Neurais Convolucionais (CNN).....	97
4.2.2 Análise Espectral utilizando Redes Neurais LSTM.	100
4.2.3 Análise Espectral utilizando a Rede Neural Híbrida CNN-LSTM.	102
4.3 Análise conjunta tempo-frequência.	105
4.3.1 Análise Conjunta Tempo-Frequência utilizando Modelo CNN	105
4.3.2 Análise Tempo-Frequência utilizando Modelo LSTM.....	108
4.3.3 Análise Tempo-Frequência utilizando o Modelo CNN-LSTM.....	111
4.4 Análise Comparativa das Abordagens no Domínio do Tempo, Frequência e Tempo-Frequência.	113
4.5 Análise dos Resultados Obtidos	117
4.5.1 Relevância dos achados.....	117
4.5.2 Desempenho das Transformadas <i>Wavelet</i>	118
4.5.3 Arquiteturas de Redes Neurais.	119
4.5.4 Limitações do Estudo	120
5. CONCLUSÃO	122
REFERÊNCIAS	124

1. INTRODUÇÃO

A epilepsia é uma das doenças neurológicas crônicas de maior prevalência no mundo, acometendo aproximadamente 50 milhões de pessoas globalmente (Zhang et al., 2024). Essa condição é caracterizada por crises epilépticas recorrentes e espontâneas, geralmente desencadeadas por descargas elétricas paroxísticas, excessivas e sincrônicas em populações de neurônios corticais (Fisher et al., 2017; Habermehl et al., 2025). Tais episódios comprometem a atividade elétrica cerebral normal e podem ocasionar alterações transitórias na consciência, no controle motor, na percepção sensorial e no comportamento (Zhang et al., 2024).

Apesar de sua ampla distribuição global, a epilepsia afeta de maneira desproporcional populações de regiões de baixa e média renda, onde aproximadamente 80% dos indivíduos com a condição não recebem diagnóstico ou tratamento adequados (Pellinen, 2022). Esse cenário é agravado por fatores como barreiras socioeconômicas, escassez de profissionais especializados e o estigma ainda associado à doença, os quais dificultam o acesso a cuidados neurológicos qualificados (Pellinen, 2022).

Estudos epidemiológicos reforçam a gravidade desse cenário. De acordo com uma revisão sistemática e meta-análise conduzida por Alva Díaz et al. (2021), a prevalência de epilepsia ativa na América Latina e no Caribe é de aproximadamente 9,06 casos por 1 000 habitantes, com uma incidência anual estimada de 139 novos casos por 100 000 habitantes. No contexto brasileiro, dados de Buainain et al. (2022), obtidos na região Sudeste, revelam que a maioria dos pacientes atendidos em centros de referência é composta por adultos em idade produtiva, o que evidencia o impacto socioeconômico da doença sobre a população economicamente ativa e os sistemas de saúde.

Diante desses desafios, torna-se essencial adotar estratégias que favoreçam o diagnóstico precoce, ampliem o acesso a serviços especializados e promovam a individualização terapêutica. Essas ações são fundamentais não apenas para o controle efetivo das crises, mas também para a redução dos impactos negativos sobre a qualidade de vida dos pacientes e a sobrecarga nos sistemas de saúde.

Nesse contexto, o eletroencefalograma (EEG) configura-se como uma das principais ferramentas diagnósticas na prática clínica para o monitoramento da atividade elétrica cerebral, destacando-se por sua natureza não invasiva, portabilidade e ampla acessibilidade (Benedetti; Guerriero; Press, 2023). A técnica baseia-se na colocação de eletrodos sobre o couro cabeludo, os quais registram variações nos potenciais elétricos resultantes da atividade pós-sináptica de populações neuronais localizadas no córtex cerebral (Kerr et al., 2024). Por sua capacidade de

registrar alterações dinâmicas da atividade cortical, o EEG é particularmente útil na detecção de eventos transitórios, como as descargas epileptiformes que caracterizam as crises epiléticas. A correta identificação do tipo de crise epilética — classificadas como de início focal, generalizado ou de origem indeterminada — constitui, portanto, uma etapa essencial no processo diagnóstico. Essa distinção, de acordo com as diretrizes da Liga Internacional contra a Epilepsia (*ILAE, do inglês International League Against Epilepsy*), constitui um fator determinante para a definição de condutas terapêuticas adequadas e para o planejamento individualizado do manejo clínico (BENICZKY et al., 2025).

Classificações imprecisas podem comprometer significativamente a eficácia do tratamento, resultando no aumento da frequência e gravidade das crises, em efeitos adversos relacionados ao uso inadequado de fármacos e, em casos extremos, na indicação indevida de intervenções cirúrgicas (Montenegro; Valente, 2024). Além disso, a caracterização precisa do tipo de crise contribui para a identificação da zona epileptogênica e o mapeamento dos padrões de propagação da atividade cerebral — aspectos fundamentais para a definição de estratégias terapêuticas baseadas em evidências (Beniczky et al., 2025).

Embora o EEG represente um recurso valioso nesse processo, sua análise tradicional ainda é predominantemente visual e depende da interpretação especializada de longos registros, o que exige tempo, atenção contínua e está sujeito à variabilidade entre observadores (Zhang et al., 2024). Diante dessas limitações, os avanços tecnológicos têm favorecido o desenvolvimento de métodos automatizados de análise de EEG, os quais se mostram promissores ao possibilitarem diagnósticos mais ágeis, padronizados e menos suscetíveis à subjetividade humana (Yan Et Al., 2025; Kerr et al., 2024).

Nesse cenário, métodos baseados em inteligência artificial (IA), particularmente aqueles fundamentados em Aprendizado de Máquina (Machine Learning – ML) e Aprendizado Profundo (Deep Learning – DL), têm se mostrado altamente promissores na análise automatizada de sinais eletroencefalográficos, devido à sua capacidade de identificar padrões complexos e sutis relacionados à atividade ictal (Saadoon; Khalil; Batikh, 2025). Essas ferramentas automáticas representam um avanço significativo em relação à análise visual tradicional, ao possibilitarem diagnósticos mais rápidos, reproduzíveis e menos sujeitos à variabilidade humana, além de reduzirem a sobrecarga dos especialistas clínicos.

Entretanto, a natureza dinâmica e não estacionária do EEG impõe desafios à análise convencional baseada exclusivamente nos domínios temporal ou espectral, limitando a extração de informações relevantes para a caracterização precisa das crises (Saadoon; Khalil; Batikh, 2025). Nesse contexto, abordagens que operam no domínio tempo-frequência têm se destacado por oferecer uma representação mais completa do sinal, permitindo observar simultaneamente

sua evolução temporal e sua composição espectral — aspecto fundamental para a detecção e classificação de eventos epileptiformes (Chen et al., 2023).

Dentre as abordagens aplicadas à análise no domínio tempo-frequência, a Transformada Wavelet Contínua (TWC) tem se destacado por sua eficácia na decomposição dos sinais em componentes simultaneamente localizados no tempo e na frequência, proporcionando representações com alta resolução e riqueza informacional (Disli et al., 2025). Essas representações permitem a extração de características que capturam padrões estruturais relevantes para a diferenciação entre distintos tipos de crises epiléticas. Tais informações enriquecem o processo de classificação automatizada ao serem utilizadas como entrada em modelos computacionais de aprendizagem, contribuindo para o aumento da acurácia e da robustez dos sistemas inteligentes de apoio ao diagnóstico (Ghudar; Mstafa, 2025).

A integração entre essas técnicas avançadas de análise de sinais e os modelos de aprendizado profundo representa, assim, um avanço significativo no desenvolvimento de sistemas inteligentes voltados ao diagnóstico da epilepsia. Tais soluções têm o potencial de ampliar o acesso a avaliações neurológicas especializadas, sobretudo em contextos marcados pela escassez de recursos técnicos e humanos, promovendo maior equidade no cuidado em saúde (Disli Et Al., 2025; Ghudar; Mstafa, 2025).

Neste trabalho, realiza-se uma análise quantitativa do desempenho da classificação automática de diferentes tipos de crises epiléticas, incluindo convulsão generalizada não específica (GNSZ), convulsão parcial complexa (CPSZ), convulsão focal não específica (FNSZ) e convulsão tônico-clônica (TCSZ). A abordagem adotada fundamenta-se na extração de características no domínio tempo-frequência dos sinais EEG, por meio da aplicação da Transformada Wavelet Contínua (CWT). A partir da distribuição tempo-frequência, são extraídas características baseadas em momentos conjuntos, que são então utilizadas como entrada em modelos de redes neurais profundas voltados à tarefa de classificação. O desempenho desses modelos é avaliado por meio de métricas quantitativas, como acurácia, precisão, recall e F1-score. Os resultados obtidos visam contribuir para o desenvolvimento de sistemas automáticos, eficientes e confiáveis, capazes de oferecer suporte objetivo aos profissionais de saúde no diagnóstico e monitoramento de pacientes com epilepsia.

1.1 Revisão Bibliográfica

A eletroencefalografia (EEG) é uma das principais ferramentas utilizadas no monitoramento e diagnóstico de distúrbios neurológicos, especialmente a epilepsia. Essa condição é marcada por descargas elétricas anormais e sincrônicas no cérebro, que provocam

crises recorrentes e impactam negativamente a qualidade de vida dos pacientes. Classificar corretamente os tipos de crise é essencial para um diagnóstico preciso, definição do tratamento mais adequado e acompanhamento clínico contínuo. No entanto, a análise visual dos sinais de EEG é um processo demorado, sujeito a interpretações diferentes entre especialistas e com alta variabilidade (AANESTAD Et Al., 2024; CHEN et al., 2025).

Diante das limitações associadas à análise visual do EEG — como subjetividade, tempo de execução elevado e variabilidade interobservador —, têm-se intensificado os esforços no desenvolvimento de abordagens automatizadas baseadas em inteligência artificial para a detecção e classificação de crises epiléticas. Essas soluções computacionais visam mitigar as fragilidades dos métodos tradicionais, oferecendo maior acurácia diagnóstica, reprodutibilidade dos resultados e escalabilidade clínica, mesmo em contextos com infraestrutura limitada (Bai; Litscher; Li, 2025; Moutonnet et al., 2024). Ademais, ao permitir a análise em tempo real, esses sistemas viabilizam intervenções precoces e monitoramento contínuo, contribuindo diretamente para a melhoria do cuidado ao paciente (Chen et al., 2025).

A análise dos sinais eletroencefalográficos (EEG) pode ser realizada em três domínios distintos: temporal, espectral e tempo-frequência. O domínio temporal avalia as variações da amplitude do sinal ao longo do tempo, sendo útil na identificação de alterações abruptas relacionadas à atividade epilética. O domínio espectral permite a decomposição do sinal em seus componentes de frequência, possibilitando a análise de oscilações associadas a diferentes estados neurofisiológicos. O domínio tempo-frequência, por sua vez, integra informações temporais e espectrais, fornecendo uma representação simultânea da evolução espectral do sinal, o que é particularmente relevante na caracterização de eventos transitórios e não estacionários, como as crises epiléticas (Morales; Bowers, 2022; Desli et al., 2022).

Nesse escopo, as transformadas wavelet têm sido amplamente utilizadas como técnicas eficazes para a representação multirresolução de sinais EEG. A Transformada Wavelet Contínua (TWC), em particular, viabiliza a decomposição do sinal em múltiplas escalas com alta resolução temporal, favorecendo a detecção de padrões dinâmicos localizados no tempo. Arts e van den Broek (2022) propuseram uma variante otimizada, denominada fCWT, adequada para aplicações em tempo real. Além disso, Wang, Ristaniemi e Cong (2021) demonstraram que representações tempo-frequência derivadas da TWC, quando empregadas como entrada em redes neurais convolucionais, podem alcançar acurácia superior a 99%, evidenciando o potencial dessa abordagem na classificação automatizada de crises epiléticas.

No contexto da Transformada Wavelet Discreta (DWT), diversos estudos destacam sua eficácia na extração de características relevantes para a classificação automática de crises

epilépticas (ACHARYA Et Al., 2018; BAIRAGI et al., 2021). Essa técnica permite a análise multiescala dos sinais EEG, com maior eficiência computacional em comparação à TWC, sendo especialmente útil em sistemas com restrições de tempo ou recursos. Em um estudo recente, Albaqami, Hassan e Datta (2022) empregaram a Transformada Wavelet Complexa Dual-Tree (DTCWT) para distinguir diferentes tipos de crise, obtendo desempenho superior com F1-score acima de 99%, evidenciando a robustez da abordagem em cenários multiclass. Além disso, métodos alternativos como a Wavelet Empírica (EWT) têm sido utilizados com sucesso para segmentar o sinal de EEG em sub-bandas informativas, possibilitando a extração de características discriminativas relevantes (Murariu et al., 2024; Gulenc; Ozturk, 2024).

Com o objetivo de aprimorar a acurácia dos sistemas de classificação de crises epilépticas, diversas abordagens têm integrado redes neurais profundas a representações extraídas por meio de transformadas tempo-frequência. Hossein-Nejad e Nasri (2023) propuseram uma arquitetura baseada em redes siamesas, utilizando características extraídas via transformadas wavelet para comparar padrões de EEG em pares de entrada. Li (2022) combinou autoencoders empilhados com o algoritmo CatBoost, explorando a complementaridade entre aprendizado não supervisionado e métodos de boosting para detecção de crises. Rabby et al. (2021) e Fan et al. (2022) demonstraram que mapas tempo-frequência, quando utilizados como entrada para redes neurais profundas, promovem ganhos expressivos no desempenho classificatório, evidenciando a importância da qualidade da representação do sinal. Liu e Zeng (2022), por sua vez, implementaram uma versão da ResNet com representações multiescala, mostrando que arquiteturas residuais são eficazes na extração de características hierárquicas em sinais EEG.

Estudos mais recentes reforçam essa tendência de integração entre aprendizado profundo e representações tempo-frequência. Liu et al. (2025) apresentaram um modelo baseado na combinação de meta-learning e aprendizado por comitê, visando melhorar a generalização e robustez dos classificadores em contextos variados. Adicionalmente, Wong et al. (2025) propuseram uma arquitetura convolucional com anotações por canal (channel-annotated CNN), que incorpora informações espaciais explícitas para aumentar a interpretabilidade clínica dos modelos, aspecto cada vez mais valorizado em aplicações em saúde.

Modelos baseados em redes neurais profundas, como redes convolucionais (CNNs), redes recorrentes do tipo LSTM e arquiteturas híbridas CNN-LSTM, têm alcançado desempenho superior em diversos benchmarks voltados à detecção e classificação de crises epilépticas. As CNNs destacam-se pela capacidade de extrair características espaciais

discriminativas diretamente das representações do sinal, favorecendo a identificação de padrões morfológicos associados a eventos epilépticos (Anwar; Eldeib, 2020). Em contrapartida, as redes LSTM demonstram elevada eficácia na modelagem de dependências temporais de longo prazo, atributo essencial para a análise de sequências temporais complexas, como os sinais de EEG (Saeedinia et al., 2024).

Arquiteturas híbridas CNN-LSTM têm sido amplamente investigadas como soluções sinérgicas, ao combinarem a extração espacial de características com a dinâmica temporal do sinal. Estudos conduzidos por Omar et al. (2023), Wang et al. (2023) e Cao et al. (2025) evidenciam o alto desempenho dessas arquiteturas em tarefas de detecção automatizada de crises, frequentemente superando abordagens univariadas. Adicionalmente, Khan, Farooq e Khan (2022) propuseram modificações nas camadas de ativação de redes convolucionais tradicionais, o que resultou em ganhos significativos em sensibilidade e especificidade, destacando a importância da otimização arquitetural no desenvolvimento de modelos mais robustos e eficientes para aplicações clínicas.

A utilização de bancos de dados representativos e bem anotados é essencial para a validação e a generalização dos modelos de detecção automática de crises epilépticas. Entre os repositórios disponíveis, o Temple University Seizure Corpus (TUSZ) destaca-se como uma das bases mais amplamente empregadas na literatura, por oferecer registros EEG de longa duração, anotados por especialistas e abrangendo uma diversidade de pacientes, protocolos e tipos de crise. Trabalhos como os de Stragier, Vanabelle e Tahry (2021) e Rivera et al. (2024) demonstraram a viabilidade da utilização de redes neurais convolucionais (CNNs) treinadas sobre o TUSZ, atestando sua adequação para o desenvolvimento e avaliação de soluções baseadas em inteligência artificial. Especificamente, Rivera et al. (2024) exploraram diferentes arquiteturas convolucionais para a classificação multicategoria de crises epilépticas, obtendo métricas expressivas de desempenho.

Embora técnicas mais tradicionais, como a decomposição em modos empíricos (EMD) combinada com máquinas de vetor de suporte (SVM), ainda apresentem bons resultados em cenários com limitações computacionais (Wijayanto et al., 2019), há uma tendência crescente de incorporação de modelos mais sofisticados e arquiteturas profundas. Um exemplo notável é o MP-SeizNet, proposto por Albaqami, Hassan e Datta (2023), que combina redes convolucionais multipercurso com redes bidirecionais LSTM (Bi-LSTM), alcançando desempenho elevado em tarefas de classificação multiclasse. Essas arquiteturas refletem a convergência entre técnicas de análise tempo-frequência, aprendizado profundo e estratégias

avançadas de modelagem, consolidando uma linha promissora para a construção de sistemas mais sensíveis e adaptáveis.

Em síntese, a integração de transformadas como a TWC com arquiteturas neurais profundas representa um caminho promissor para o desenvolvimento de soluções automatizadas de apoio ao diagnóstico clínico. Tais sistemas têm se mostrado eficazes na geração de resultados acurados, interpretáveis e viáveis para implementação em ambientes com restrições operacionais. Nesse cenário, torna-se imperativo continuar a investigação de metodologias híbridas e inovadoras de extração de características e modelagem computacional, promovendo a expansão do conhecimento científico e contribuindo para a modernização dos protocolos de diagnóstico em neurologia clínica.

1.2 Justificativa

A epilepsia é uma condição neurológica crônica de elevada prevalência mundial, afetando aproximadamente 50 milhões de pessoas e gerando impactos significativos na qualidade de vida dos pacientes, especialmente no que se refere à autonomia, segurança e funcionalidade nos âmbitos cognitivo, social e ocupacional (Ozdemir; Tuglu, 2025). O diagnóstico preciso e a correta classificação dos diferentes tipos de crises epiléticas — como crises focais, generalizadas e de origem indeterminada — são etapas fundamentais para a definição de condutas terapêuticas adequadas, que incluem desde o uso racional de medicamentos até a indicação de procedimentos cirúrgicos e o planejamento de estratégias preventivas (Gill et al., 2025).

Embora avanços importantes tenham sido alcançados na área médica, o diagnóstico da epilepsia ainda depende, em grande parte, da análise visual dos sinais eletroencefalográficos (EEG) por especialistas. Essa prática, apesar de consolidada na rotina clínica, apresenta limitações relevantes, por demandar tempo, atenção contínua e estar sujeita à variabilidade entre observadores. Estudos apontam que essa variabilidade pode ultrapassar 30%, especialmente em registros prolongados, comprometendo a uniformidade dos laudos e a confiabilidade das decisões clínicas (Beuchat et al., 2021).

Diante desse cenário, o uso de ferramentas computacionais para a detecção e classificação automática de crises epiléticas surge como uma alternativa promissora. Esses sistemas podem reduzir o tempo de análise, minimizar a subjetividade diagnóstica e ampliar o acesso a avaliações especializadas, principalmente em contextos com poucos recursos técnicos e humanos.

Além disso, diagnósticos mais ágeis e precisos favorecem a escolha do tratamento mais adequado, a prescrição correta de medicamentos e o monitoramento mais eficiente da resposta

terapêutica. Isso resulta em maior controle das crises, menos efeitos adversos e melhor qualidade de vida para os pacientes, além de auxiliar os profissionais de saúde no processo decisório.

Este trabalho propõe a análise de um sistema automático de classificação de crises epiléticas com base em sinais EEG transformados no domínio tempo-frequência, por meio da Transformada Wavelet Contínua (TWC). A partir dessas representações, são extraídas características descritivas — como os momentos conjuntos da distribuição tempo-frequência — que serão utilizadas como variáveis de entrada em modelos de classificação baseados em redes neurais. Um dos diferenciais da proposta está na diversidade de combinações entre funções da TWC e estruturas de modelagem, permitindo a comparação entre diferentes abordagens e a construção de um sistema mais robusto e adaptável a diferentes perfis clínicos.

A proposta contribui com uma metodologia complementar às existentes na literatura, permitindo sua comparação com marcos de referência consolidados e ampliando as possibilidades de investigação na área de análise de sinais biomédicos. Espera-se que os resultados beneficiem tanto a comunidade científica, ao expandir o repertório metodológico disponível, quanto a prática clínica, ao oferecer subsídios para o desenvolvimento de ferramentas computacionais úteis no apoio ao diagnóstico.

Assim, este projeto busca integrar conhecimentos das áreas de ciência dos dados, engenharia biomédica e neurociência, contribuindo para o aprimoramento de tecnologias em saúde e gerando benefícios concretos para pacientes e profissionais — com diagnósticos mais confiáveis, tratamentos mais eficazes e maior precisão na escolha e no ajuste de medicamentos antiepiléticos.

1.3 Objetivo

1.3.1 Objetivo Geral

Avaliar a eficácia de características extraídas da distribuição tempo-frequência de sinais EEG, geradas por meio da Transformada Wavelet Contínua (CWT), na classificação automática de diferentes tipos de crises epiléticas com redes neurais profundas, contribuindo para o desenvolvimento de ferramentas computacionais que auxiliem profissionais de saúde no diagnóstico da epilepsia.

1.3.2 Objetivos Específicos

- Realizar o pré-processamento dos sinais EEG multicanais referentes a distintos tipos de crises epiléticas, contemplando a análise qualitativa e a segmentação temporal dos

sinais, com o objetivo de garantir a adequação dos dados para as etapas subsequentes de extração de características e classificação;

- Obter a distribuição tempo-frequência dos segmentos dos sinais EEG por meio da Transformada Wavelet Contínua (TWC), utilizando diferentes funções wavelet-mãe, com o objetivo de viabilizar a extração de atributos relevantes à classificação dos tipos de crises epilépticas;

- Extrair os momentos estatísticos conjuntos dos momentos condicionais nos domínios temporal, espectral e tempo-frequência, a partir da distribuição tempo-frequência obtida por meio da TWC;

- Construir e treinar modelos de redes neurais profundas, utilizando como entrada os atributos extraídos das representações tempo-frequência dos sinais EEG;

- Ajustar os hiperparâmetros e a arquitetura das redes neurais, número de camadas, funções de ativação e taxa de aprendizagem, por meio de estratégias de busca sistemática e aleatória, com validação cruzada k-fold, a fim de aprimorar a classificação dos diferentes tipos de crises epilépticas.

- Avaliar o desempenho dos modelos na classificação dos diferentes tipos de crises epilépticas, por meio de métricas quantitativas como acurácia, precisão, recall e f1-score;

- Analisar comparativamente os resultados para identificar os conjuntos de características e configurações mais eficazes na classificação dos diferentes tipos de crises epilépticas.

2. REFERENCIAL TEÓRICO

A classificação de sinais eletroencefalográficos (EEG) constitui uma etapa fundamental em sistemas computacionais voltados à detecção e ao diagnóstico de condições neurológicas, como a epilepsia. Para sua implementação eficaz, é necessário compreender o fluxo completo do processamento de sinais, que, de forma geral, envolve quatro etapas principais: aquisição do sinal, pré-processamento, extração de características e, por fim, a classificação propriamente dita.

Essa última fase tem como propósito atribuir rótulos a segmentos do sinal com base em padrões previamente aprendidos, distinguindo, por exemplo, entre atividades cerebrais normais e patológicas. O sucesso dessa tarefa depende diretamente da qualidade das representações extraídas nas etapas anteriores, especialmente em sinais EEG, que são intrinsecamente ruidosos e não estacionários. Nesse cenário, técnicas de aprendizado profundo, como Redes Neurais Convolucionais (CNNs), Redes LSTM e modelos híbridos, têm se destacado por sua capacidade de identificar padrões espaciais e temporais complexos, oferecendo maior acurácia e robustez na classificação automática de eventos epiléticos.

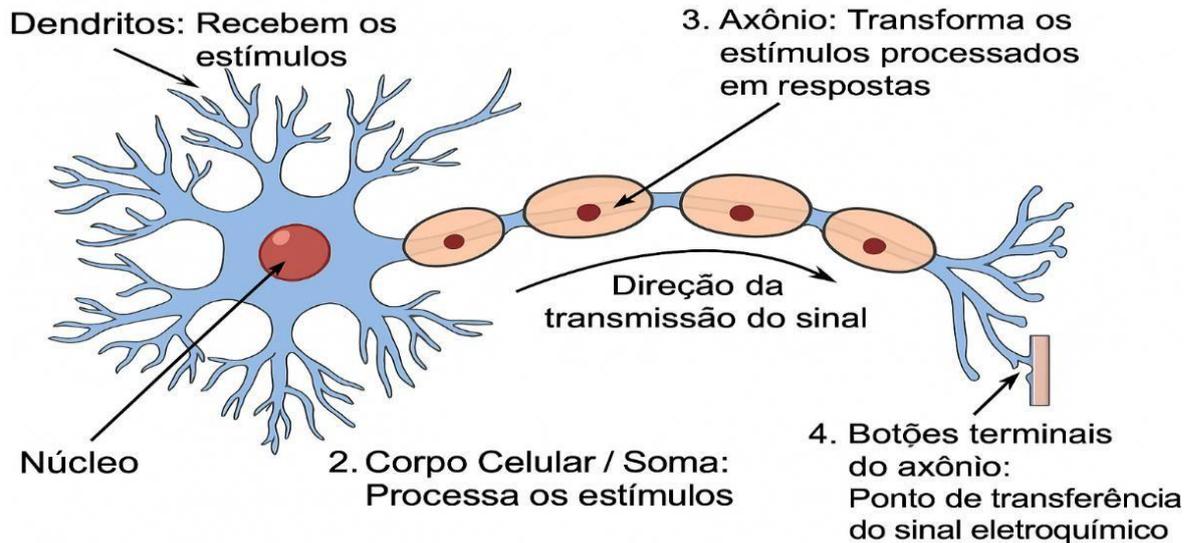
2.1 Fundamentos Neurofisiológicos da Atividade Elétrica no Cérebro

A atividade elétrica cerebral constitui um dos pilares fundamentais da funcionalidade do sistema nervoso, sendo produto da complexa dinâmica eletroquímica que ocorre nos neurônios — células altamente especializadas na recepção, integração e transmissão de sinais bioelétricos. Essa atividade emerge a partir do movimento seletivo de íons através da membrana plasmática, regulado por gradientes eletroquímicos e mediado por proteínas especializadas, como canais iônicos e bombas de transporte ativo (Bear; Connors; Paradiso, 2016; Kecskés; Peigneur; Held, 2023). Dentre esses mecanismos, destaca-se a bomba de sódio-potássio (Na^+/K^+ -ATPase), responsável por manter os gradientes iônicos essenciais para o potencial de repouso da membrana, sendo, portanto, indispensável à manutenção da excitabilidade neuronal e à condução eficiente dos impulsos nervosos (Bear; Connors; Paradiso, 2016).

A capacidade dos neurônios de conduzir impulsos nervosos está diretamente relacionada à sua organização morfofuncional. Suas principais estruturas incluem os dendritos, que recebem sinais de outras células; o corpo celular (ou soma), responsável pela integração das informações; e o axônio, que conduz o potencial de ação ao longo da fibra nervosa. Em muitos casos, o axônio é revestido por uma bainha de mielina, que acelera significativamente a propagação do impulso nervoso (Bear; Connors; Paradiso, 2016). Essas estruturas estão representadas na

Figura 1, que ilustra a anatomia básica de um neurônio e sua relação com a condução dos sinais elétricos.

Figura 1 – Anatomia básica do neurônio

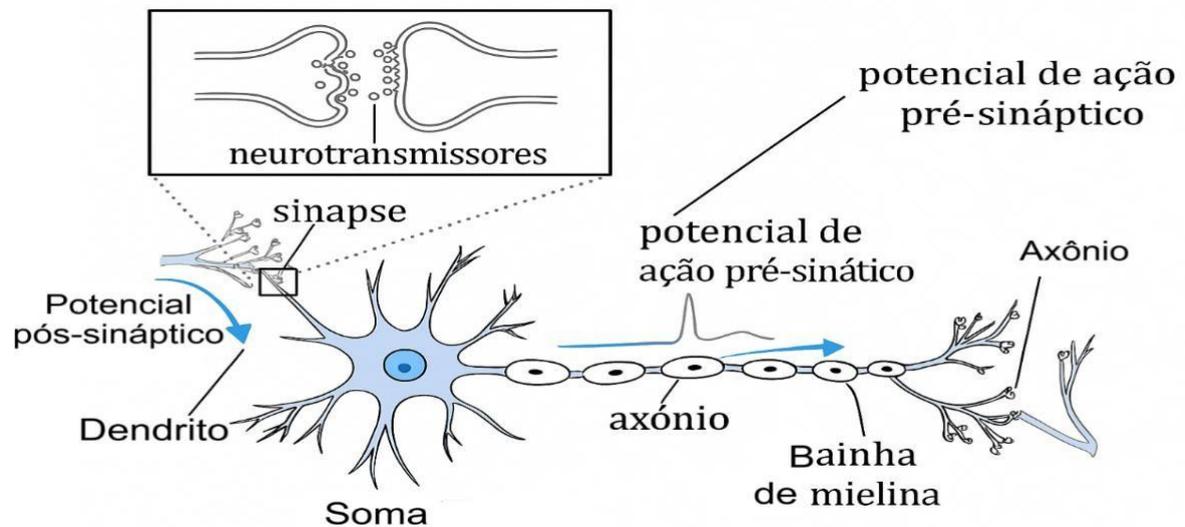


Fonte: Adaptado de Wang (2013)

A atividade elétrica gerada pelos neurônios não apenas sustenta sua excitabilidade individual, mas também viabiliza a comunicação entre células nervosas, fundamental para o funcionamento integrado do sistema nervoso. Essa comunicação ocorre nas sinapses, especializações funcionais que permitem a transferência de sinais entre neurônios (Purves et al., 2017). A maioria das sinapses é de natureza química, mediada pela liberação de neurotransmissores na fenda sináptica; no entanto, também existem sinapses elétricas, nas quais há passagem direta de corrente iônica entre células. A capacidade das sinapses de se fortalecerem ou enfraquecerem conforme a atividade — fenômeno conhecido como plasticidade sináptica — é essencial para os processos de aprendizagem e memória (Bear; Connors; Paradiso, 2016; Purves et al., 2017).

A propagação coordenada da atividade elétrica ao longo das redes sinápticas é fundamental para a realização de funções cognitivas, motoras e autonômicas complexas, refletindo a integração funcional entre diferentes regiões do sistema nervoso central (Bear; Connors; Paradiso, 2016; Purves et al., 2017). A Figura 2 apresenta uma representação esquemática das principais estruturas neuronais envolvidas nesse processo, destacando a anatomia funcional do neurônio e sua participação na condução e transmissão dos sinais bioelétricos.

Figura 2 – Principais estruturas neuronais



Fonte: Adaptado de Yamazaki et al. (2022).

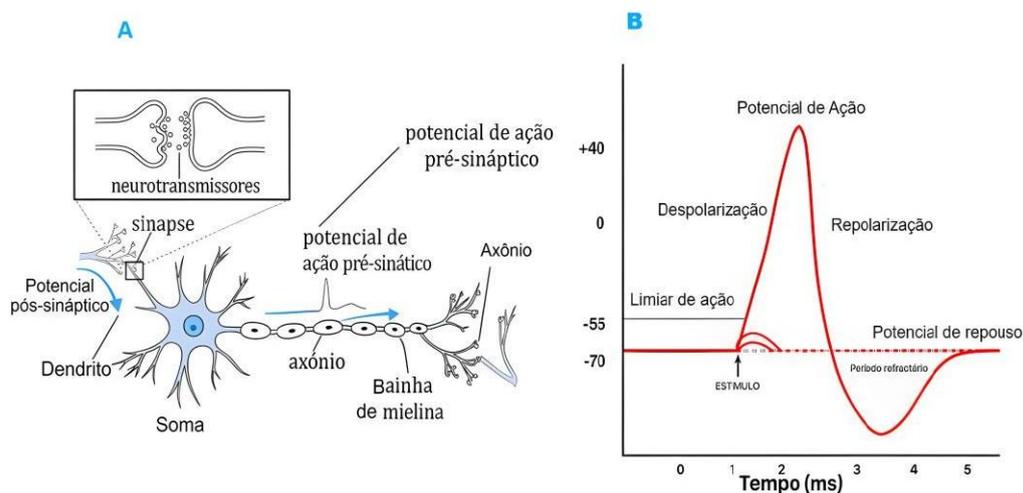
Nos circuitos neurais, a atividade elétrica e a comunicação sináptica se complementam na modulação da resposta neuronal. As sinapses podem exercer efeito excitatório ou inibitório sobre a célula pós-sináptica, influenciando diretamente seu potencial de ativação (Bear; Connors; Paradiso, 2016; Purves et al., 2017). Essas interações geram os chamados potenciais pós-sinápticos, decorrentes do fluxo de íons por canais específicos na membrana pós-sináptica, ativados pela ligação de neurotransmissores a seus receptores. A soma espacial e temporal desses sinais determina se o limiar de excitação será atingido, promovendo a geração de um potencial de ação, conforme ilustrado na figura 3. Esse processo ocorre, em geral, no segmento inicial do axônio, também chamado de zona de gatilho, uma região caracterizada por alta densidade de canais de sódio voltagem-dependentes (Bear; Connors; Paradiso, 2016; Purves et al., 2017).

O potencial de ação (PA) é um evento elétrico estereotipado, de curta duração (alguns milissegundos), caracterizado por uma rápida e transitória despolarização da membrana neuronal. Quando o potencial de membrana atinge o limiar de excitação (aproximadamente -55 mV), ocorre a abertura abrupta dos canais de sódio voltagem-dependentes (Na^+), permitindo um influxo massivo de íons Na^+ . Esse movimento leva o potencial de membrana a valores positivos, entre $+30$ e $+40$ mV. Em seguida, esses canais se inativam, e os canais de potássio (K^+) se abrem, promovendo a saída de K^+ e iniciando a repolarização da membrana. Frequentemente, há uma hiperpolarização transitória, devido à atividade prolongada dos canais de K^+ , antes que os gradientes iônicos sejam restaurados pela ação da bomba de sódio-potássio

(Na^+/K^+ -ATPase). Essa enzima é essencial para reestabelecer o potencial de repouso e garantir a manutenção da excitabilidade neuronal, ao bombear Na^+ para fora e K^+ para dentro da célula, consumindo energia na forma de ATP (Yamazaki et al., 2022; Purves et al., 2018).

Ao alcançar o terminal axonal, o PA promove a abertura de canais de cálcio (Ca^{2+}), desencadeando a liberação de neurotransmissores na fenda sináptica e reiniciando o ciclo de comunicação entre neurônios. Nas sinapses excitatórias, essa liberação gera potenciais pós-sinápticos excitatórios (PPSEs), que despolarizam a membrana da célula pós-sináptica e a aproximam do limiar de disparo. Já nas sinapses inibitórias, os neurotransmissores induzem a abertura de canais que favorecem o influxo de Cl^- ou o efluxo de K^+ , produzindo potenciais pós-sinápticos inibitórios (PPSIs), que hiperpolarizam ou estabilizam a membrana, diminuindo a probabilidade de ocorrência de um novo PA.

Figura 3 - Propagação do impulso nervoso e fases do potencial de ação



Fonte: Adaptado de Ali (2015).

A atividade elétrica cerebral registrada pelo eletroencefalograma (EEG) resulta da integração sincrônica de potenciais pós-sinápticos gerados por grandes populações de neurônios piramidais corticais, orientados perpendicularmente à superfície do crânio. Esses potenciais, principalmente os excitatórios e inibitórios, somam-se espacial e temporalmente, originando flutuações de voltagem no campo extracelular. Essas variações são suficientemente amplas para se propagarem através do tecido cerebral, do líquido cefalorraquidiano, das meninges, do osso do crânio e do couro cabeludo, sendo então captadas por eletrodos posicionados sobre a superfície craniana.

O EEG, portanto, não reflete diretamente os potenciais de ação isolados, mas sim a atividade sináptica coletiva e organizada, associada aos potenciais transmembranares lentos.

Essa dinâmica é sustentada por mecanismos celulares fundamentais, como o disparo de potenciais de ação, a transmissão sináptica e a ação contínua da bomba de sódio-potássio (Na^+/K^+ -ATPase), responsável por manter os gradientes iônicos e a excitabilidade neuronal.

Trata-se de uma medida contínua e em tempo real da atividade elétrica do cérebro, sendo uma ferramenta valiosa tanto para o estudo de funções cerebrais normais, como nos potenciais evocados por estímulos sensoriais ou cognitivos, quanto para a identificação de condições neurológicas, incluindo epilepsia, encefalopatias, distúrbios do sono e a avaliação da atividade cortical em estados de coma.

Em suma, os sinais EEG refletem uma complexa cadeia de eventos eletroquímicos que envolvem a excitabilidade dos neurônios, a transmissão sináptica e a integração em larga escala da atividade cortical. O entendimento desses mecanismos é essencial para interpretar corretamente os padrões registrados e suas alterações em condições neurológicas diversas.

2.2 Aquisição do sinal EEG

A aquisição dos sinais eletroencefalográficos (EEG) consiste em uma sequência de procedimentos técnicos voltados à captação, amplificação, digitalização e registro da atividade elétrica cerebral, registrada a partir do couro cabeludo. Esse processo é fundamental tanto para aplicações clínicas — como o diagnóstico de epilepsia, distúrbios do sono e encefalopatias — quanto para investigações em neurociência e neuroengenharia.

A primeira etapa desse processo envolve a preparação do sujeito e do couro cabeludo. A pele deve ser devidamente higienizada com álcool ou solução abrasiva suave, com o objetivo de reduzir a impedância entre os eletrodos e o tecido cutâneo. Em seguida, aplica-se um gel ou pasta condutora, essencial para garantir a transmissão eficiente dos sinais elétricos da superfície da pele até os eletrodos (JAdeja, 2021; Qin et al., 2023).

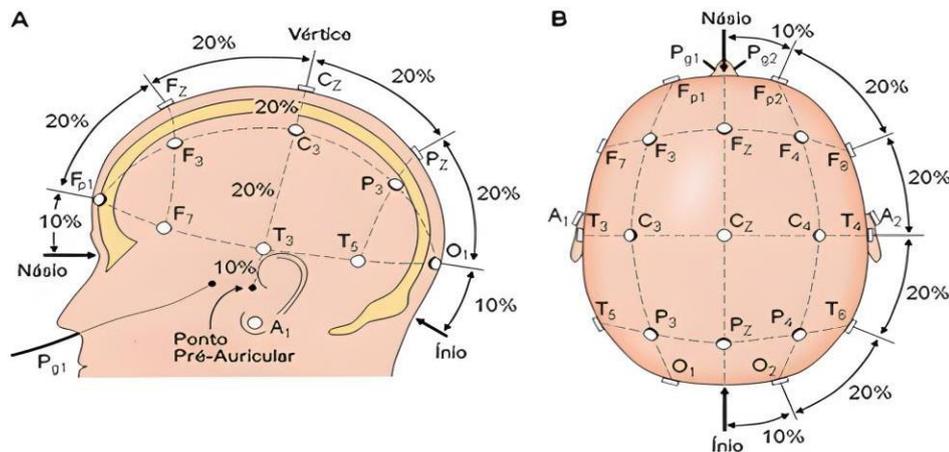
Após essa preparação, procede-se à fixação dos eletrodos sobre o couro cabeludo. Esses sensores são responsáveis por captar variações de voltagem geradas pela atividade elétrica cerebral. São geralmente constituídos por discos metálicos de alta condutividade — como aço inoxidável, ouro, estanho ou prata clorada —, materiais que asseguram boa estabilidade do sinal e minimizam os efeitos de polarização durante o registro. O uso de gel eletrolítico entre os eletrodos e a pele é indispensável para reduzir a impedância de contato e maximizar a qualidade da captação (Qin et al., 2023).

As variações de potencial detectadas pelos eletrodos refletem, em sua maioria, os potenciais pós-sinápticos de neurônios piramidais do córtex cerebral — a camada mais externa do cérebro, composta por substância cinzenta e responsável por funções superiores como

percepção sensorial, linguagem, memória e cognição. Essas variações tornam-se registráveis principalmente quando há ativação coordenada e sincronizada desses neurônios (Jadeja, 2021; Qin et al., 2023).

Para garantir que essa atividade elétrica seja registrada de maneira padronizada e comparável entre diferentes indivíduos e sessões clínicas, é utilizado o sistema internacional 10-20 para a colocação dos eletrodos. Esse sistema estabelece pontos específicos de posicionamento com base em proporções anatômicas do crânio, como ilustrado na Figura 4. Os marcos anatômicos utilizados incluem o nasion (região entre o nariz e a testa), o inion (protuberância occipital) e pontos laterais, que servem de referência para distribuir os eletrodos com espaçamentos de 10% ou 20% ao longo do comprimento craniano (Duun Henriksen et al., 2020; Rocha, 2022; Ulate Campos; Loddenkemper, 2023). Cada eletrodo é identificado por uma letra, que representa a região cerebral correspondente (F – frontal, T – temporal, C – central, P – parietal, O – occipital), e por um número que indica o lado do crânio: números ímpares se referem ao hemisfério esquerdo, pares ao direito, e a letra “z” é usada para os pontos localizados na linha média. Essa nomenclatura padronizada facilita a interpretação clínica dos registros e a correlação entre a topografia do sinal e as funções cerebrais envolvidas (Rocha, 2022).

Figura 4 - Sistema Internacional 10-20 de localização dos eletrodos

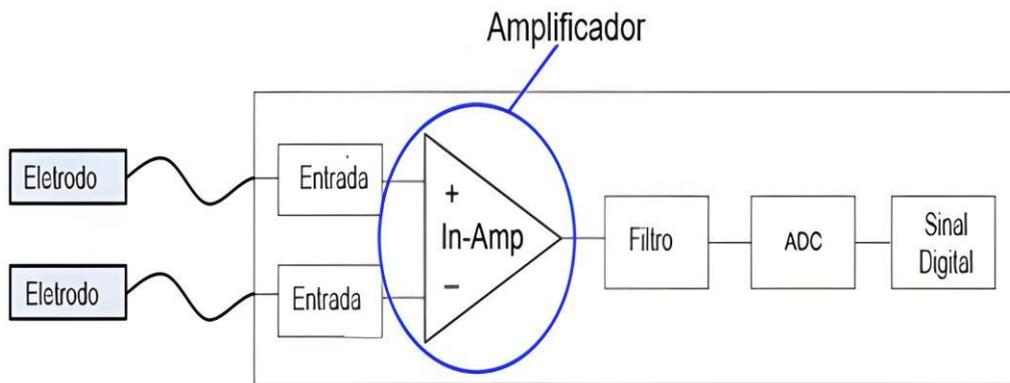


Fonte: Adaptado de Rocha (2022)

A aplicação do sistema 10-20, portanto, não apenas assegura a reprodutibilidade dos exames, mas também possibilita a localização anatômica precisa da atividade elétrica cerebral registrada, permitindo a associação direta dos sinais às regiões funcionais correspondentes do encéfalo.

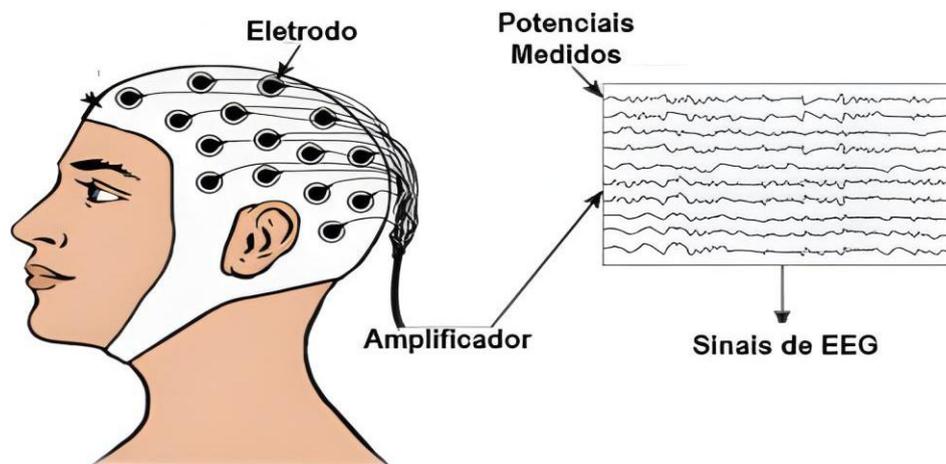
Entretanto, os sinais bioelétricos captados por esses eletrodos apresentam amplitude extremamente baixa e são altamente suscetíveis a ruídos e artefatos fisiológicos, como movimentos oculares, contrações musculares e interferências ambientais. Para mitigar essas limitações e garantir a qualidade dos registros, uma etapa fundamental no processo de aquisição é a amplificação do sinal. Essa função é desempenhada por amplificadores diferenciais, que aumentam seletivamente a amplitude dos sinais desejados ao mesmo tempo em que atenuam o ruído comum às entradas, melhorando de forma significativa a relação sinal-ruído e, conseqüentemente, a confiabilidade clínica do traçado eletroencefalográfico (Neprokin et al., 2019; Sanei; Chambers, 2007). O fluxo básico dessas etapas pode ser visualizado nas Figuras 5 e 6, adaptadas de Neprokin et al. (2020) e Nagel (2019), respectivamente.

Figura 5 - Diagrama simplificado do sistema de aquisição de sinais EEG



Fonte: Adaptado de Neprokin et al. (2019)

Figura 6 – Esquema de aquisição de EEG através de eletrodos e amplificação do sinal



Fonte: Adaptado de Nagel et al. (2019)

Após a amplificação, o sinal é submetido à filtragem, etapa essencial para a remoção de componentes indesejados que possam comprometer a análise. São comumente utilizados filtros passa-faixa, com o objetivo de preservar apenas as faixas de frequência fisiologicamente relevantes da atividade cerebral espontânea, como as bandas delta, teta, alfa, beta e gama. Adicionalmente, aplica-se frequentemente um filtro notch (rejeita-faixa), ajustado à frequência da rede elétrica local (geralmente 50 ou 60 Hz), para eliminar o ruído senoidal proveniente de interferência eletromagnética (Ouyang; Li, 2025; Sanei; Chambers, 2007).

Em seguida, o sinal amplificado e filtrado passa pela conversão analógico-digital (ADC), processo em que a atividade elétrica contínua captada pelos eletrodos é convertida em dados digitais compatíveis com sistemas computacionais. Para que essa conversão seja fidedigna, é necessário que a frequência de amostragem seja suficientemente elevada, de modo a preservar as características temporais e espectrais do sinal. As diretrizes internacionais recomendam taxas mínimas de 250 Hz para exames clínicos convencionais, podendo ultrapassar 500 Hz em aplicações que exigem maior resolução temporal, como estudos de potenciais evocados ou sistemas de interface cérebro-computador (Ouyang; Li, 2025; Sanei; Chambers, 2007).

Por fim, os sinais digitalizados podem ser visualizados em tempo real e armazenados para análises posteriores. O processamento subsequente pode incluir remoção de artefatos, referenciamento, segmentação baseada em eventos e análises nos domínios do tempo, da frequência e do tempo-frequência. Essas etapas possibilitam a extração de informações neurofisiológicas relevantes, como padrões rítmicos, potenciais evocados e métricas de conectividade funcional.

Dessa forma, o processo de aquisição do EEG constitui uma etapa crítica que demanda rigor técnico e controle ambiental, sendo essencial para garantir a validade das interpretações clínicas e científicas sobre a atividade elétrica cerebral.

2.3 Características temporais e espectrais do sinal EEG

O sinal EEG corresponde a uma série temporal não estacionária que contém informações relevantes sobre a atividade elétrica cerebral. Ele é captado por eletrodos posicionados no couro cabeludo e resulta da soma da atividade pós-sináptica de populações de neurônios piramidais do córtex cerebral. A organização e orientação dessas células favorecem a propagação dos potenciais elétricos até a superfície do crânio, possibilitando seu registro extracraniano. Esse sinal carrega, ao longo do tempo, padrões rítmicos e variações espectrais

que refletem diferentes estados fisiológicos e alterações neurológicas, sendo fundamental para a identificação de anomalias como as crises epiléticas.

2.3.1 Características Temporais do Sinal EEG

As características temporais do sinal eletroencefalográfico (EEG) descrevem as variações da atividade elétrica cerebral ao longo do tempo. Por se tratar de uma série temporal não estacionária, a análise no domínio do tempo permite detectar eventos agudos, padrões transitórios e ritmos fisiológicos ou patológicos, aspectos fundamentais para a avaliação clínica e neurofuncional. Esses elementos são diretamente observáveis no traçado EEG, com representações visuais distintas que facilitam a identificação de alterações comportamentais e neurológicas (Rajalakshmi; Sridhar, 2023). A seguir, são apresentados os principais parâmetros temporais, suas manifestações gráficas e respectivas implicações clínicas:

- **Amplitude:** Refere-se à magnitude das variações de voltagem do sinal, geralmente medida em microvolts (μV). No traçado EEG, é representada pela altura das ondas em relação à linha de base. Amplitudes aumentadas podem indicar descargas epileptiformes, enquanto reduções difusas podem estar associadas a encefalopatias metabólicas ou hipóxicas, nas quais o traçado apresenta-se achatado e com baixa reatividade.
- **Morfologia:** Diz respeito à forma da onda registrada. No EEG, certas formas são características de condições neurológicas específicas. Por exemplo, espículas (ondas pontiagudas com duração < 70 ms), ondas agudas (70–200 ms) e complexos espícula-onda (combinação típica em epilepsia de ausência) são padrões morfológicos facilmente identificáveis visualmente e amplamente utilizados no diagnóstico de epilepsia.
- **Latência:** Define o intervalo de tempo entre um estímulo externo e a resposta cerebral registrada no EEG, especialmente nos potenciais evocados. No traçado, a latência é medida como a distância temporal entre o marcador de estímulo e o início da deflexão da onda-resposta. Por exemplo, um aumento da latência da onda P100 nos potenciais visuais evocados pode indicar desmielinização do nervo óptico, como ocorre na esclerose múltipla.
- **Duração:** Corresponde ao tempo de permanência de um evento elétrico específico. No traçado EEG, é representada pela extensão da onda no eixo temporal. Descargas epileptiformes, por exemplo, podem ser diferenciadas de artefatos com base

em sua duração característica (geralmente entre 20–200 ms), sendo esse parâmetro crucial para a interpretação precisa do exame.

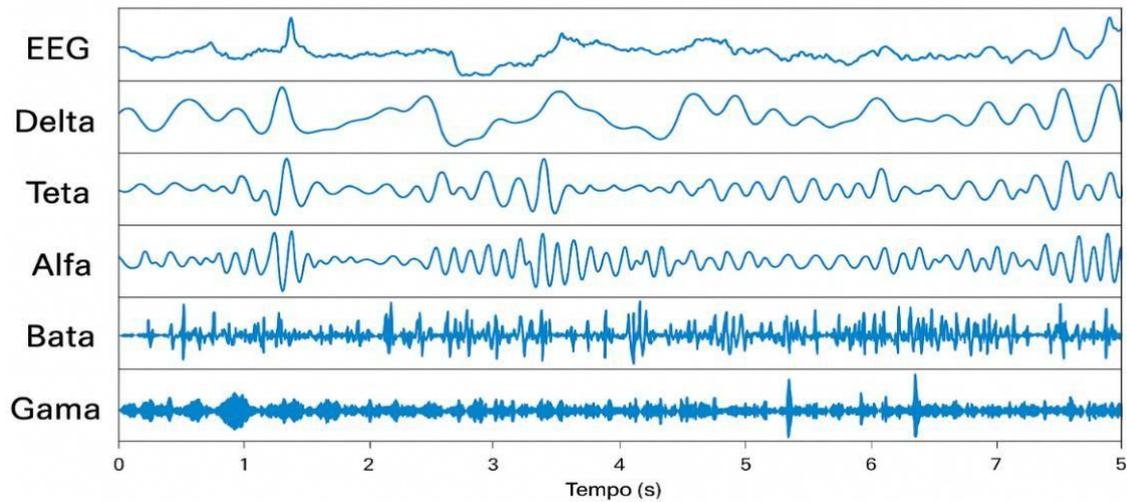
- **Ritmicidade:** Refere-se à regularidade com que um padrão oscilatório ocorre ao longo do tempo. No EEG, a ritmicidade é visível em ondas que se repetem com frequência constante e morfologia semelhante. A presença de ritmo alfa (8–13 Hz) regular na região occipital durante o repouso com olhos fechados é um exemplo de atividade cerebral normal. Já a perda dessa ritmicidade pode estar associada a doenças neurodegenerativas, como a doença de Alzheimer. Em contrapartida, ritmos frontais atípicos observados durante o sono podem indicar epilepsia noturna do lobo frontal.

A identificação e interpretação dessas características permitem detectar eventos ictais, atividade interictal, e padrões anormais que auxiliam no diagnóstico de diversas condições neurológicas, incluindo epilepsias, encefalopatias, distúrbios do sono, esclerose múltipla e demências. A análise temporal, portanto, constitui uma ferramenta indispensável na prática neurofisiológica, fornecendo informações clínicas relevantes diretamente a partir da observação do traçado EEG.

2.3.2 Características Espectrais do Sinal EEG

As características espectrais do sinal eletroencefalográfico (EEG) referem-se à distribuição da energia do sinal ao longo das diferentes faixas de frequência, oferecendo uma representação quantitativa do estado funcional do cérebro. Essa análise é fundamental tanto para a compreensão da atividade cerebral em condições fisiológicas quanto para a detecção de alterações neurológicas e psiquiátricas. Por meio de métodos como a Transformada Rápida de Fourier (FFT) e a Transformada Wavelet, é possível decompor o sinal em suas componentes espectrais, revelando padrões oscilatórios que não são facilmente observáveis no domínio temporal Redwan et al., 2024; Zhang et al., 2023). No contexto do EEG, cinco bandas de frequência são tradicionalmente reconhecidas, cada uma associada a diferentes estados mentais, comportamentais e condições clínicas, conforme ilustrado na Figura 8 (adaptada de Abo-Zahhad, Ahmed e Seha, 2015).

Figura 7 – Decomposição do sinal EEG em bandas de frequência



Fonte: Adaptado de Abo-Zahhad; Ahmed; Seha (2015).

Delta (0,5–4 Hz): Representa as oscilações de mais baixa frequência e é normalmente associada a estados fisiológicos de sono profundo e recuperação neural. A atividade delta reflete sincronização neuronal generalizada, e seu surgimento em vigília é geralmente considerado um sinal de desorganização funcional, embora sua presença controlada também seja explorada em práticas de relaxamento e regulação autônoma.

Teta (4–8 Hz): A banda teta está frequentemente relacionada a estados de transição entre vigília e sono, mas também aparece em momentos de introspecção, imaginação e relaxamento. Sua ocorrência é fisiológica em crianças e em adultos durante estados meditativos ou de baixa demanda cognitiva. A atividade teta também é alvo de interesse em contextos educacionais e terapêuticos, especialmente em estudos sobre atenção, aprendizagem e neurofeedback.

Alfa (8–13 Hz): Trata-se de uma das bandas mais estudadas, sendo considerada um marcador de repouso com alerta, com expressão predominante nas regiões occipitais durante o relaxamento de olhos fechados. O ritmo alfa está relacionado à inibição cortical ativa, favorecendo o foco interno e a redução da interferência sensorial externa. Variações na expressão do ritmo alfa podem refletir diferenças individuais no estado de relaxamento, vigilância ou carga mental.

Beta (13–30 Hz): Associada a atividades cognitivas e sensório-motoras, a banda beta reflete processamento ativo de informações, atenção e envolvimento em tarefas. É mais pronunciada em momentos de vigília com engajamento mental. A modulação da atividade beta também é observada durante movimentos voluntários, sendo relevante em estudos de motricidade e em aplicações de interfaces cérebro-computador.

Gama (>30 Hz): Representa oscilações de alta frequência e está ligada a processos neurais integrativos e de alta complexidade, como percepção consciente, atenção sustentada e integração multimodal de informações. Embora sua investigação seja mais comum em contextos de pesquisa avançada, a banda gama tem despertado crescente interesse na neurociência por seu papel na comunicação entre regiões cerebrais distantes e na coordenação de redes neurais distribuídas.

A avaliação das características espectrais dos sinais EEG permite uma comparação objetiva entre padrões normais e patológicos, contribuindo significativamente para o diagnóstico diferencial de diversas condições neurológicas, incluindo epilepsia, demência, distúrbios do sono e transtornos psiquiátricos.

Nesse contexto, a análise espectral do EEG fornece um perfil funcional do cérebro em tempo real, complementando a avaliação clínica com informações sobre a integridade das redes neuronais e seus padrões oscilatórios. A interpretação adequada das diferentes faixas de frequência é essencial para a caracterização de estados cerebrais específicos e para o avanço de aplicações diagnósticas e terapêuticas na neurociência contemporânea.

2.3.3 Características Tempo-Frequência do Sinal EEG

A análise da atividade elétrica cerebral por meio do eletroencefalograma (EEG) tem evoluído consideravelmente com o reconhecimento da importância de integrar informações tanto do domínio do tempo quanto do domínio da frequência. Essa abordagem tempo-frequência tem se consolidado como uma das estratégias mais eficazes para investigar a dinâmica cerebral, especialmente por considerar que o EEG é um sinal altamente não estacionário, com variações que ocorrem simultaneamente em ambos os domínios (Morales; Bowers, 2022).

Tradicionalmente, as análises temporais têm se concentrado na identificação de eventos rápidos, como potenciais evocados e picos epileptiformes, enquanto as análises espectrais se dedicam à investigação de ritmos cerebrais sustentados, como as oscilações alfa, beta ou gama. No entanto, muitos eventos neurofisiológicos relevantes — como mudanças cognitivas rápidas, transições de estados de consciência, crises epiléticas e flutuações rítmicas associadas ao sono — envolvem alterações complexas e dinâmicas que ocorrem em escalas simultâneas de tempo e frequência (Rodrigues; Rodrigues, 2024)

Nesse contexto, a integração tempo-frequência permite uma visualização contínua da evolução espectral ao longo do tempo, possibilitando a identificação de padrões oscilatórios que surgem de forma transitória e localizada. Essa abordagem é especialmente útil em contextos

clínicos e de pesquisa que exigem maior sensibilidade para detectar eventos breves, irregulares ou de baixa amplitude, muitas vezes despercebidos por análises tradicionais (Pei et al., 2023). Estudos recentes têm demonstrado o potencial dessa integração para:

- Caracterizar alterações sutis em ritmos cerebrais associadas a estados emocionais ou cognitivos;
- Monitorar atividades neuronais rápidas durante a execução de tarefas motoras ou sensoriais;
- Diferenciar padrões relacionados a transtornos neurológicos e psiquiátricos;
- Investigar mecanismos de sincronização cortical em redes neurais distribuídas.

Além disso, a abordagem tempo-frequência permite acompanhar, em tempo real, as modulações da atividade cerebral, o que favorece sua aplicação em áreas como treinamento neurofisiológico por retroalimentação, interfaces neurais e mapeamento funcional personalizado (PEI et al., 2023).

Em síntese, a integração entre tempo e frequência amplia significativamente a capacidade interpretativa do EEG, oferecendo uma perspectiva mais completa sobre o funcionamento cerebral. Ao capturar as oscilações neurais em sua dimensão temporal e espectral simultaneamente, essa abordagem tem contribuído de forma expressiva para o avanço das investigações em neurociência, bem como para o aperfeiçoamento de métodos diagnósticos e terapêuticos.

2.4. Epilepsia

A epilepsia é uma doença neurológica crônica caracterizada por uma predisposição duradoura do cérebro à geração de crises epiléticas não provocadas, acompanhada de consequências neurobiológicas, cognitivas, psicológicas e sociais que impactam significativamente a qualidade de vida do indivíduo (Fisher et al., 2014). A crise epilética, por sua vez, é compreendida como uma manifestação clínica transitória resultante de descargas elétricas anormais, excessivas em populações neuronais, comprometendo temporariamente a função cortical normal. Suas manifestações clínicas são altamente variáveis, dependendo da localização, extensão e propagação da atividade ictal (Fischer et al, 2017).

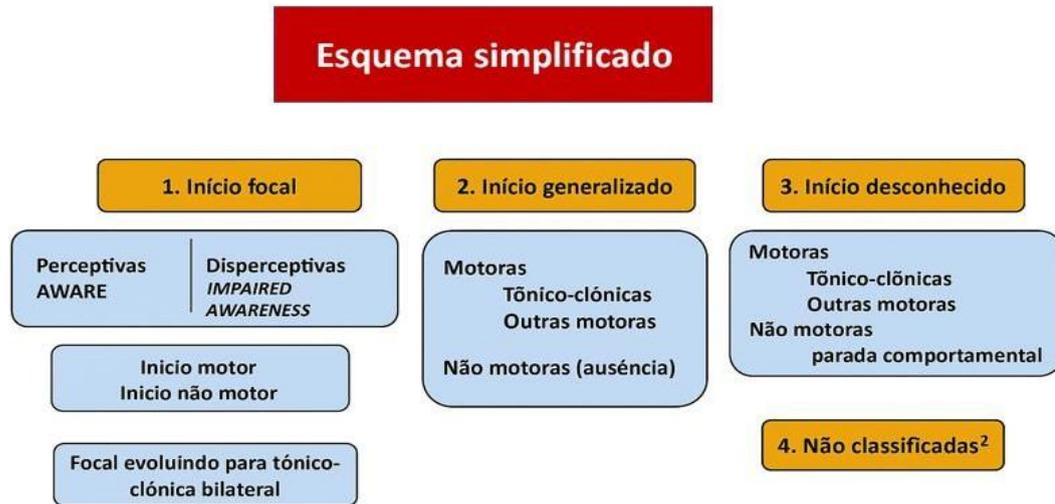
Com o intuito de padronizar o diagnóstico e melhorar a comunicação clínica, a *International League Against Epilepsy* (ILAE) propôs, em 2017, uma classificação operacional em três níveis hierárquicos: (1) tipo de crise epilética, (2) tipo de epilepsia e (3) síndrome

epiléptica, quando aplicável. Essa estrutura visa atender tanto a contextos clínicos especializados quanto a ambientes com recursos limitados, sendo complementada pela investigação etiológica e pela consideração das comorbidades associadas (ILAE, 2017a; 2017b; Fischer et al, 2017).

Entre esses níveis, a identificação correta do tipo de crise representa uma etapa fundamental para o raciocínio diagnóstico, pois orienta diretamente a classificação da epilepsia, a escolha do tratamento antiepiléptico mais adequado e a previsão do curso clínico. Além disso, permite distinguir crises epilépticas de eventos paroxísticos não epilépticos, como síncope, distúrbios do movimento e crises psicogênicas, prevenindo condutas inadequadas e exposições terapêuticas desnecessárias.

No primeiro nível, as crises epilépticas são classificadas com base na localização do início da atividade ictal (focal, generalizada, combinada ou desconhecida), no estado de consciência do paciente (preservada ou alterada) e nas manifestações clínicas predominantes (motoras ou não motoras), como mostrado na figura 9. As crises de início focal se originam em redes neuronais restritas a um hemisfério cerebral e podem ser acompanhadas ou não de comprometimento da consciência. Quando a atividade inicial é localizada, mas evolui bilateralmente, o quadro é denominado crise focal com progressão para tônico-clônica bilateral. Já as crises de início generalizado envolvem redes bilaterais desde o início e costumam apresentar manifestações motoras ou não motoras. Um exemplo clássico é a crise tônico-clônica generalizada, que se manifesta por perda súbita da consciência, rigidez muscular (fase tônica) e movimentos rítmicos dos membros (fase clônica), seguida por um período pós-ictal com sonolência e confusão. Outro subtipo importante é a crise de ausência, caracterizada por uma interrupção breve e súbita da consciência, frequentemente sem manifestações motoras evidentes, sendo mais comum em crianças.

Figura 8 – Classificação operacional das crises epilépticas segundo a ILAE (2017)

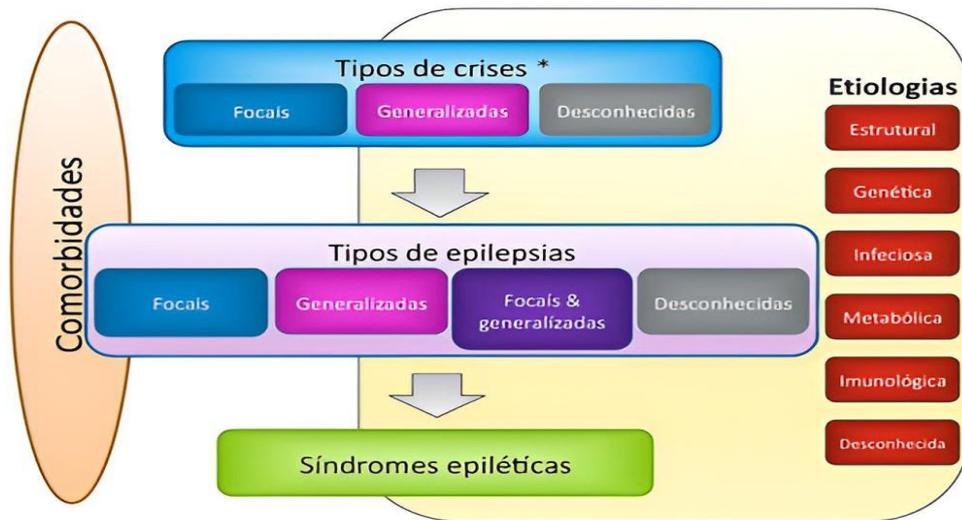


Fonte: Adaptado Fischer et al (2017)

O segundo nível da classificação refere-se ao tipo de epilepsia, determinado pelo padrão de crises predominantes. As categorias incluem epilepsia focal, generalizada, combinada (quando há crises de ambos os tipos) e de tipo desconhecido (quando os dados disponíveis são insuficientes para classificação) (ilae, 2017a; Manokaran; Sharma; Ramachandrannair, 2024). O terceiro nível contempla as síndromes epilépticas, definidas por um conjunto específico e recorrente de características clínicas, eletroencefalográficas e de neuroimagem, frequentemente associadas a faixas etárias específicas, fatores desencadeantes, evolução previsível e presença de comorbidades. Um exemplo típico é a síndrome de West, caracterizada por espasmos infantis, atraso no desenvolvimento neuropsicomotor e padrão de hipsarritmia no eletroencefalograma (EEG) (Manokaran; Sharma; Ramachandrannair, 2024).

A ILAE também propõe uma classificação etiológica da epilepsia com base nos mecanismos fisiopatológicos identificados ou presumidos, apresentada na Figura 10. São reconhecidos seis grupos principais: (1) estrutural, quando há alterações anatômicas cerebrais visíveis; (2) genética, quando mutações afetam diretamente a função neuronal; (3) infecciosa, relacionada a infecções do sistema nervoso central; (4) metabólica, decorrente de distúrbios metabólicos hereditários ou adquiridos; (5) imune, como nas encefalites autoimunes; e (6) desconhecida, quando a causa não é determinada mesmo após investigação adequada. A determinação da etiologia é crucial não apenas para a definição do diagnóstico, mas também para o estabelecimento do prognóstico e da abordagem terapêutica personalizada (Ilae, 2017b;).

Figura 9 – Esquemático da classificação do tipo de epilepsia



Fonte: Adaptado Fischer et al (2017)

O diagnóstico da epilepsia fundamenta-se prioritariamente na anamnese detalhada e na avaliação neurológica criteriosa, sendo o eletroencefalograma (EEG) um dos principais exames complementares. O EEG permite o registro direto da atividade elétrica cerebral com alta resolução temporal, contribuindo para a detecção de padrões epileptiformes interictais, o monitoramento de crises e a caracterização do tipo de epilepsia ou síndrome envolvida. Em contextos especializados, a monitorização prolongada com vídeo-EEG e o registro de parâmetros fisiológicos adicionais (frequência cardíaca, oxigenação, atividade motora) são úteis para a correlação clínico-eletrofisiológica e para o diagnóstico diferencial (Manokaran; Sharma; Ramachandrannair, 2024).

Em síntese, a identificação precisa do tipo de crise epiléptica é o alicerce do processo diagnóstico da epilepsia, sendo determinante para a classificação adequada do transtorno, o planejamento terapêutico eficaz e o acompanhamento longitudinal do paciente. A abordagem estruturada proposta pela ILAE contribui para um manejo mais preciso, individualizado e baseado em evidências, favorecendo melhores desfechos clínicos e qualidade de vida.

2.5 Extração de características

A extração de características constitui uma etapa essencial no processamento de sinais para aplicações em redes neurais. Esse processo visa converter sinais brutos — frequentemente complexos, ruidosos e de alta dimensionalidade — em representações mais compactas e

informativas, que evidenciem padrões relevantes para tarefas de aprendizado, tais como classificação, detecção ou regressão.

No contexto específico da análise de sinais eletroencefalográficos (EEG), a extração de características tem por objetivo representar os sinais de maneira reduzida, porém com elevada capacidade discriminativa, de modo a ressaltar as diferenças entre as classes de interesse, como distintos estados cognitivos ou condições clínicas. Ao promover uma representação mais estruturada e interpretável dos dados, essa etapa facilita a generalização dos modelos de redes neurais, contribuindo para a identificação de padrões subjacentes mesmo em meio à variabilidade e ao ruído inerentes aos sinais biológicos.

Assim, torna-se imperativo identificar e selecionar um conjunto de características relevantes — extraídas em domínios como tempo, frequência ou tempo-frequência — que sejam capazes de descrever adequadamente o comportamento global do sinal. A efetividade da extração de características impacta diretamente o desempenho do sistema de classificação, sendo determinante para a obtenção de resultados confiáveis, robustos e clinicamente interpretáveis.

2.5.1 Processamento de Sinal no Domínio Tempo-Frequência

O processamento de sinais no domínio tempo-frequência (PSTF) refere-se a um conjunto de técnicas e algoritmos que utilizam simultaneamente as duas variáveis fundamentais que descrevem um sinal: o tempo (t) e a frequência (f). Diferentemente das abordagens tradicionais, que analisam os sinais exclusivamente no domínio temporal ou no domínio espectral, o PSTF oferece uma representação conjunta (t, f), permitindo capturar de forma mais precisa a dinâmica dos sinais não estacionários (Pan; Wang; Zhang, 2022; Orhanbulucu; Latifoğlu; Baydemir, 2023; Yan et al., 2025; Eriksen; Rehman, 2023).

Sinais reais, como os sinais de voz, eletrocardiográficos (ECG) e eletroencefalográficos (EEG), apresentam comportamento espectral que varia ao longo do tempo. Nessas situações, as representações clássicas — temporais ou espectrais — são limitadas, pois tratam o tempo e a frequência como variáveis independentes, o que pode resultar na perda de informações relevantes sobre as mudanças transitórias do sinal (Parlak, 2023; Akan; Aydın, 2021).

O PSTF surge, portanto, como uma solução mais adequada para lidar com sinais cuja frequência se altera com o tempo. Ao representar simultaneamente a evolução temporal e o conteúdo espectral, esse método possibilita uma análise mais completa e interpretável. Técnicas como a Transformada de Fourier de Curto Prazo (STFT) e a Transformada Wavelet Discreta (DWT) são amplamente utilizadas para esse fim, pois permitem decompor o sinal em componentes que revelam estruturas temporais e espectrais em múltiplas escalas (Parlak, 2023).

Além disso, representações tempo-frequência são especialmente úteis em aplicações de aprendizado de máquina e redes neurais, uma vez que tornam visíveis padrões sutis e transitórios que não podem ser detectados em domínios isolados. Essas representações podem ser convertidas em mapas bidimensionais (como espectrogramas ou escalogramas), adequados como entrada para modelos de classificação automática.

Em resumo, o processamento de sinais no domínio tempo-frequência constitui uma extensão natural das análises temporais e espectrais, oferecendo uma visão mais abrangente e eficaz da estrutura dos sinais reais, especialmente quando se trata da análise de sinais não estacionários.

2.5.1.1 Transformada de Fourier

A Transformada de Fourier (TF) configura-se como uma ferramenta analítica de grande relevância no contexto da teoria de sinais e sistemas, sendo amplamente empregada nas áreas de ciência, engenharia e tecnologia para a decomposição de sinais no domínio da frequência. Essa técnica permite representar uma função originalmente expressa no domínio temporal como uma superposição contínua de componentes harmônicas — senoidais e cossenoidais —, cada uma associada a uma frequência, amplitude e fase específicas. Tal decomposição viabiliza a análise do conteúdo espectral do sinal, sendo especialmente útil na identificação de padrões periódicos, frequências dominantes e fenômenos de natureza oscilatória.

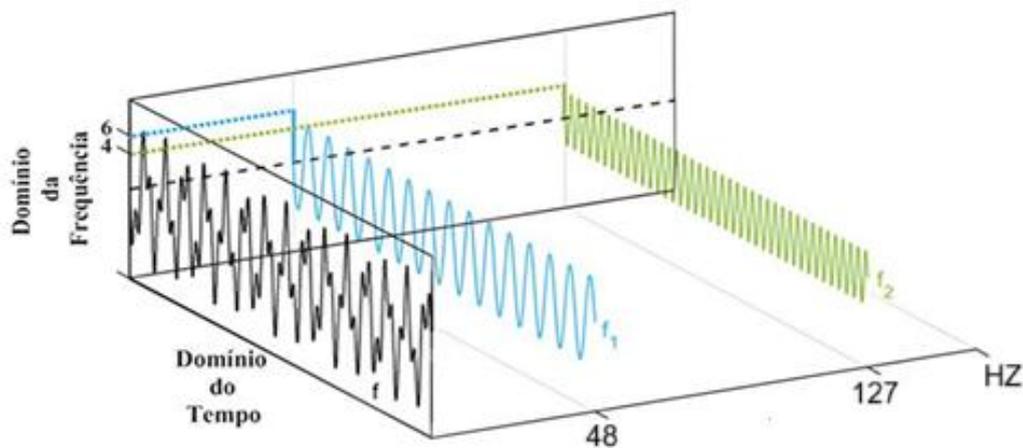
No contexto da teoria clássica, essa decomposição inicia-se pela série de Fourier, que é aplicada na representação de sinais periódicos por meio da soma de senóides com frequências discretas, múltiplas de uma frequência fundamental. No entanto, a maior parte dos sinais observados em sistemas reais é de natureza aperiódica, o que inviabiliza a aplicação direta da série de Fourier nesses casos. Para contornar essa limitação, emprega-se a Transformada de Fourier, que pode ser compreendida como uma generalização da série para funções não periódicas. Tal generalização é formalmente obtida ao considerar o sinal como sendo periódico em um intervalo finito $[-L/2, L/2]$ e tomar o limite quando L tende ao infinito, resultando em uma representação contínua da densidade espectral (Magrini, 2020).

A aplicação da Transformada de Fourier a uma função aperiódica $f(t)$ permite, assim, identificar suas componentes espectrais e quantificar a contribuição relativa de cada frequência na constituição global do sinal. Mesmo na ausência de periodicidade explícita, a TF possibilita uma reconstrução aproximada do sinal original a partir da soma ponderada de suas componentes harmônicas. Essa representação no domínio da frequência é particularmente vantajosa em

situações em que a estrutura espectral oferece maior poder interpretativo do que a visualização direta no tempo (Zhang; Jiang, 2021).

A Figura 10 ilustra a representação da função $f(t)$ nos domínios do tempo e da frequência. A referida função é definida como a soma de duas componentes senoidais: $f(t) = f_1(t) + f_2(t)$, sendo $f_1(t) = 6 \sin(300t)$ e $f_2(t) = 4 \sin(800t)$. Ao se aplicar a Transformada de Fourier sobre $f(t)$, observam-se picos bem definidos no espectro de potência nas frequências de aproximadamente 48 Hz e 127 Hz, com amplitudes de 6 e 4, respectivamente. Essa análise evidencia como a TF permite identificar com precisão a composição harmônica do sinal e representa uma ferramenta essencial para a caracterização espectral de sinais contínuos.

Figura 10: Representação da f nos domínios do tempo e frequência



Fonte: Adaptado de Magrini (2020)

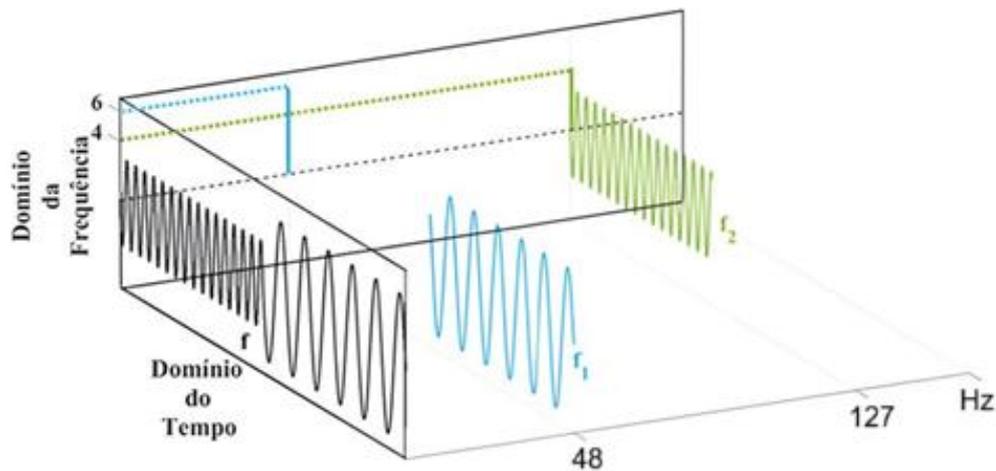
A função $f(t)$ é classificada como estacionária, pois suas componentes de frequência estão presentes de forma constante ao longo de todo o intervalo de observação. Em outras palavras, seu conteúdo espectral não se altera com o tempo, o que caracteriza um comportamento espectral invariante.

No entanto, esse tipo de sinal não reflete a realidade da maioria dos fenômenos encontrados em aplicações práticas. Sinais biomédicos, como os eletroencefalográficos (EEG), além de sinais acústicos, sísmicos e de comunicação, são geralmente não estacionários — ou seja, apresentam variações significativas em seu conteúdo espectral ao longo do tempo. Nesses casos, embora a Transformada de Fourier ainda consiga identificar as frequências presentes, mesmo que ocorram por curtos períodos, ela não fornece nenhuma informação sobre o instante em que essas frequências se manifestam.

A Figura 11 ilustra precisamente essa limitação, ao representar a função $g(t)$, definida por partes da seguinte forma:

$$g = \begin{cases} 6 \sin(300t) & \text{se } t \leq 0 \\ 4 \sin(800t) & \text{se } t > 0 \end{cases} \quad (2.1)$$

Figura 11 - Representação da g nos domínios do tempo e da frequência



Fonte: Adaptado de Magrini (2020)

Apesar da diferença em relação à função $f(t)$, na qual ambas as componentes estão presentes simultaneamente ao longo de todo o tempo, as funções $f(t)$ e $g(t)$ compartilham o mesmo conteúdo espectral. Isso ocorre porque a Transformada de Fourier aplicada a $g(t)$ revela exatamente o mesmo espectro de potência observado em $f(t)$, com picos nas mesmas frequências e amplitudes correspondentes.

Esse resultado evidencia uma limitação fundamental da Transformada de Fourier: embora ela seja extremamente eficaz na identificação das componentes de frequência de um sinal, ela não fornece qualquer informação sobre o momento temporal em que essas frequências ocorrem. Ao privilegiar a resolução espectral, a TF sacrifica completamente a resolução temporal. Como consequência, sinais distintos no domínio do tempo — como $f(t)$ e $g(t)$ — podem apresentar espectros idênticos, tornando impossível, por meio da TF, distinguir a ordem ou o instante de ocorrência de suas componentes espectrais.

Dessa forma, a Transformada de Fourier apresenta uma limitação significativa no que diz respeito à localização temporal das frequências de um sinal. Embora forneça uma descrição precisa do conteúdo espectral, sua incapacidade de capturar a evolução temporal compromete sua aplicabilidade na análise de sinais não estacionários — aqueles cuja composição espectral varia ao longo do tempo e cuja interpretação depende diretamente da identificação dessas variações.

Para contornar essa limitação, uma abordagem alternativa foi desenvolvida com base na segmentação do sinal em intervalos fixos de tempo: a Transformada de Fourier com Tempo Restrito, ou *Short-Time Fourier Transform* (STFT). Nessa técnica, o sinal é dividido em janelas consecutivas de mesma duração, e a Transformada de Fourier é aplicada separadamente em cada segmento. Esse procedimento, conhecido como janelamento, permite calcular os coeficientes espectrais de forma localizada, gerando uma representação tempo-frequência da evolução do sinal ao longo do tempo (Jeon et al., 2020; Magrini, 2020).

A STFT viabiliza, portanto, a análise de sinais não estacionários, permitindo observar como o conteúdo espectral se modifica ao longo do tempo. No entanto, essa técnica também impõe restrições. A principal delas refere-se à escolha do tamanho da janela: janelas longas oferecem melhor resolução espectral, mas prejudicam a precisão temporal; janelas curtas, por sua vez, aumentam a resolução temporal, mas em detrimento da resolução em frequência. Além disso, por empregar funções senoidais de energia infinita como base, a STFT pode não ser adequada para representar eventos abruptos ou altamente localizados no tempo (Jeon et al., 2020).

2.5.1.2 Transformada Contínua Wavelet

A Transformada de Fourier é uma ferramenta amplamente utilizada na análise de sinais, especialmente para a identificação de suas componentes espectrais no domínio da frequência. Sua aplicação permite decompor um sinal em funções harmônicas, revelando com precisão quais frequências estão presentes. No entanto, essa abordagem apresenta limitações significativas na análise de séries temporais não estacionárias — ou seja, sinais cujo conteúdo espectral varia ao longo do tempo.

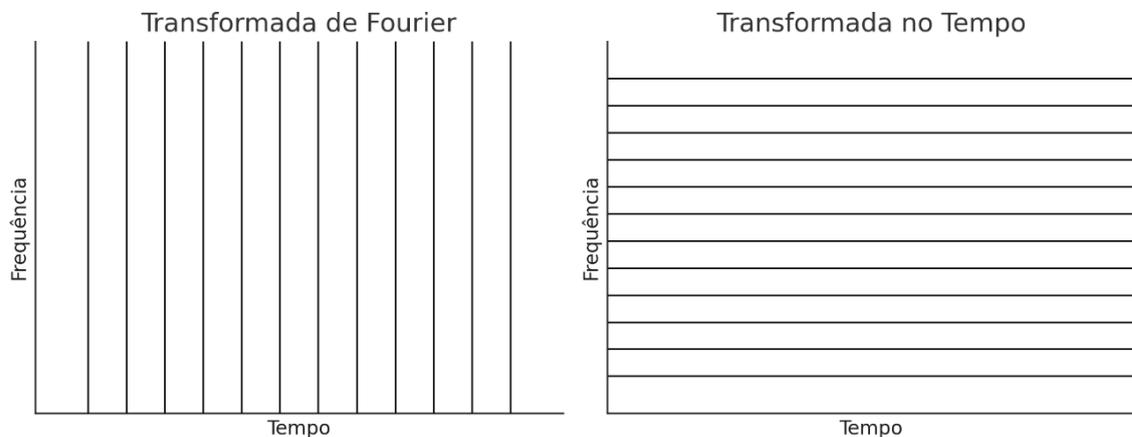
Nesses casos, a representação exclusivamente no domínio da frequência torna-se inadequada, pois elimina a dimensão temporal, ocultando quando determinadas frequências ocorrem. Essa perda de informação compromete aplicações em que a localização temporal dos

eventos espectrais é essencial, como na análise de sinais biomédicos, sísmicos ou acústicos (Eriksen; Rehman, 2023).

Para compreender essas limitações, é necessário considerar o equilíbrio entre resolução temporal e resolução espectral em uma transformação. No domínio do tempo — onde o sinal é originalmente definido — há alta resolução temporal, que permite localizar precisamente a ocorrência dos eventos, mas com baixa resolução espectral, dificultando a identificação das frequências envolvidas. Com a aplicação da Transformada de Fourier, essa relação se inverte: obtém-se uma descrição precisa das frequências presentes, mas com perda total da informação temporal, tornando impossível determinar quando cada componente espectral ocorre ao longo do sinal (Pan; Wang; Zhang, 2022; Orhanbulucu; Latifoğlu; Baydemir, 2023; Yan et al., 2025; Eriksen; Rehman, 2023).

Essa dualidade é ilustrada na Figura 12. À esquerda, observa-se uma representação no domínio temporal, com divisões bem definidas que permitem a localização precisa de eventos no tempo, mas sem revelar o conteúdo espectral. À direita, a representação no domínio da frequência mostra quais faixas de frequência compõem o sinal, mas sem qualquer referência temporal sobre sua ocorrência.

Figura 12 - Comparativo de resoluções no domínio temporal e de frequência



Fonte: Autor

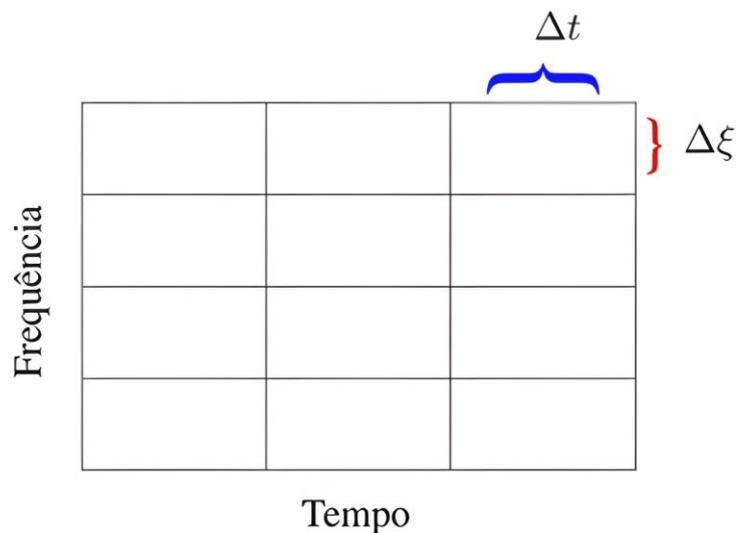
Para superar essa limitação, técnicas de análise tempo-frequência foram desenvolvidas com o objetivo de preservar, ainda que parcialmente, as informações de ambas as dimensões. Uma dessas abordagens é a Transformada de Fourier de Curto Prazo (STFT), que consiste em segmentar o sinal em janelas de tempo fixas, aplicando a Transformada de Fourier em cada trecho separadamente. Isso permite observar como o conteúdo espectral do sinal evolui ao longo do tempo, mantendo uma descrição simultânea — ainda que limitada — dos domínios temporal e espectral.

Na aplicação da STFT, uma das principais limitações está relacionada ao compromisso intrínseco entre resolução temporal e espectral. Esse equilíbrio depende diretamente do

tamanho da janela de segmentação utilizada. Janelas mais longas garantem maior resolução em frequência, por englobarem mais ciclos das componentes harmônicas do sinal, mas reduzem a precisão temporal, dificultando a detecção de eventos rápidos e transitórios (Pan; Wang; Zhang, 2022; Orhanbulucu; Latifoğlu; Baydemir, 2023; Yan et al., 2025; Eriksen; Rehman, 2023).

É comum, na implementação da STFT, utilizar janelas de tamanho fixo distribuídas de forma equidistante ao longo do sinal, como ilustrado na Figura 13. Nessa configuração, obtém-se uma análise balanceada, com resolução moderada tanto no tempo quanto na frequência. Diferentemente da Transformada de Fourier tradicional — que oferece alta resolução espectral, mas elimina a informação temporal —, a STFT viabiliza uma visualização conjunta no domínio tempo-frequência, sendo útil para o estudo de sinais não estacionários (Möncke et al., 2020; Leiber et al., 2023).

Figura 13 - Plano resolução tempo-frequência Transformada de Fourier de Curto-Prazo.



Fonte: Autor

Entretanto, mesmo essa abordagem enfrenta limitações conceituais impostas por fundamentos teóricos. A restrição de resolução no plano tempo-frequência decorre diretamente do princípio da incerteza de Heisenberg, que estabelece um limite à precisão com que se pode determinar simultaneamente a localização temporal e o conteúdo espectral de um sinal. Essa

limitação não é exclusiva da STFT, mas inerente a qualquer técnica de análise tempo-frequência, constituindo uma propriedade fundamental desses métodos.

No caso específico da STFT, essa limitação se expressa pela adoção de uma resolução fixa ao longo de todo o plano tempo-frequência. Como a análise é realizada com janelas de duração constante, o método não se ajusta às variações espectrais locais do sinal, o que pode comprometer a qualidade da representação em sinais fortemente não estacionários, que apresentam alterações abruptas e localizadas no tempo (Möncke et al., 2020).

Como alternativa à resolução fixa imposta pela STFT, a análise multirresolução propõe uma abordagem mais flexível e adaptativa, na qual diferentes escalas de tempo e frequência são utilizadas conforme a natureza do sinal. Em particular, empregam-se janelas estreitas para a análise de componentes de alta frequência, que exigem maior precisão temporal, e janelas mais amplas para componentes de baixa frequência, que requerem maior resolução espectral. Essa estratégia está na base da Transformada *Wavelet*, cuja estrutura multiescala possibilita uma representação mais eficiente da dinâmica dos sinais ao longo do tempo e da frequência (Arts; Van Den Broek, 2022; Guo et al., 2022; Qiu et al., 2024; Rocha et al., 2022).

A Figura 14 representa o plano tempo-frequência, enquanto a Figura 15 ilustra de forma esquemática como a Transformada *Wavelet* distribui a resolução nesse domínio. Ao contrário da STFT, que emprega janelas de tamanho fixo em toda a extensão do sinal, a *Wavelet* adota uma abordagem adaptativa, ajustando a largura da janela conforme a frequência analisada.

Esse ajuste se dá por meio da escala da função *Wavelet*, refletida em diferentes níveis de resolução:

Para escalas maiores ($j < 0$, representadas em verde), associadas a componentes de baixa frequência, utiliza-se uma janela temporal ampla e, conseqüentemente, menor resolução espectral. Essa configuração favorece a análise de eventos prolongados no tempo, ainda que com menor detalhamento em frequência;

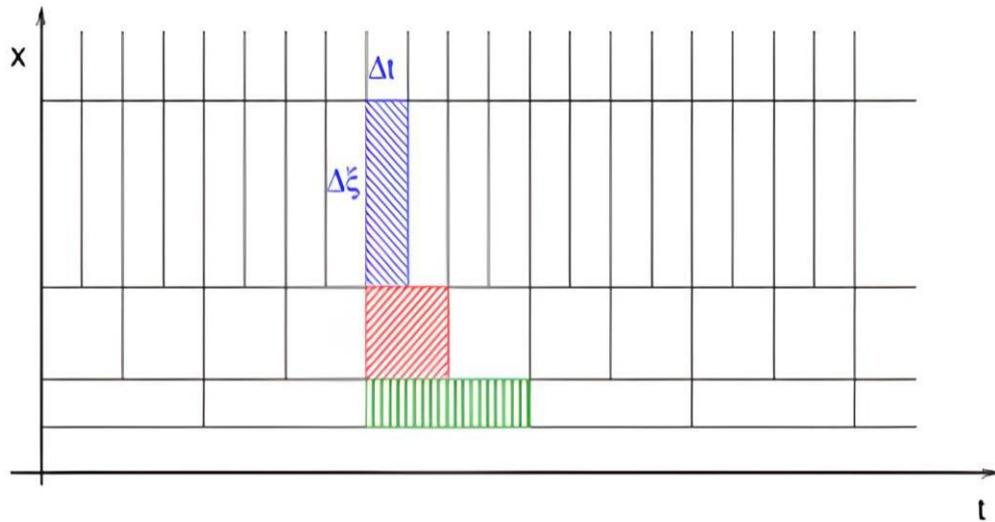
Em escalas intermediárias ($j = 0$, em vermelho), obtém-se uma resolução equilibrada entre tempo e frequência, adequada para componentes de frequência média;

Para escalas menores ($j > 0$, em azul), correspondentes a altas frequências, adota-se uma janela mais estreita, o que aumenta a resolução temporal, ainda que à custa da resolução espectral. Essa configuração é ideal para a detecção de eventos rápidos e localizados no tempo.

Esse comportamento é representado visualmente pelas caixas dinamicamente às características do sinal, permitindo a identificação eficiente tanto de padrões transientes quanto de oscilações desenhadas na Figura 14, cujas dimensões ($\Delta t, \Delta \xi$) variam conforme a escala.

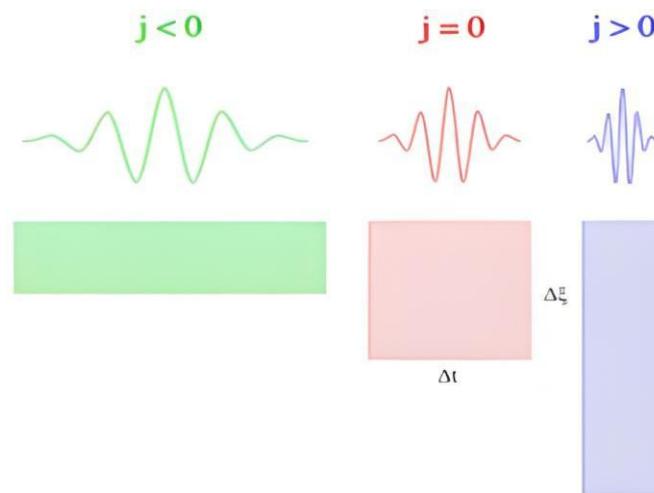
Assim, a Transformada *Wavelet* Contínua proporciona uma análise multiescala que se adapta sustentadas — aspecto essencial na análise de sinais não estacionários como os eletroencefalográficos.

Figura 14 – Distribuição da resolução tempo-frequência na Transformada *Wavelet*



Fonte: Adaptada de Domingues et al. (2016)

Figura 15 – Representação da resolução tempo-frequência na Transformada *Wavelet*



Fonte: Adaptada de Domingues et al. (2016)

Para alcançar essa representação tempo-frequência com resolução variável, a Transformada *Wavelet* adota um procedimento conceitualmente análogo ao da Transformada de Fourier, no qual o sinal é decomposto por meio de projeções sobre uma base de funções. No entanto, diferentemente da Transformada de Fourier — baseada em uma base ortonormal composta por senoide de suporte global e energia infinita —, a Transformada *Wavelet*

utiliza uma família de funções ortogonais localizadas no tempo e na frequência, denominadas wavelets.

Essas funções formam uma base ortonormal adaptativa, construída a partir de translações e dilatações aplicadas a uma única função geradora, chamada wavelet-mãe. Essa estrutura permite realizar uma análise multiescala, em que a resolução é ajustada dinamicamente conforme a frequência: escalas mais elevadas (baixas frequências) utilizam janelas temporais largas, garantindo maior resolução espectral; enquanto escalas mais baixas (altas frequências) utilizam janelas estreitas, assegurando melhor resolução temporal (Arts; Van Den Broek, 2022; Qiu et al., 2024; Rocha et al., 2022).

As *wavelets* empregadas devem atender a propriedades matemáticas essenciais, como ortogonalidade, suporte compacto e momento nulo, que as tornam eficazes na detecção de discontinuidades, transições abruptas e padrões locais. A escolha da wavelet-mãe influencia diretamente a adaptação ao tipo de sinal analisado e ao contexto de aplicação (Review et al., 2022; Willey et al., 2023). Por isso, diversas famílias de wavelets foram desenvolvidas, cada uma com características próprias em termos de regularidade, simetria e capacidade de compactação. Entre as mais utilizadas destacam-se:

- Haar – descontínua, simples e de fácil implementação computacional;
- Daubechies – suaves e ortogonais, amplamente utilizadas em compressão e análise numérica;
- Symlet – versões simétricas das Daubechies, com melhor regularidade;
- Coiflet – com mais momentos nulos e simetria aprimorada, eficazes em sinais com variações suaves;
- Morlet – composta por uma senoide modulada por gaussiana, comumente aplicada na Transformada Wavelet Contínua (TWC);
- Mexican Hat – derivada da segunda derivada de uma gaussiana, útil na detecção de picos e bordas.

Todas essas funções são derivadas de uma única wavelet-mãe, denotada por $\Psi(t)$, que serve como base para a construção das chamadas wavelets-filhas. Essas funções filhas são obtidas por meio de operações de escala (dilatação) e translação aplicadas à wavelet-mãe, o que permite adaptar a análise à frequência e à localização temporal do sinal. Essa variação de escala e posição estrutura a representação multirresolução no plano tempo-frequência, permitindo que a Transformada Wavelet se ajuste dinamicamente à complexidade dos sinais analisados. Como ilustrado na figura anterior, essa abordagem fornece uma descrição eficaz tanto de eventos breves e abruptos quanto de estruturas mais prolongadas, sendo particularmente adequada para sinais não estacionários como os eletroencefalográficos.

A forma geral de uma wavelet filha, construída a partir da wavelet mãe, é dada por:

$$\Psi(t)_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-a}{a}\right) \quad (2.2)$$

Onde:

- $a \in R^+ \setminus \{0\}$ é o parâmetro de escala, responsável pela compressão (alta frequência) ou expansão (baixa frequência) da wavelet;
- $b \in R$ é o parâmetro de translação, que desloca a wavelet no tempo;
- o fator $\frac{1}{\sqrt{a}}$ garante a preservação da energia da função.

Os parâmetros a e b desempenham papéis centrais na construção das wavelets-filhas, pois controlam, respectivamente, a escala (ou dilatação) e a translação da wavelet-mãe $\Psi(t)$. O parâmetro $b \in R$ atua como responsável pela localização temporal da wavelet no sinal, determinando o instante específico em que a análise será realizada. Sob uma perspectiva geométrica, b representa o deslocamento horizontal da função no plano tempo-frequência, associando a wavelet a diferentes posições ao longo do eixo do (Arts; Van Den Broek, 2022; Qiu et al., 2024; Rocha et al., 2022).

Por sua vez, o parâmetro $a \in R^+ \setminus \{0\}$ regula o fator de escala, modificando a largura da wavelet no domínio temporal. Valores pequenos de a resultam em compressão da wavelet, favorecendo a análise de componentes de alta frequência com elevada resolução temporal. Em contrapartida, valores grandes de a promovem a dilatação da função, tornando-a mais sensível a frequências mais baixas e ampliando a resolução espectral. Nesse contexto, a pode ser interpretado como um controlador vertical no plano tempo-frequência, ajustando a profundidade da análise conforme a faixa espectral de interesse.

A interação dinâmica entre os parâmetros a e b possibilita à Transformada Wavelet realizar uma decomposição multiescala e multitemporal do sinal, adaptando a resolução da análise às características locais da estrutura do sinal. Essa capacidade de ajuste fino entre tempo e frequência constitui uma das principais vantagens da abordagem wavelet em relação a

métodos de resolução fixa, como a Transformada de Fourier com Tempo Restrito (STFT) (Arts; Van Den Broek, 2022; Qiu et al., 2024; Rocha et al., 2022).

A partir da definição da wavelet-filha $\Psi_{a,b}(t)$, construída por dilatação (escala a) e translação (deslocamento b) da wavelet-mãe $\Psi(t)$, é possível formular a Transformada Contínua Wavelet (TCW) de um sinal $x(t)$. Essa transformada corresponde ao conjunto de projeções de $x(t)$ sobre as diferentes versões escaladas e transladadas da wavelet-mãe, e é definida por:

$$X_{W_{a,b}}(t) = \int_{-\infty}^{\infty} x(t) \Psi_{a,b} dt \quad (2.3)$$

Nesta expressão, $X_{\Psi}(a, b)$ representa o coeficiente wavelet correspondente à escala a e à posição temporal b . Esses coeficientes indicam o grau de similaridade (ou correlação) entre o sinal original $x(t)$ e a wavelet $\Psi(t)$, dilatada e deslocada em cada ponto do plano tempo-escala.

O conjunto desses coeficientes permite construir uma representação contínua do sinal em dois domínios simultâneos: tempo e escala. Tal representação é especialmente útil na análise de sinais não estacionários, pois permite acompanhar a variação de suas componentes espectrais ao longo do tempo. Ao calcular o módulo ao quadrado dos coeficientes, $|X_W(a, b)|^2$, obtém-se uma medida de densidade de energia no plano tempo-escala, que pode ser convertida em um mapa tempo-frequência para visualização e interpretação das propriedades locais do sinal (Arts; Van Den Broek, 2022; Qiu et al., 2024).

Essa abordagem multirresolução oferece um arcabouço matemático sólido e versátil para a análise de eventos transitórios, singularidades e estruturas localizadas em sinais complexos. Sua capacidade de adaptar simultaneamente a resolução temporal e espectral torna-a especialmente eficaz na identificação de padrões dinâmicos que escapam às técnicas tradicionais de análise com resolução fixa. Por essas razões, a Transformada Wavelet tem sido amplamente empregada em aplicações avançadas, incluindo o processamento de sinais biomédicos (como EEG e ECG), a engenharia de sinais, a geofísica, a análise de imagens e diversas outras áreas em que a representação tempo-frequência detalhada é essencial para a extração de informações significativas.

2.5.1.3 Momentos Condicionais e Conjuntos da Distribuições Tempo-Frequência

A análise de sinais não estacionários — cujas propriedades espectrais se modificam ao longo do tempo — reveste-se de importância crucial em diversos domínios científicos e

tecnológicos, incluindo a engenharia biomédica, o processamento de sinais acústicos, os sistemas de radar e as aplicações de inteligência artificial voltadas à modelagem de séries temporais. Nesse contexto, os momentos estatísticos extraídos das distribuições tempo-frequência (TFD) configuram uma abordagem robusta para a caracterização quantitativa da dinâmica energética dos sinais nos domínios temporal e espectral.

Tais momentos podem ser sistematicamente organizados em três categorias principais: momentos espectrais condicionais, momentos temporais condicionais e momentos conjuntos tempo-frequência. Cada uma dessas categorias fornece uma perspectiva estatística complementar acerca da distribuição de energia do sinal, permitindo a descrição precisa de fenômenos transientes e padrões dinâmicos complexos. A utilização desses descritores tem se mostrado particularmente eficaz em aplicações voltadas ao diagnóstico automatizado, à extração de atributos discriminativos, ao reconhecimento de padrões e ao desenvolvimento de sistemas inteligentes de monitoramento (Davidson; Loughlin, 2000b; Loughlin, 2001; Tacer; Loughlin, 1998).

Dentre essas categorias, destacam-se os momentos espectrais condicionais, que consistem em parâmetros estatísticos derivados da distribuição tempo-frequência $P(t, \omega)$. Esses momentos descrevem, de forma quantitativa, a distribuição da energia em frequência condicionada a cada instante de tempo, permitindo uma representação compacta e eficiente do conteúdo espectral do sinal (Taslimi; HAghnejad; Mohammadi, 2023). Essa compressão da informação resulta em um conjunto de medidas de baixa dimensionalidade e elevado poder discriminativo, tornando-os especialmente úteis em sistemas de classificação e diagnóstico automatizado (Davidson; Loughlin, 2000b; Loughlin, 2001; Tacer; Loughlin, 1998).

Matematicamente, o momento espectral condicional de ordem m , para um tempo fixo t , é definido por:

$$\langle \omega^m \rangle_t = \frac{1}{P(t)} \int \omega^m P(t, \omega) d\omega \quad (2.4)$$

em que ω representa a frequência, m é a ordem do momento, e $P(t) = \int P(t, \omega) d\omega$ é a distribuição marginal temporal, utilizada para normalizar a função de densidade espectral. Esse momento não centralizado fornece informações sobre parâmetros estatísticos como média, variância, assimetria e curtose da distribuição espectral em um dado instante, dependendo do valor de m . No entanto, para uma análise mais precisa da dispersão da energia em torno da frequência média instantânea, recorre-se aos momentos centralizados, definidos como:

$$\mu_{\omega}^m = \frac{1}{P(t)} \int (\omega - \langle w^1 \rangle_t)^m P(t, \omega) d\omega \quad (2.5)$$

Nos momentos centralizados, o cálculo é realizado em torno da média espectral instantânea, representada pelo primeiro momento $\langle w^1 \rangle_t$. O segundo momento expressa a variância local da frequência, também denominada largura de banda instantânea, a qual quantifica a dispersão da energia espectral em torno da frequência média. O terceiro momento, por sua vez, representa a assimetria da distribuição espectral, evidenciando desvios em relação à simetria da média, com possível predominância de componentes em frequências superiores ou inferiores. O quarto momento corresponde à curtose, parâmetro responsável por avaliar o grau de concentração da energia espectral em torno da média, sendo relevante para a identificação de distribuições com picos acentuados (leptocúrticas) ou mais achatadas (platicúrticas), frequentemente associadas a eventos transitórios ou alterações espectrais de interesse clínico ou técnico (Davidson; Loughlin, 2000b; Loughlin, 2001; Tacer; Loughlin, 1998).

Tal abordagem fornece uma estrutura conceitual sólida para a análise de sinais não estacionários, permitindo a captura de aspectos relevantes de sua evolução espectral. Além disso, constitui uma base metodológica consistente para algoritmos de extração de atributos em contextos diversos, como bioengenharia, processamento acústico, controle de processos e sistemas embarcados com sensibilidade temporal.

Nesse escopo, os momentos temporais condicionais configuram ferramentas analíticas essenciais para a caracterização da distribuição temporal da energia associada a cada componente espectral. Derivados da distribuição tempo-frequência $P(t, \omega)$, esses momentos possibilitam a quantificação precisa da maneira como a energia vinculada a uma frequência específica se propaga ou se concentra ao longo do tempo. Essa representação permite inferências relevantes acerca de propriedades como o atraso de grupo, a duração efetiva da atividade espectral e a morfologia temporal de eventos dinâmicos. A principal finalidade desses momentos consiste em fornecer um conjunto de descritores estatísticos crescentes que sintetizam a distribuição temporal do sinal, condicionada à frequência (Davidson; LOUGHLIN, 2000b; Loughlin, 2001; Tacer; LOughlin, 1998). Para uma frequência ω fixa, o momento temporal condicional de ordem n é definido como:

$$\langle t^n \rangle_{\omega} = \frac{1}{P(\omega)} \int t^n P(t, \omega) dt \quad (2.6)$$

em que $P(\omega) = \int P(t, \omega) dt$ corresponde à distribuição marginal espectral, responsável pela normalização da densidade de energia associada à frequência considerada. Essa normalização assegura que os momentos calculados reflitam de forma relativa à distribuição temporal da energia para cada componente espectral. Para uma caracterização mais refinada da estrutura temporal, é possível centralizar os momentos em torno do tempo médio associado a uma dada frequência, denotado por $\langle t^1 \rangle_w$. Esta abordagem resulta na seguinte expressão para os momentos temporais condicionais centralizados, que permitem analisar a dispersão, simetria e curtose temporal da energia espectral em torno de sua média:

$$\mu_t^n = \frac{1}{P(\omega)} \int (t - \langle t^1 \rangle_w)^n P(t, \omega) dt \quad 2.7$$

Essa formulação permite avaliar, com maior rigor, as propriedades estatísticas relacionadas à dispersão temporal da energia, possibilitando interpretações relevantes sobre a dinâmica do sinal, tais como o atraso médio, a duração efetiva, a assimetria temporal e a concentração local da energia no tempo.

Dessa maneira, os momentos temporais condicionais estabelecem uma fundamentação analítica consistente para o desenvolvimento de algoritmos computacionais avançados, especialmente em contextos que demandam elevada precisão, eficiência operacional e robustez na extração de atributos de sinais não estacionários.

Em continuidade, os momentos conjuntos tempo-frequência configuram descritores estatísticos extraídos da distribuição tempo-frequência $P(t, \omega)$, os quais incorporam, de forma simultânea, as dimensões temporal e espectral do sinal. Em oposição aos momentos condicionais — que analisam separadamente as variações em um domínio com o outro mantido fixo —, os momentos conjuntos têm como finalidade quantificar as correlações cruzadas entre tempo e frequência. Tal abordagem permite caracterizar estruturas interdependentes no plano tempo-frequência, bem como identificar padrões modulados e dinâmicas complexas não capturáveis por métricas unidimensionais (Davidson; Loughlin, 2000b; Loughlin, 2001; Tacer; Loughlin, 1998).

Matematicamente, o momento conjunto tempo-frequência de ordem (n, m) , na forma não centralizada, é definido por:

$$\langle t^n \omega^m \rangle = \iint t^n \omega^m P(t, \omega) dt d\omega \quad (2.8)$$

Nessa formulação, $P(t, \omega)$ representa a distribuição tempo-frequência do sinal, e o valor calculado expressa a expectativa matemática de $t^n w^m$, ponderada pela densidade de energia associada à TFD. Essa medida fornece uma representação quantitativa da interação conjunta entre os domínios temporal e espectral, permitindo caracterizar aspectos globais da estrutura energética do sinal, como tendências de acoplamento tempo-frequência e padrões modulados. Para uma análise mais refinada das variações em torno dos valores médios, emprega-se a forma centralizada dos momentos conjuntos tempo-frequência, definida por:

$$\mu_{t,\mu}^{n,m} = \frac{1}{P(w)} \iint (t - \langle t \rangle_w)^n (\omega - \langle \omega \rangle_t)^m P(t, \omega) dt d\omega \quad (2.9)$$

em que $\langle t \rangle_w$ e $\langle \omega \rangle_t$ denotam, respectivamente, os primeiros momentos temporais e espectrais condicionais. Esses parâmetros correspondem, respectivamente, ao tempo médio de ocorrência da energia para uma frequência específica e à frequência média instantânea associada a um determinado instante de tempo. A adoção da forma centralizada permite uma avaliação mais rigorosa da dispersão conjunta da energia, bem como da correlação cruzada entre os domínios temporal e espectral. Além disso, viabiliza a análise da estrutura geométrica da distribuição tempo-frequência, aspectos essenciais para a caracterização de padrões dinâmicos complexos presentes em sinais não estacionários.

Em síntese, os momentos conjuntos tempo-frequência constituem uma abordagem eficaz para a redução de dimensionalidade e a extração de características relevantes em sinais não estacionários, preservando simultaneamente informações dos domínios temporal e espectral. Sua interpretação estatística e robustez tornam-nos componentes centrais em sistemas modernos de análise de sinais complexos. Embora cada abordagem seja fundamentada em domínios distintos — tempo, frequência ou ambos —, todas permitem a derivação dos quatro momentos estatísticos clássicos: média, variância, assimetria e curtose (Loughlin, 2000b; Loughlin, 2001; Tacer; Loughlin, 1998).

Do ponto de vista computacional, os momentos condicionais apresentam menor custo de processamento por envolverem integrais unidimensionais, sendo, portanto, mais adequados a aplicações em tempo real. Em contrapartida, os momentos conjuntos, que requerem integrais bidimensionais, demandam maior capacidade computacional, mas fornecem representações mais ricas e informativas (Loughlin, 2000b; Loughlin, 2001; Tacer; Loughlin, 1998).

Dessa forma, a escolha entre os métodos deve considerar os objetivos específicos da análise. Momentos espectrais são particularmente úteis para acompanhar a evolução de componentes frequenciais; momentos temporais permitem caracterizar padrões de ativação ao longo do tempo; e momentos conjuntos são indicados para a investigação de interações complexas entre tempo e frequência. A integração dessas três abordagens fornece um arcabouço abrangente de descritores estatísticos, essencial para o desenvolvimento de sistemas avançados de classificação, diagnóstico e monitoramento em áreas como bioengenharia, processamento de sinais e sistemas embarcados.

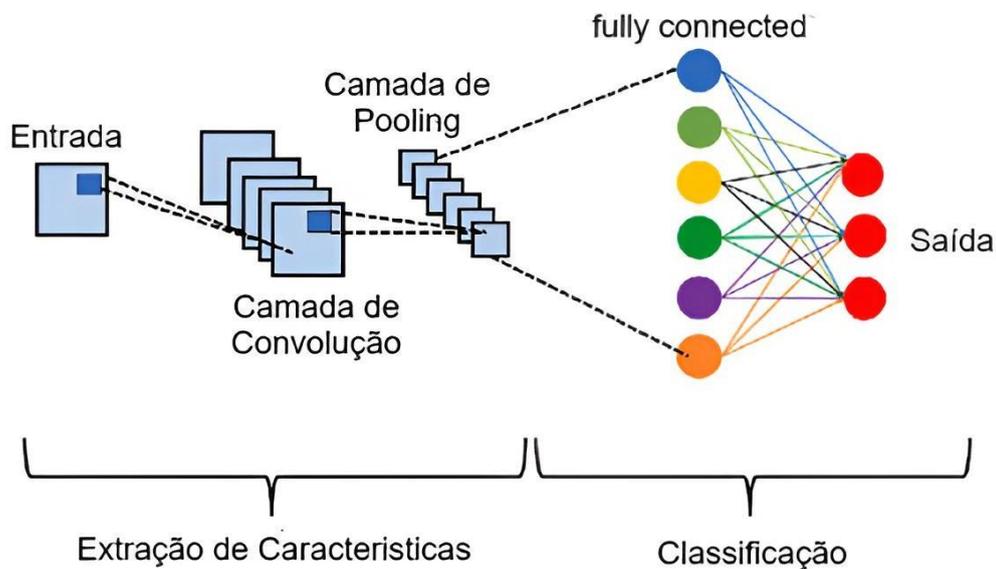
2.6 Classificação

A classificação é a etapa final do processamento de sinais EEG, na qual os dados, previamente transformados em representações discriminativas, são atribuídos a categorias específicas, como presença ou ausência de atividade epiléptica. Essa tarefa visa identificar padrões relevantes nos sinais com base em atributos extraídos dos domínios temporal, espectral ou tempo-frequência. Modelos baseados em aprendizado profundo, como Redes Neurais Convolucionais (CNNs), Redes de Memória de Longo e Curto Prazo (LSTM) e suas combinações híbridas, têm se mostrado eficazes na análise de sinais EEG por sua capacidade de capturar estruturas complexas e dependências temporais. Tais modelos vêm sendo amplamente empregados na detecção automatizada de crises epiléticas, contribuindo para diagnósticos mais rápidos, precisos e objetivos.

2.6.1 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) constituem uma classe de modelos de aprendizado profundo amplamente empregada no processamento de sinais, notadamente por sua arquitetura especializada na extração automática e hierárquica de características locais. Inspiradas na organização funcional do córtex visual, essas redes são particularmente eficazes na identificação de padrões estruturais em sinais unidimensionais, bidimensionais ou em representações tempo-frequência, eliminando a necessidade de engenharia manual de atributos (Younesi et al., 2024). Para viabilizar essa capacidade de análise eficiente e adaptativa, a arquitetura de uma CNN pode ser conceitualmente dividida em duas etapas principais, conforme ilustrado na figura 16.

Figura 12 – Estrutura típica de uma Rede Neural Convolutiva (CNN)



Fonte: Adaptado de Alzubaidi, 2021.

Na primeira etapa, os dados de entrada — representados como matrizes, como uma configuração espacial, espectrograma ou segmento de sinal — são processados pelas camadas convolucionais, nas quais filtros treináveis percorrem localmente a entrada. Esses filtros aplicam operações de convolução, detectando automaticamente padrões locais relevantes, como bordas, transições abruptas ou estruturas repetitivas. Os resultados dessas operações constituem os mapas de ativação, que preservam as relações espaciais ou temporais da entrada original.

Na sequência, os mapas de ativação são submetidos às camadas de *pooling*, que realizam uma redução da resolução espacial, retendo apenas as informações mais significativas por meio de operações como o *max pooling*. Essa redução contribui para a diminuição da complexidade computacional, além de conferir maior robustez do modelo a ruídos, translações e deformações sutis nos dados.

A segunda etapa corresponde à fase de classificação, conduzida pelas camadas totalmente conectadas (*fully connected layers*). Nessa etapa, os mapas de ativação reduzidos são linearizados em um vetor unidimensional, que é então processado por camadas densas, nas quais cada neurônio é conectado a todas as ativações anteriores. Essa estrutura permite uma combinação global e não linear das características extraídas, resultando em um vetor de saída cuja dimensionalidade depende da tarefa final — como classificação, regressão ou detecção de eventos.

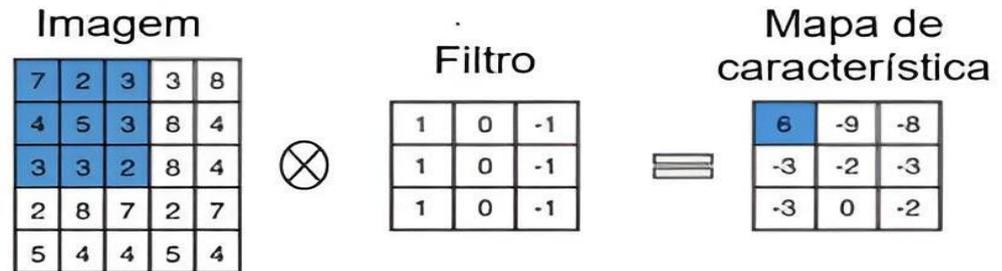
Essa organização hierárquica e modular permite que as CNNs aprendam representações progressivamente mais abstratas e discriminativas à medida que os dados percorrem suas camadas. Tal capacidade favorece a modelagem de estruturas complexas e a identificação de padrões relevantes mesmo em sinais com elevada variabilidade ou presença de ruído. A flexibilidade para operar sobre dados brutos, aliada à habilidade de adaptação a diferentes domínios e formatos de entrada, torna as CNNs uma ferramenta particularmente eficaz em aplicações envolvendo classificação, segmentação, compressão e análise automatizada de sinais.

2.6.1.1 Camada Convolutiva

Entre os componentes essenciais dessa arquitetura, destacam-se as camadas convolucionais, que desempenham um papel central na extração automática e hierárquica de características locais a partir dos dados de entrada. Esses elementos operam por meio da aplicação sistemática de filtros sobre regiões específicas dos dados, permitindo a detecção de padrões com diferentes níveis de complexidade e abstração, essenciais para tarefas de aprendizado supervisionado (Alzubaidi et al., 2021; Goodfellow; Bengio; Courville, 2016; Younesi et al., 2024).

No núcleo funcional de uma camada convolutiva estão os filtros — pequenas matrizes de pesos treináveis que percorrem a entrada em diferentes posições. Cada filtro é ajustado, durante o processo de treinamento, para responder a um padrão específico nos dados, como bordas, texturas, simetrias ou variações estruturais locais. A aplicação sucessiva dos filtros sobre sub-regiões da entrada resulta em mapas de ativação, também chamados de mapas de características (*feature maps*), que representam a intensidade de resposta de cada filtro em distintas regiões do domínio original (Goodfellow; Bengio; Courville, 2016). A Figura 17 ilustra esse processo, mostrando como um filtro convolutivo é aplicado a uma imagem de entrada para gerar um mapa de ativação correspondente, destacando padrões detectáveis (Mostafa; Wu, 2021).

Figura 17 - Operação de convolução entre uma imagem de entrada e um filtro



Fonte: Adaptado de Mostafa; Wu (2021).

A operação de convolução, que rege a interação entre os filtros e os dados de entrada, consiste em multiplicações elemento a elemento entre a matriz do filtro e a submatriz correspondente da entrada, seguidas pela soma dos produtos. Essa operação é repetida conforme o filtro se desloca pela matriz de entrada, produzindo uma nova matriz de saída que evidencia a presença do padrão aprendido. A imagem ilustrativa desse processo destaca, de forma clara, como a movimentação do filtro sobre regiões adjacentes gera valores na saída, preservando a estrutura espacial local e permitindo a construção de representações significativas (Alkhalidi et al., 2024; Mostafa; Wu, 2021).

O deslocamento do filtro é controlado por um parâmetro chamado *stride*, que determina o número de posições que o filtro avança após cada operação. Um *stride* de valor 1 resulta em mapas de ativação com maior resolução espacial, ao passo que valores maiores reduzem a dimensionalidade da saída, economizando recursos computacionais, mas diminuindo a granularidade da análise. Para evitar a redução excessiva da dimensão da entrada ao longo das camadas, pode-se aplicar *padding*, que consiste na adição de valores (geralmente zeros) ao redor da matriz de entrada. O uso de *same padding* preserva a dimensão original da entrada, enquanto o *valid padding* aplica a convolução apenas onde o filtro se ajusta completamente, resultando em uma saída de tamanho menor.

Os mapas de características produzidos após a convolução refletem, portanto, a presença de padrões específicos identificados por cada filtro. A combinação desses mapas, provenientes de diversos filtros, gera uma representação distribuída e rica da entrada, que é fundamental para as camadas subsequentes da rede aprofundarem a abstração e aumentarem o poder

discriminativo do modelo (Alzubaidi et al., 2021; Goodfellow; Bengio; Courville, 2016; Younesi et al., 2024).

Após a convolução, aplica-se comumente uma função de ativação não linear a cada valor dos mapas de características. Essa etapa é essencial para permitir que a rede aprenda relações não lineares nos dados. A função mais amplamente utilizada é a ReLU (*Rectified Linear Unit*), definida por $\text{ReLU}(x) = \max(0, x)$, que mantém os valores positivos e zera os negativos. Isso introduz esparsidade nas ativações, acelera o processo de treinamento e contribui para a mitigação do problema de gradientes desvanecentes em redes profundas (Goodfellow; Bengio; Courville, 2016; Krichen, 2023).

De forma integrada, esses elementos permitem que as camadas convolucionais transformem os dados de entrada em representações progressivamente mais informativas e compactas, viabilizando a identificação e classificação de padrões com alta eficiência computacional e excelente capacidade de generalização.

2.6.1.2 Camadas de Pooling

As camadas de *pooling* constituem um elemento central nas arquiteturas de Redes Neurais Convolucionais (CNNs), tendo como função primordial a redução das dimensões espaciais — largura e altura — dos mapas de características gerados pelas camadas convolucionais. Essa operação contribui diretamente para diminuir o custo computacional, reduzir o risco de *overfitting* e preservar os elementos mais representativos da estrutura ativacional aprendida (Goodfellow; Bengio; Courville, 2016; Zhao; Zhang, 2024).

O *pooling* atua localmente e de forma independente em cada mapa de características, realizando um resumo estatístico — como o valor máximo (*max pooling*) ou a média (*average pooling*) — em pequenas regiões da entrada. Tal mecanismo confere à rede maior robustez frente a variações espaciais sutis, como deslocamentos, rotações ou ruídos, pois simplifica os dados mantendo as tendências ativacionais mais relevantes (Ahamed et al., 2020; Zhao; Zhang, 2024).

Tal mecanismo confere à rede maior robustez frente a variações espaciais sutis, como deslocamentos, rotações ou ruídos, pois simplifica os dados mantendo as tendências ativacionais mais relevantes (Ahamed et al., 2020; Zhao; Zhang, 2024).

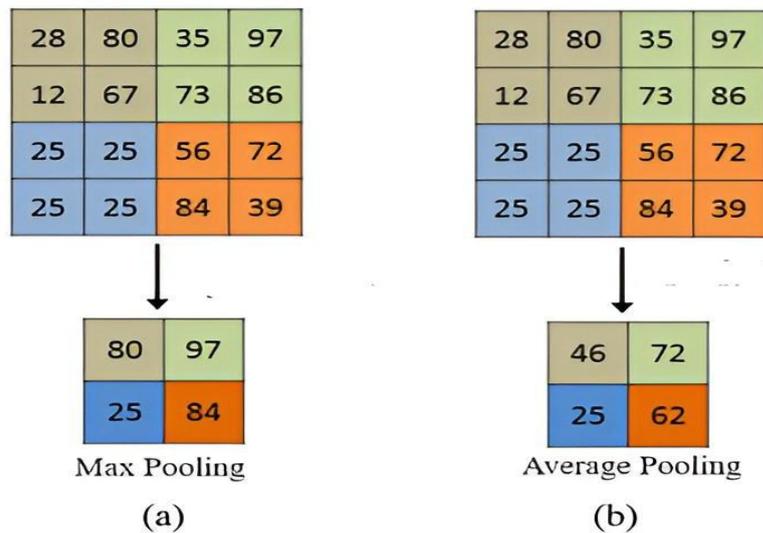
Destacam-se dois tipos principais de *pooling* usados em CNNs:

- *Max Pooling*: aplica-se uma janela (tipicamente 2×2 ou 3×3) sobre o mapa de características e seleciona-se o valor máximo presente em cada região. Este procedimento enfatiza as ativações de maior magnitude, que costumam corresponder aos padrões mais discriminativos na entrada.

- *Average Pooling*: computa-se a média dos valores contidos na janela de *pooling*, resultando em uma forma suavizada da representação. Essa abordagem pode ser vantajosa em cenários nos quais a informação média local melhor preserva características estruturais importantes, priorizando menos a presença de picos isolados.

A Figura 18 ilustra graficamente a diferença entre essas duas estratégias, mostrando como o valor máximo ou a média de cada sub-região é utilizado para compor o novo mapa reduzido de ativação (Ahamed et al., 2020).

Figura 18 – Operações de pooling: max pooling e average pooling com janela 2×2



Fonte: Adaptado de Ahamed, Pratik et al. (2020).

Ao reduzir a resolução dos mapas de ativação, o *pooling* também permite que camadas posteriores operem em representações mais compactas, favorecendo a generalização e a capacidade de abstração da rede. Além disso, o *pooling* contribui para a invariância espacial do modelo, um requisito importante em tarefas onde o posicionamento preciso de um padrão é menos relevante que sua presença geral.

2.6.1.3 Camadas Totalmente Conectadas

Com a redução da dimensionalidade e o enriquecimento das representações por meio das camadas convolucionais e de *pooling*, os dados tornam-se aptos a serem processados pelas camadas finais da rede: as camadas totalmente conectadas, ou *fully connected layers*. Essas camadas são responsáveis por consolidar as informações extraídas pelas etapas anteriores e viabilizar a tomada de decisão. Diferentemente das camadas convolucionais, que operam localmente sobre a entrada, as camadas totalmente conectadas realizam combinações globais

das ativações, conectando cada neurônio a todas as unidades da camada precedente (Alzubaidi et al., 2021; Goodfellow; Bengio; Courville, 2016).

Sua principal função é integrar de maneira não linear as representações aprendidas ao longo da rede, permitindo ao modelo executar tarefas como classificação, regressão ou segmentação, com base nas características hierarquicamente abstraídas. Para que essa operação seja possível, os mapas de características gerados pelas etapas convolucionais e de *pooling* são primeiramente achatados (ou linearizados), transformando-se em um vetor unidimensional que serve de entrada para as camadas densas. A transformação realizada por uma camada totalmente conectada pode ser expressa pela seguinte relação linear:

$$Z = W \cdot X + bZ \quad (2.10)$$

em que:

- $Z \in R^n$ representa o vetor de saída da camada;
- $W \in R^n$ é a matriz de pesos que conecta as entradas às saídas;
- $X \in R^n$ é o vetor de entrada proveniente da etapa de *flattening*;
- $b \in R^n$ é o vetor de bias, adicionado para ajustar a saída.

A essa operação linear, segue-se a aplicação de uma função de ativação não linear, como *ReLU* ou *softmax*, a depender da tarefa-alvo. Tal combinação permite à rede modelar funções complexas, capturar interações entre atributos e distinguir eficientemente entre classes ou padrões subjacentes nos dados.

Portanto, as camadas totalmente conectadas desempenham um papel crítico na arquitetura das Redes Neurais Convolucionais, funcionando como a interface entre os blocos convolucionais — responsáveis pela extração hierárquica de características — e a camada de saída que realiza a inferência final. Ao receber como entrada os vetores unidimensionais resultantes da linearização dos mapas de ativação, essas camadas densas realizam combinações lineares e não lineares globais das representações extraídas, permitindo que a rede integre informações espaciais distribuídas e as projete em um espaço de decisão. Essa etapa de síntese é determinante para a capacidade do modelo em mapear padrões complexos para classes ou valores-alvo, sendo, portanto, essencial para a eficácia preditiva da CNN nas mais diversas tarefas supervisionadas.

2.6.2 RNN

As Redes Neurais Recorrentes (RNNs – *Recurrent Neural Networks*) constituem uma classe de modelos computacionais projetados especificamente para o processamento de dados sequenciais. Sua arquitetura foi concebida com o propósito de capturar e modelar dependências temporais entre os elementos de uma sequência, o que as torna particularmente adequadas para contextos em que a ordem dos dados desempenha papel fundamental (Mienye, Swart & Obaido, 2024).

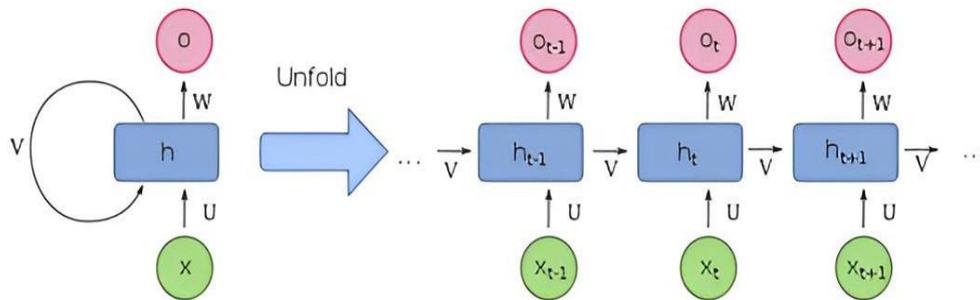
A principal inovação das RNNs, em relação às redes neurais artificiais convencionais do tipo *feedforward*, reside na introdução de um mecanismo de memória interna, que possibilita a retenção de informações ao longo do tempo. Esse mecanismo permite que estados anteriores influenciem o processamento atual, conferindo à rede a capacidade de representar e explorar contextos temporais estendidos (Sun et al., 2023; Mienye, Swart & Obaido, 2024).

Em virtude dessa capacidade de modelar dependências temporais, as RNNs se mostram particularmente eficazes em tarefas nas quais a estrutura sequencial dos dados é determinante, como no processamento de linguagem natural, reconhecimento de fala, análise de sinais fisiológicos (por exemplo, eletroencefalograma – EEG, ou eletrocardiograma – ECG), modelagem de séries temporais financeiras, entre outras aplicações que envolvem previsão de padrões comportamentais ao longo do tempo (Casolaro et al., 2023; Minic et al., 2023; Postepski et al., 2025).

Para viabilizar esse comportamento dinâmico, as RNNs incorporam conexões cíclicas entre os estados ocultos, o que as diferencia estruturalmente das redes *feedforward*, em que as entradas são processadas de forma independente. Essa recorrência permite a persistência de informações relevantes entre diferentes passos temporais. Em termos operacionais, a saída gerada em um determinado instante é realimentada ao modelo e utilizada como entrada adicional no instante subsequente, caracterizando o que se denomina *memória temporal fundamental* (Mienye, Swart & Obaido, 2024).

A Figura 19 exemplifica graficamente o princípio de funcionamento das RNNs, apresentando a representação esquemática de uma célula recorrente, a qual é composta pelos principais elementos responsáveis pelo processamento sequencial de informações ao longo do tempo.

Figura 19 - Representação esquemática de uma Rede Neural Recorrente (RNN) e seu desdobramento temporal



Fonte: Adaptado de Feng et al. (2017).

Em uma Rede Neural Recorrente (RNN), o processamento de dados sequenciais é fundamentado em três elementos principais em cada etapa temporal: o vetor de entrada no tempo atual, denotado por x_t ; o estado oculto da rede, representado por h_t , que funciona como uma memória interna; e o vetor de saída correspondente, indicado por o_t . Embora a estrutura da RNN possa ser representada de forma compacta por uma única célula recorrente, é comum desdobrar essa célula ao longo do tempo, evidenciando sua replicação em diferentes instantes e facilitando a visualização do fluxo de informações entre os estados sucessivos.

Dessa forma, a cada instante t , a rede realiza três operações fundamentais: primeiramente, recebe uma nova entrada x_t ; em seguida, atualiza seu estado oculto h_t , levando em consideração tanto a entrada atual quanto o estado imediatamente anterior h_{t-1} ; por fim, gera uma nova saída o_t com base no estado atualizado. Esse processo iterativo confere à RNN a capacidade de manter o contexto temporal da sequência, uma vez que o estado oculto atua como uma memória dinâmica que armazena informações relevantes ao longo do tempo.

Tal característica é particularmente relevante para tarefas em que a ordem dos dados influencia diretamente o significado da informação, como no reconhecimento de fala, na análise de séries temporais, no processamento de linguagem natural e em diversas outras aplicações que exigem a modelagem de dependências temporais. Ao utilizar o histórico acumulado, a RNN é capaz de produzir respostas mais contextualmente consistentes, representando uma abordagem eficaz para problemas envolvendo dados sequenciais (Mienye, Swart & Obaido, 2024; Ambuj Mehrish et al., 2023).

No entanto, apesar de sua flexibilidade, Redes Neurais Recorrentes (RNNs) tradicionais apresentam limitações significativas na modelagem de dependências temporais de longo prazo.

Tais limitações decorrem, principalmente, dos problemas de desvanecimento e explosão do gradiente, frequentemente observados durante o treinamento por retropropagação no tempo. Esses fenômenos comprometem a atualização eficiente dos pesos da rede ao longo de longas sequências, dificultando o aprendizado de relações temporais distantes (Zucchet & Orvieto, 2024; Mienye, Swart & Obaido, 2024).

Como consequência, embora as RNNs sejam eficazes na captura de dependências de curto prazo, sua performance tende a se degradar em tarefas que demandam a retenção de padrões temporais prolongados, como em séries temporais com sazonalidade anual — por exemplo, o aumento cíclico na demanda por determinados produtos em períodos específicos do ano.

Para mitigar essas deficiências, foram propostas variantes arquiteturais mais robustas, como as Redes de Memória de Longo e Curto Prazo (*Long Short-Term Memory* – LSTM). Essas arquiteturas introduzem mecanismos internos de controle do fluxo de informação, permitindo que a rede selecione, armazene ou descarte informações de maneira adaptativa. Dessa forma, as LSTMs oferecem maior estabilidade no treinamento e melhor desempenho em tarefas que envolvem dependências temporais complexas e de longa duração, sendo amplamente adotadas em diversas aplicações práticas.

2.6.3 Redes de Memória de Longo e Curto Prazo

As Redes de Memória de Longo e Curto Prazo (*Long Short-Term Memory* – LSTM) representam uma extensão das Redes Neurais Recorrentes (RNNs), proposta por Hochreiter e Schmidhuber em 1997, com o objetivo de superar as limitações das RNNs convencionais na modelagem de dependências temporais de longo alcance (Zucchet & Orvieto, 2024; Ghoghj & Ghodsi, 2023).

Embora as RNNs sejam adequadas para capturar padrões de curto prazo em sequências, sua capacidade de manter informações relevantes ao longo de extensos horizontes temporais é comprometida pelos problemas de desvanecimento e explosão do gradiente, frequentemente observados durante o treinamento via retropropagação no tempo (*Backpropagation Through Time* – BPTT). Esses fenômenos dificultam a retenção de contexto, prejudicando o desempenho da rede em tarefas que exigem memória de longo prazo (Zucchet & Orvieto, 2024).

As LSTM mitigam essas limitações por meio de uma arquitetura interna especializada, composta por unidades de memória e portas de controle que regulam dinamicamente o fluxo de informações. As portas — de entrada, de esquecimento e de saída — permitem que a rede, em cada etapa temporal, decida quais informações devem ser armazenadas, atualizadas ou

descartadas. Esse mecanismo de controle refinado confere maior estabilidade ao processo de treinamento e torna a arquitetura eficaz na modelagem de dependências temporais complexas (Ghojogh & Ghodsi, 2023).

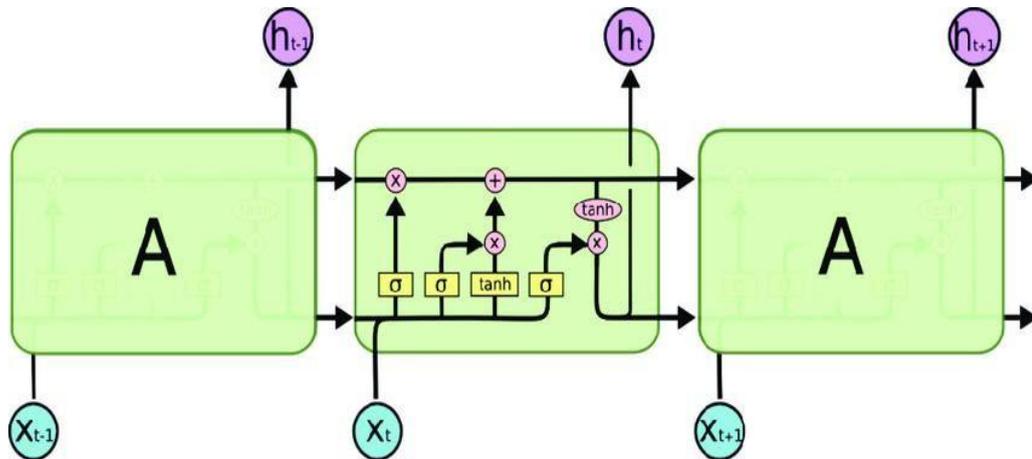
Desde sua proposição, as LSTM têm sido amplamente utilizadas em diversas áreas, incluindo processamento de linguagem natural, reconhecimento de fala, análise de sinais biomédicos e previsão de séries temporais. Sua capacidade de representar relações temporais de longa duração consolidou-as como uma das arquiteturas mais robustas e versáteis para o tratamento de dados sequenciais (Malashin et al., 2024).

Em termos estruturais, as LSTM compartilham com as RNNs convencionais a abordagem baseada no processamento sequencial de dados, com módulos recorrentes repetidos ao longo da dimensão temporal. No entanto, diferenciam-se substancialmente no nível interno de cada módulo. Enquanto as RNNs tradicionais empregam um bloco recorrente simples, composto por uma única transformação linear seguida de uma função de ativação não linear, as LSTM integram uma arquitetura interna significativamente mais complexa, formada por quatro camadas funcionais interdependentes.

Essa complexidade estrutural confere às LSTM uma capacidade aprimorada de regular o fluxo de informações temporais, possibilitando o armazenamento, a atualização seletiva e o descarte de informações ao longo de sequências extensas, de maneira controlada e eficiente.

A figura 20 apresentada ilustra a arquitetura interna do módulo de repetição de uma LSTM, evidenciando sua distinção em relação ao modelo padrão de RNN. A célula LSTM recebe, em cada instante temporal t , o vetor de entrada atual (x_t) e o estado oculto do instante anterior (h_{t-1}), os quais são processados por três portas de controle — porta de esquecimento, porta de entrada e porta de saída — além de um vetor candidato gerado por meio de uma função tangente hiperbólica (\tanh).

Figura 20 Estrutura de repetição em uma arquitetura LSTM



Fonte: Adaptado de Feng, Weijiang et al. (2017).

As operações realizadas internamente são controladas por mecanismos aprendidos durante o treinamento: as portas são implementadas por funções lineares seguidas de ativações sigmóides, conforme representado pelos blocos amarelos na ilustração, enquanto as operações de soma e multiplicação ponto a ponto são indicadas por círculos rosa. O fluxo da informação na célula ocorre conforme descrito a seguir:

- Porta de esquecimento: decide quais componentes do estado da célula anterior (C_{t-1}) devem ser descartados;
- Porta de entrada: em conjunto com o vetor candidato, determina quais informações novas serão incorporadas ao estado atual da célula (C_t);
- Porta de saída: define quais elementos do estado atualizado serão emitidos como saída (h_t) e propagados ao próximo módulo.

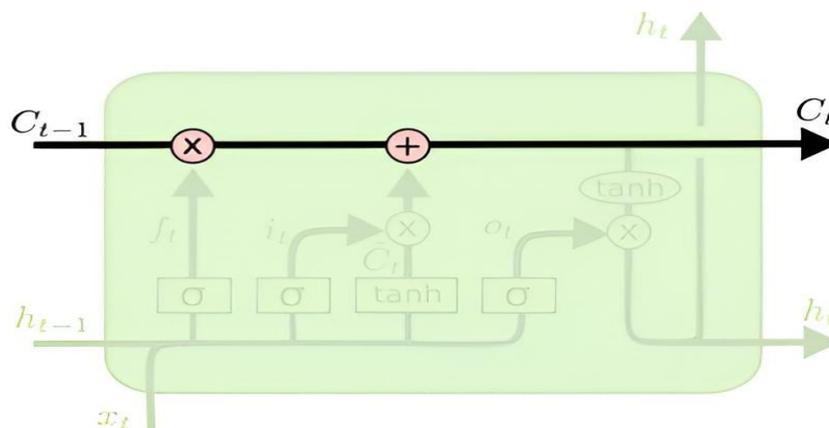
Além disso, o diagrama utiliza convenções visuais importantes para facilitar a interpretação da dinâmica interna da célula: setas simples indicam a propagação de vetores ao longo da sequência temporal, bifurcações correspondem à replicação de informações para múltiplos destinos computacionais, e junções representam operações de concatenação ou combinação de sinais provenientes de diferentes caminhos. Essa arquitetura sofisticada permite à LSTM mitigar os problemas de desvanecimento e explosão do gradiente comumente associados às RNNs tradicionais, viabilizando o aprendizado eficaz de dependências temporais de longo prazo. Por essa razão, as LSTMs têm se consolidado como uma das abordagens mais eficazes para modelagem sequencial, sendo amplamente aplicadas em tarefas como tradução automática, reconhecimento de fala, análise de sentimentos, previsão de séries temporais e interpretação de sinais biomédicos complexos.

2.6.3.1 Arquitetura Funcional e Mecanismos de Controle de Memória nas Redes LSTM

A principal inovação das Redes de Memória de Longo e Curto Prazo (*Long Short-Term Memory* – LSTM) reside na introdução de um componente interno denominado estado da célula (tCt), o qual funciona como uma memória persistente, responsável por armazenar e transportar informações ao longo do tempo. Esse mecanismo foi concebido para superar as limitações inerentes às Redes Neurais Recorrentes (RNNs) tradicionais, especialmente no que se refere à modelagem de dependências temporais de longo alcance e à mitigação dos problemas de desvanecimento do gradiente durante o processo de treinamento (Beck et al., 2024; Ghojogh; Ghodsi, 2023).

Graficamente representado pela linha horizontal que atravessa a célula LSTM (Figura 21), o estado da célula funciona como um canal de memória que propaga informações entre os instantes temporais com interferência mínima. Essa estrutura contínua de transmissão pode ser analogamente interpretada como uma esteira rolante, que transporta informações de forma ininterrupta ao longo da saída — responsáveis por atualizar, preservar ou descartar informações de acordo com a relevância contextual de cada instante, tempo, sendo pontualmente modulada por mecanismos internos de controle — as portas de esquecimento e entrada.

Figura 21– Esquema interno da célula LSTM, destacando o estado da célula (C_t) e o fluxo regulado de informações.



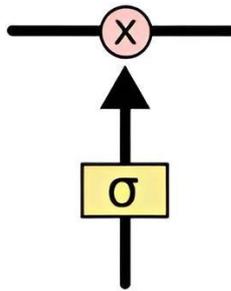
Fonte: Adaptado de Feng, Weijiang et al. (2017).

O fluxo de dados dentro da célula LSTM é, portanto, regulado por essas três portas adaptativas, que determinam de forma seletiva quais informações devem ser mantidas, atualizadas ou descartadas. Cada uma dessas portas é composta por dois elementos fundamentais:

- Uma camada densa com função de ativação sigmoide (σ), responsável por gerar coeficientes de retenção no intervalo $[0, 1]$;
- Uma operação de multiplicação ponto a ponto, que modula a quantidade de informação propagada com base nesses coeficientes.

A estrutura dessas operações está ilustrada na Figura 23, na qual uma ativação sigmoide é seguida de uma multiplicação vetorial com a informação recebida, permitindo o controle preciso do fluxo de memória em cada etapa da sequência.

Figura 22 – Estrutura funcional de uma porta LSTM: camada densa com ativação sigmoide seguida por operação de multiplicação ponto a ponto.



Fonte: Adaptado de Feng, Weijiang et al. (2017).

As três portas funcionais que compõem a célula LSTM são descritas a seguir:

1. Porta de esquecimento (f_t) – regula a remoção de informações do estado da célula anterior (C_{t-1}), permitindo que a rede descarte conteúdos irrelevantes ou obsoletos;
2. Porta de entrada (i_t) – controla a inserção de novas informações no estado da célula atual (C_t), em conjunto com um vetor candidato (\tilde{C}_t) obtido por meio de uma função de ativação hiperbólica (\tanh);
3. Porta de saída (o_t) – define quais partes do estado da célula atualizado serão disponibilizadas como saída oculta (h_t), alimentando os módulos subsequentes da rede.

Na representação esquemática da célula LSTM, os blocos amarelos correspondem a camadas parametrizáveis treinadas durante o processo de otimização, enquanto os círculos rosa indicam operações vetoriais elementares, como multiplicações e somas. As setas representam o fluxo de vetores, com bifurcações simbolizando a replicação de informações e junções indicando combinações ou concatenações.

Essa arquitetura sofisticada possibilita o aprendizado *end-to-end* de padrões temporais extensos, permitindo que a rede aprenda quando e como armazenar, atualizar ou suprimir informações. Essa capacidade torna as LSTM especialmente eficazes em tarefas de modelagem sequencial complexa, como tradução automática, síntese e reconhecimento de fala, análise de sentimentos, séries temporais financeiras e interpretação de sinais biomédicos, como EEG e ECG.

2.6.3.2 Etapas do Processamento Sequencial na Célula LSTM

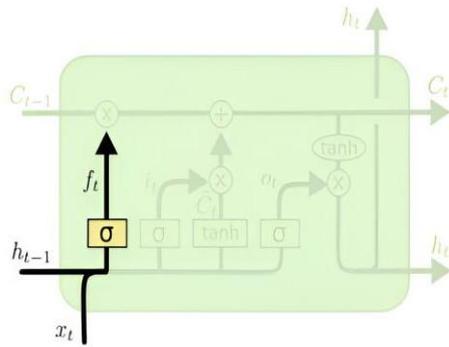
A arquitetura da célula *Long Short-Term Memory* (LSTM) foi desenvolvida com o objetivo de mitigar os problemas de desvanecimento e explosão do gradiente, frequentemente observados em Redes Neurais Recorrentes (RNNs) tradicionais. Essa célula é capaz de preservar informações relevantes ao longo de longas sequências temporais, o que a torna especialmente eficaz em tarefas que envolvem dependências de longo prazo.

O funcionamento da LSTM baseia-se na manipulação de um vetor interno denominado estado da célula (C_t), que atua como memória de longo prazo. Esse vetor é dinamicamente regulado por portas de controle que determinam, a cada instante temporal, o que deve ser mantido, atualizado ou descartado. Cada etapa do processamento realiza transformações específicas nesse vetor de memória, conforme representado nas figuras anteriormente apresentadas (Zhou et al., 2023; Chen et al., 2024).

- **Porta de Esquecimento**

A primeira etapa, representada na Figura 23, envolve a porta de esquecimento, responsável por decidir quais informações do estado da célula anterior (C_{t-1}) devem ser descartadas. Essa decisão é tomada com base na entrada atual (x_t) e no estado oculto anterior (h_{t-1}), que são concatenados e processados por uma camada densa com função de ativação sigmoide. O resultado é um vetor de ativação $f_t \in [0,1]^n$, cujos elementos controlam, ponto a ponto, o grau de retenção de cada componente do estado anterior:

Figura 23 - Porta de esquecimento em uma unidade LSTM



$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.11)$$

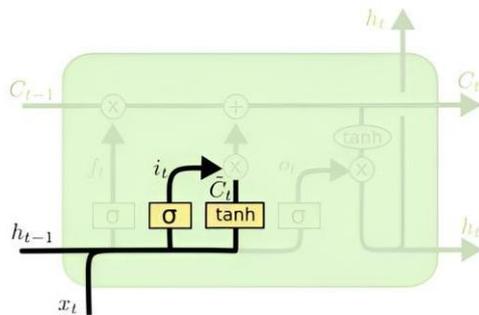
Fonte: Adaptado de Feng, Weijiang et al. (2017).

- **Porta de Entrada e Vetor Candidato**

Na sequência, representada na Figura 24, a célula decide quais novas informações devem ser armazenadas no estado da célula. Esse processo ocorre em duas etapas:

- A porta de entrada, também baseada em uma função sigmoide, gera o vetor i_t , que determina as posições a serem atualizadas;
- Em paralelo, um vetor candidato (\tilde{C}_t) é gerado por meio de uma camada com ativação tangente hiperbólica, representando o novo conteúdo a ser incorporado:

Figura 24 - Porta de entrada em uma unidade LSTM.



$$f_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.12)$$

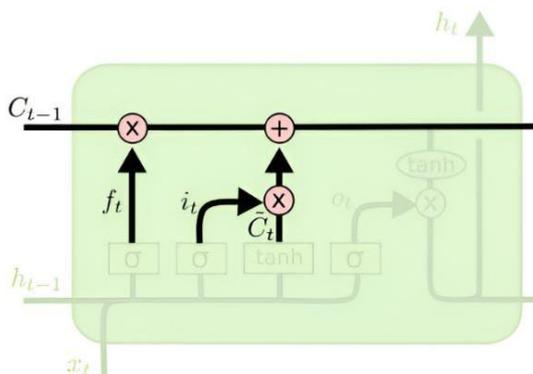
$$C_t = \tanh W_c \cdot [h_{t-1}, x_t] + b_c \quad (2.13)$$

Fonte: Adaptado de Feng, Weijiang et al. (2017).

- **Atualização do Estado da Célula**

O novo estado da célula (C_t), representada na Figura 25, é calculado combinando a memória anterior filtrada pela porta de esquecimento com os valores candidatos ponderados pela porta de entrada:

Figura 25 – Atualização do estado da célula em uma unidade LSTM



$$C_t = f_t * C_{t-1} + i_t * C_t \quad (2.14)$$

Fonte: Adaptado de FENG, Weijiang et al. (2017).

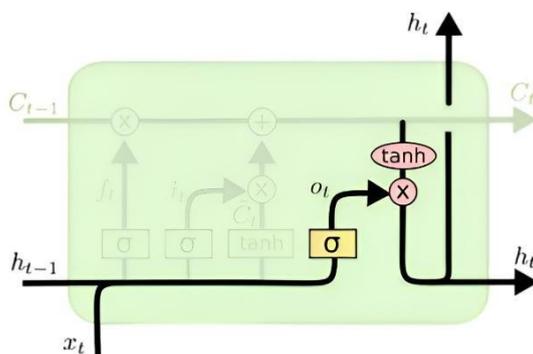
Esse vetor atualizado representa a memória de longo prazo da célula e será utilizado nas etapas seguintes do processamento sequencial.

- **Porta de Saída e Estado Oculto**

Por fim, representada na Figura 26, a porta de saída determina quais partes do novo estado da célula serão expostas como saída oculta (h_t), a ser enviada para a próxima célula ou para camadas superiores da rede. A saída é calculada em duas etapas:

- A ativação sigmoide gera o vetor de controle o_t ;
- O vetor h_t é obtido pela aplicação da função \tanh ao estado atualizado C_t , seguido de uma multiplicação ponto a ponto com o_t ;

Figura 26 - Cálculo da saída de uma unidade LSTM



$$O_t = \sigma(W_0 [h_{t-1}] + b_0) \quad (2.15)$$

$$h_t = o_t * \tanh(C_t) \quad (2.16)$$

Fonte : Adaptado de Feng, Weijiang et al. (2017).

Esse processo é repetido para cada passo temporal da sequência, permitindo que a célula LSTM armazene, atualize ou descarte informações de maneira seletiva, com base no contexto dinâmico da tarefa. Essa capacidade de controle explícito da memória interna é o que torna a LSTM particularmente eficaz em aplicações de modelagem sequencial complexa, como tradução automática, reconhecimento de fala, análise de séries temporais multivariadas e interpretação de sinais biológicos, tais como EEG e ECG.

2.6.4 Modelos Híbridos

Modelos híbridos consistem em sistemas computacionais que integram distintos métodos, paradigmas ou arquiteturas de aprendizado com o propósito de explorar sinergias e potencializar vantagens complementares entre as abordagens envolvidas. A motivação central para a adoção de arquiteturas híbridas reside na superação de limitações inerentes a modelos isolados, especialmente no que se refere ao desempenho, à robustez e à capacidade de generalização. Tais deficiências tornam-se particularmente evidentes em cenários de elevada complexidade, como o processamento de grandes volumes de dados, a análise de sequências

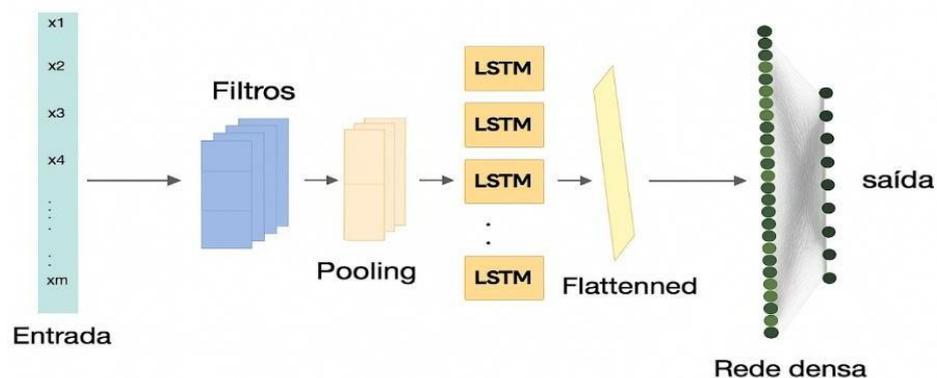
temporais e a detecção de padrões não lineares em contextos ruidosos ou multimodais (Bayouhd, 2024).

A construção de modelos híbridos envolve, frequentemente, a combinação de técnicas de naturezas distintas, como a integração entre modelos estatísticos e redes neurais, a fusão de estratégias supervisionadas e não supervisionadas, ou ainda a articulação de diferentes arquiteturas de redes neurais profundas. Complementarmente, é comum a incorporação de métodos de otimização baseados em algoritmos metaheurísticos com o objetivo de aprimorar o ajuste de hiperparâmetros e favorecer a convergência eficiente das funções de custo (Zhang et al., 2025; Kowalski; Kucharczyk; Mańdziuk, 2025).

Nesse contexto, a sinergia promovida pela hibridização permite aliar a capacidade de generalização de um modelo ao poder preditivo de outro, bem como combinar abordagens especializadas em diferentes estágios do fluxo de processamento, da extração de características à tomada de decisão. Um exemplo amplamente explorado na literatura é o modelo híbrido CNN-LSTM, que conjuga Redes Neurais Convolucionais (CNNs), responsáveis pela extração hierárquica de características espaciais, com Redes Recorrentes do tipo *Long Short-Term Memory* (LSTM), aptas a modelar dependências temporais de longo prazo (Ladjal et al., 2025).

A Figura 27 apresenta uma arquitetura representativa desse tipo de modelo híbrido, em que uma sequência de entrada é submetida a uma série de camadas convolucionais e recorrentes organizadas de forma sequencial. Essa estrutura permite a captura simultânea de padrões espaciais locais e de dinâmicas temporais complexas, constituindo uma abordagem robusta e versátil para tarefas avançadas de classificação sequencial.

Figura 27 - Arquitetura de um modelo CNN-LSTM



Fonte : Adaptado de Hamad et al. (2020).

Modelos híbridos que integram Redes Neurais Convolucionais (CNNs) e Redes Recorrentes do tipo *Long Short-Term Memory* (LSTM) têm se destacado como soluções eficazes para o tratamento de dados com estrutura espaço-temporal, ao combinarem a capacidade das CNNs em extrair padrões locais — como bordas, texturas e formas — com a competência das LSTM em modelar dependências temporais de longo prazo. Originalmente concebidas para tarefas de visão computacional, as CNNs operam por meio da aplicação de filtros convolucionais sobre os dados de entrada, como imagens, sinais ou séries multivariadas, gerando representações hierárquicas e invariantes das estruturas espaciais. Após sucessivas camadas convolucionais e de *pooling*, obtém-se uma representação vetorial condensada, a qual é encaminhada à LSTM. Esta última processa a sequência resultante, preservando a ordem temporal e capturando correlações de longa duração ao longo da série (Pandey et al., 2024).

A adoção dessa arquitetura híbrida revela-se particularmente vantajosa em domínios que demandam análise simultânea de informações espaciais e temporais. Exemplos incluem a análise de vídeos, em que a CNN extrai características espaciais de cada quadro, enquanto a LSTM modela sua evolução temporal; a classificação de séries temporais multivariadas, como sinais biomédicos (e.g., EEG ou ECG), em que a CNN identifica padrões locais em janelas deslizantes e a LSTM representa a continuidade temporal; e o processamento de linguagem natural multimodal, como na análise de sentimentos em vídeos, nos quais transcrições textuais e expressões faciais são avaliadas conjuntamente (Alasmari et al., 2024).

Do ponto de vista arquitetural, a implementação típica desses modelos segue uma abordagem sequencial em duas fases bem definidas. A primeira é composta por camadas convolucionais (unidimensionais ou bidimensionais, conforme a natureza dos dados), seguidas por camadas de *pooling* e, eventualmente, por uma etapa de achatamento (*flattening*) para transformar os mapas de ativação em vetores compatíveis. A segunda fase compreende uma ou mais camadas LSTM, responsáveis pelo processamento sequencial das representações extraídas. Por fim, camadas densas, dotadas de funções de ativação adequadas ao objetivo da tarefa — como *softmax* para classificação ou ativação linear para regressão — são utilizadas para a produção da saída final do modelo (Anam et al., 2024).

Apesar dos benefícios observados em termos de acurácia, capacidade de generalização e robustez a ruído, a implementação de modelos híbridos exige cuidados específicos, especialmente no que tange ao pré-processamento e à transformação dos dados entre os módulos convolucional e recorrente. É fundamental assegurar que a saída da CNN esteja compatível com o formato de entrada requerido pela LSTM, sendo frequente o emprego de operações de *reshaping*, normalização e padronização dimensional.

Em síntese, arquiteturas híbridas baseadas na integração CNN-LSTM constituem uma solução versátil e robusta para problemas complexos que envolvem múltiplas dimensões de informação. Ao unirem a extração hierárquica de características proporcionada pelas CNNs à capacidade de modelagem sequencial das LSTM, tais modelos têm demonstrado elevado desempenho em tarefas de classificação, predição e reconhecimento de padrões, sendo amplamente empregados em aplicações reais nas áreas de saúde, segurança, finanças, indústria e inteligência artificial aplicada (Sinha et al., 2025).

3. METODOLOGIA

A metodologia proposta realiza uma análise quantitativa e sistemática do desempenho na classificação automática de diferentes tipos de crises epiléticas, abrangendo os seguintes subtipos: generalizada não específica (GNSZ), parcial complexa (CPSZ), focal não específica (FNSZ) e tônico-clônica (TCSZ).

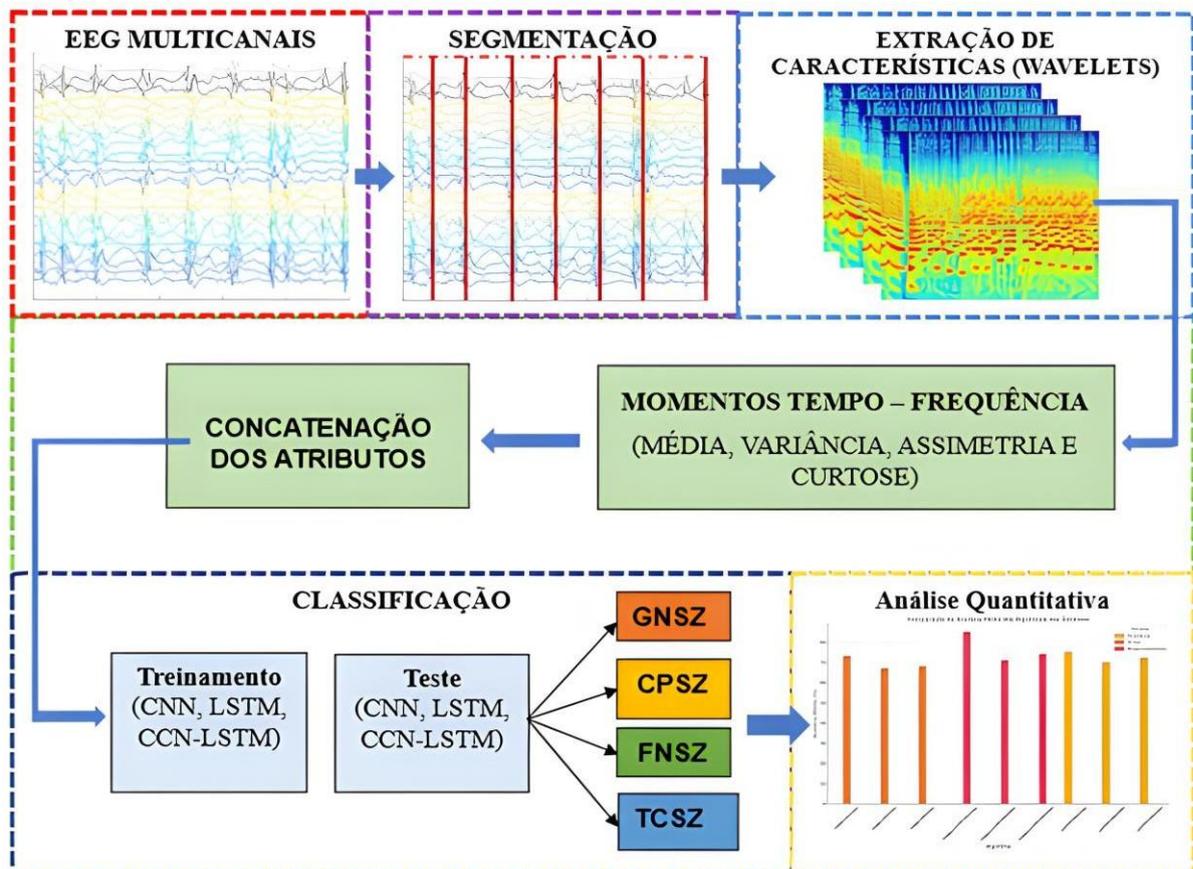
A abordagem adotada fundamenta-se na extração de três momentos característicos — Momento Espectral Condicional, Momento Temporal Condicional e Momento Conjunto de Tempo e Frequência — obtidos a partir da distribuição tempo-frequência dos sinais EEG, gerada por meio da Transformada *Wavelet* Contínua (CWT). Essa transformada permite a representação simultânea das componentes temporal e espectral do sinal, sendo particularmente adequada para a análise de fenômenos cerebrais não estacionários, como as crises epiléticas, cuja dinâmica varia ao longo do tempo e das faixas de frequência.

Para a tarefa de classificação, foram implementados modelos de aprendizado profundo, contemplando arquiteturas baseadas em Redes Neurais Convolucionais (CNN), Redes LSTM e uma configuração híbrida CNN-LSTM, com o objetivo de explorar diferentes capacidades de extração e modelagem de padrões espaciais e temporais nos sinais EEG. A avaliação do desempenho dos modelos foi realizada com base em métricas quantitativas amplamente consolidadas na literatura, tais como acurácia, precisão, recall e F1-score, visando assegurar uma análise abrangente e comparável da eficácia dos classificadores.

Os experimentos foram conduzidos em três cenários distintos de avaliação: (i) classificação baseada exclusivamente em características extraídas a partir dos momentos condicionais temporais; (ii) classificação fundamentada unicamente em características obtidas por meio dos momentos condicionais espectrais; e (iii) classificação utilizando características conjuntas no domínio tempo-frequência, derivadas dos momentos conjuntos. Essa estrutura experimental tem por objetivo analisar, de forma isolada e combinada, a contribuição de cada tipo de representação na performance dos modelos, bem como avaliar a robustez e a relevância discriminativa dos atributos extraídos para a tarefa de classificação automática das crises epiléticas.

A Figura 28 apresenta o diagrama esquemático da metodologia proposta, descrevendo o fluxo das etapas de pré-processamento, extração de características, modelagem e avaliação da classificação automática das crises epiléticas.

Figura 28- Diagrama Esquemático



Fonte: Autor

A primeira etapa consistiu no pré-processamento dos sinais de EEG obtidos da base de dados pública *Temple University Hospital Seizure Corpus* (TUSZ), disponibilizada pelo *Temple University Hospital* (TUH), um centro médico acadêmico localizado na Filadélfia, Pensilvânia, integrante da rede de saúde Temple Health (Albaqami; Hassan; Datta, 2022; Temple University, 2025).

Após o pré-processamento, os sinais foram segmentados em janelas retangulares de 10 segundos, sem sobreposição, a fim de viabilizar a padronização dos dados e facilitar a extração de características.

Os segmentos extraídos dos sinais de pacientes com epilepsia foram rotulados de acordo com suas respectivas classes clínicas, a saber: GNSZ (*Generalized Non-Specific Seizure*), FNSZ (*Focal Non-Specific Seizure*), CPSZ (*Complex Partial Seizure*) e TCSZ (*Tonic-Clonic Seizure*), possibilitando a construção dos conjuntos de dados para a análise supervisionada.

Na etapa seguinte, foi realizada a extração de características estatísticas por canal, posteriormente combinadas em um único vetor representativo por segmento, com o objetivo de sintetizar a informação multicanal e prepará-la para os modelos de classificação.

Para isso, aplicou-se a Transformada *Wavelet* Contínua (TWC), gerando representações no domínio tempo-frequência dos sinais EEG. Três funções wavelet-mãe foram utilizadas: *Morse*, *Morlet (Gabor)* e *Bump*, a fim de explorar diferentes resoluções temporais e espectrais.

A partir dos espectrogramas gerados, foram extraídos os quatro primeiros momentos condicionais — média, variância, assimetria e curtose — nos domínios temporal e espectral, além do momento conjunto tempo-frequência, os quais foram utilizados como atributos discriminantes na classificação dos diferentes tipos de crises epilépticas.

Para a tarefa de classificação multiclasse das crises epilépticas, foram implementados três modelos de aprendizado profundo: CNN, LSTM e uma arquitetura híbrida CNN-LSTM, com o objetivo de categorizar as diferentes classes de eventos epilépticos. O desempenho dos modelos foi avaliado por meio do método de validação cruzada *k-fold*, o que contribuiu para uma análise mais robusta e reduziu o viés amostral.

As métricas utilizadas incluíram acurácia, recall, precisão e F1-score, permitindo uma avaliação abrangente da eficácia de cada modelo. Essa abordagem possibilitou a identificação da arquitetura com melhor desempenho na discriminação entre os diferentes tipos de crises, contribuindo de forma significativa para o avanço da análise automatizada e da interpretação clínica dos sinais epilépticos.

3.1 Banco de dados EEG

A base de dados utilizada neste estudo foi a TUSZ versão 1.5.2 (*Temple University Hospital EEG Seizure Corpus*), um subconjunto da TUEG (*Temple University Hospital EEG Data Corpus*), disponibilizada pelo *Neural Engineering Data Consortium* (NEDC). Reconhecida como uma das principais bases públicas e referências internacionais para pesquisa em epilepsia, a TUSZ tem sido amplamente empregada no desenvolvimento e validação de algoritmos de aprendizado de máquina e técnicas de processamento de sinais biomédicos, com foco na detecção e classificação de crises epilépticas (Abirami et al., 2024; Albaqami; Hassan; Datta, 2022; Temple University, 2025).

Os sinais contidos na base são armazenados no formato EDF (*European Data Format*), o que assegura compatibilidade com ferramentas amplamente utilizadas na área, como MNE, pyEDFlib e MATLAB. As gravações foram realizadas em ambiente clínico no Temple University Hospital (TUH), com aplicação da montagem TCP/AR baseada no sistema internacional 10-20, e uma frequência mínima de amostragem de 250 Hz. O conjunto de dados foi coletado de mais de 300 pacientes, abrangendo uma ampla faixa etária — de crianças a

idosos —, o que confere diversidade e potencial de generalização aos modelos construídos (Yan et al., 2025,).

O corpus contempla diferentes padrões neurológicos, incluindo eventos epiléticos, períodos normais e artefatos fisiológicos ou ambientais. As anotações dos sinais foram realizadas por especialistas, com base em critérios eletrográficos, eletro clínicos e clínicos, assegurando uma rotulação precisa e confiável dos eventos. A base contém 3.050 eventos epiléticos, com registros de pelo menos 15 minutos de duração cada, o que fornece um volume substancial de dados para análise computacional (Abirami et al., 2024; Zhao et al., 2024).

Neste estudo, foram selecionados quatro tipos de crises com base em sua maior representatividade estatística na versão 1.5.2:

- Generalizada não específica (GNSZ): crises que envolvem ambos os hemisférios cerebrais, com atividade elétrica síncrona e sem origem focal definida;
- Parcial complexa (CPSZ): crises que se originam em uma região específica do cérebro e frequentemente comprometem a consciência;
- Focal não específica (FNSZ): crises com atividade epilética restrita a uma região cortical, sem elementos clínicos suficientes para subclassificação mais precisa;
- Tônico-clônicas (TCSZ): crises generalizadas que apresentam uma fase tônica (rigidez muscular) seguida por uma fase clônica (movimentos rítmicos involuntários).

Os demais tipos de crises presentes no TUSZ foram excluídos da análise em virtude de sua baixa ocorrência, a fim de preservar a representatividade estatística e a robustez do treinamento dos modelos de classificação.

3.2 Pré-processamento do sinal de EEG

Os sinais de EEG utilizados neste estudo foram extraídos da base de dados descrita na seção anterior e categorizados de acordo com os tipos de crises epiléticas: GNSZ, CPSZ, FNSZ e TCSZ. Devido à qualidade satisfatória dos registros, não foi necessária a aplicação de filtros adicionais para remoção de ruídos indesejados, tais como artefatos oculares, interferências musculares e ruídos extracerebrais, uma vez que esses componentes já haviam sido adequadamente atenuados durante o pré-processamento automatizado realizado pela própria base de dados.

Em seguida, os sinais de EEG de cada canal foram segmentados em janelas de 10 segundo, utilizando uma função janela retangular. A escolha desse intervalo baseou-se em

evidências da literatura especializada em análise de EEG, sendo considerado suficiente para capturar padrões relevantes associados a crises epiléticas. Estudos demonstram que janelas nessa escala temporal oferecem um bom equilíbrio entre resolução e estabilidade na detecção de eventos ictais, além de favorecer a extração de características discriminantes (Zhang et al., 2018; Vandecasteele et al., 2020).

A segmentação foi realizada sem sobreposição entre as janelas, a fim de garantir a independência estatística entre os segmentos. O tamanho de cada segmento foi definido pelo produto entre a taxa de amostragem do sinal e a duração da janela, assegurando a integridade dos dados e a uniformidade no processo de extração de características.

Após a segmentação, o conjunto final de dados consistiu em 4.800 segmentos de EEG, distribuídos de forma balanceada entre as quatro classes de crises epiléticas analisadas, com 1.200 segmentos por tipo de crise (GNSZ, CPSZ, FNSZ e TCSZ). Esse balanceamento foi essencial para evitar viés nos algoritmos de classificação, uma vez que conjuntos desbalanceados tendem a favorecer classes mais representadas, comprometendo a performance geral dos modelos de aprendizado de máquina e reduzindo sua capacidade de generalização para novos dados.

3.3 Extração de características do sinal de EEG

Após a segmentação dos sinais de EEG multicanais, procedeu-se à obtenção das representações no domínio tempo-frequência por meio da Transformada *Wavelet* Contínua (CWT), aplicada individualmente a cada canal e classe de sinal. A partir dos espectrogramas resultantes, foram extraídos quatro momentos estatísticos de ordem inferior — média, variância, assimetria e curtose —, os quais caracterizam a distribuição de energia ao longo do tempo e da frequência. Esses parâmetros foram calculados para três domínios distintos: o domínio temporal condicional, o domínio espectral condicional e o domínio conjunto tempo-frequência, de modo a capturar diferentes aspectos da dinâmica não estacionária dos sinais eletroencefalográficos.

Assim, para a aplicação da metodologia proposta, foi construído o conjunto de matrizes M^j , derivado do T-ésimo segmento multicanal do sinal EEG, contendo ch canais, associado ao padrão j a ser reconhecido. As classes consideradas foram GNSZ, CPSZ, FNSZ e TCSZ, conforme apresentado na equação (3.1):

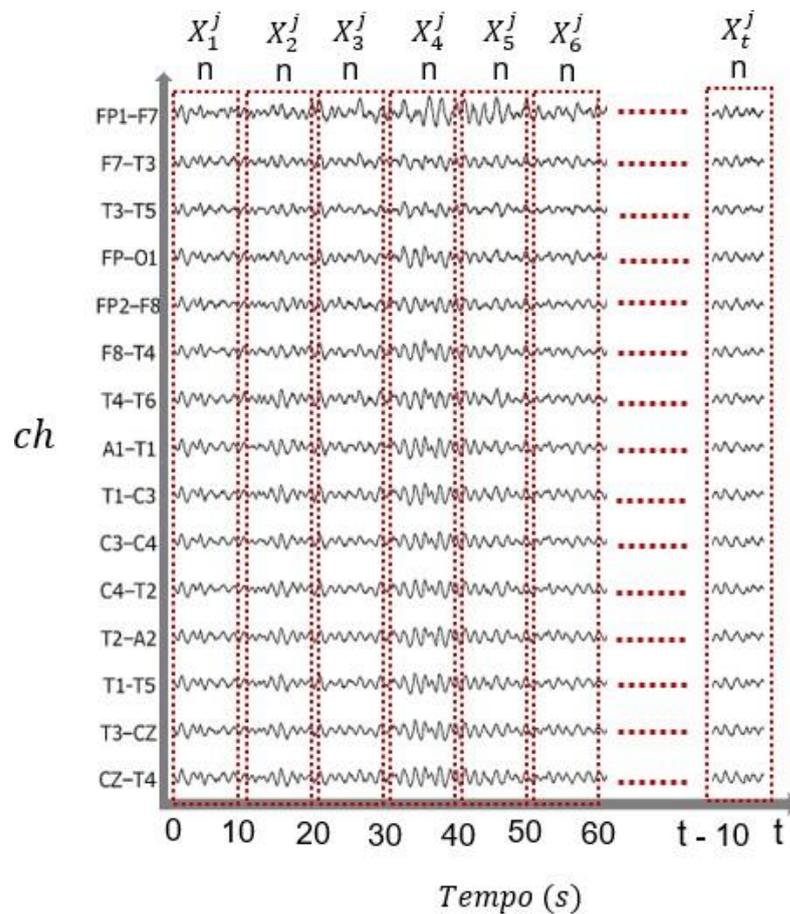
$$M^j = \{X_1^j, X_2^j, X_3^j \dots, X_T^j\} \quad (3.1)$$

A matriz X corresponde a um segmento temporal multicanal do sinal de EEG, obtido a partir da extração simultânea de uma janela fixa de tempo em todos os canais disponíveis.

Estruturalmente, $X \in R^{ch \times n}$, sendo ch o número de canais e n o número de amostras por segmento. Este último é determinado pelo produto entre a frequência de amostragem (f_a) e a duração da janela temporal ($T=10$ s), o que assegura a manutenção da resolução temporal do sinal original.

A Figura 29 ilustra esquematicamente o processo de formação do conjunto de matrizes M^j , que agrega os segmentos temporais associados à classe j , representando assim a organização dos dados de acordo com os diferentes tipos de crises epilépticas consideradas neste estudo.

Figura 29 - Representação esquemática da formação do conjunto de matrizes M^j



Fonte: Autor

A partir do conjunto M^j , procede-se à etapa de extração de características dos sinais de EEG. Nesta fase, aplica-se a Transformada Wavelet Contínua (CWT) a cada linha da matriz $X \in M^j$, sendo que cada linha representa um canal individual do segmento multicanal. Para

essa análise, são utilizadas três diferentes funções wavelet-mãe — Morse, Morlet e Bump — a fim de explorar distintos padrões morfológicos e resoluções tempo-frequência. Assim, para cada matriz X_t^j correspondente ao T-ésimo segmento da classe j, obtêm-se três conjuntos de matrizes de distribuição de energia no domínio tempo-frequência, associadas a cada função wavelet aplicada, conforme representado na equação (3.2).

$$\zeta^j(t, f) = \left\{ \begin{bmatrix} W_1^{(t, f)} \\ W_2^{(t, f)} \\ \vdots \\ W_{ch}^{(t, f)} \end{bmatrix}_1, \begin{bmatrix} W_1^{(t, f)} \\ W_2^{(t, f)} \\ \vdots \\ W_{ch}^{(t, f)} \end{bmatrix}_2, \begin{bmatrix} W_1^{(t, f)} \\ W_2^{(t, f)} \\ \vdots \\ W_{ch}^{(t, f)} \end{bmatrix}_3, \dots, \begin{bmatrix} W_1^{(t, f)} \\ W_2^{(t, f)} \\ \vdots \\ W_{ch}^{(t, f)} \end{bmatrix}_T \right\} \quad (3.2)$$

Onde

$$W_{ch}^{(t, f)}(M \times n) = \begin{bmatrix} W_{s_1} 1 & W_{s_1} 2 & \dots & W_{s_1} n \\ W_{s_2} 1 & W_{s_2} 2 & \dots & W_{s_2} n \\ \vdots & \vdots & \ddots & \vdots \\ W_{s_M} 1 & W_{s_M} 2 & \dots & W_{s_M} n \end{bmatrix} \quad (3.3)$$

É a matriz de distribuição de energia tempo-frequência do ch – ésimos canal do T-ésimo segmento. M é o número de escalas de análise da Transformada Contínua Wavelet, s_M é a M -ésima escala da TCW e $W_{s_M} n$ é o n -ésimo coeficiente da TCW na escala s_M . Uma vez formado o conjunto $\delta_j(t, f)$, quatro momentos conjuntos tempo-frequência são gerados a partir da ch -ésima matriz $W(t, f)$ do T-ésimo segmento: média - $\mu(t, f)$ 3.4, variância - $\sigma^2(t, f)$ 3.5, assimetria - $\lambda(t, f)$ 3.6 e curtose - $K(t, f)$ 3.7. Dessa forma, obtêm-se quatro conjuntos de métricas estatísticas para as diferentes TCW:

$$\mathcal{M}_{\mu(t, f)}^j = \{Md_1^j, Md_2^j, Md_3^j, \dots, Md_T^j\} \quad (3.4)$$

$$\mathcal{V}_{\sigma^2(t, f)}^j = \{Var_1^j, Var_2^j, Var_3^j, \dots, Var_T^j\} \quad (3.5)$$

$$\mathcal{A}_{\lambda(t, f)}^j = \{Ass_1^j, Ass_2^j, Ass_3^j, \dots, Ass_T^j\} \quad (3.6)$$

$$\mathcal{K}_{\kappa(t, f)}^j = \{Curt_1^j, Curt_2^j, Curt_3^j, \dots, Curt_T^j\} \quad (3.7)$$

Onde

$$Md_T^j = \begin{bmatrix} \mu_{(t,f)}^1 \\ \mu_{(t,f)}^2 \\ \vdots \\ \mu_{(t,f)}^{ch} \end{bmatrix}_{ch \times 1} \quad (3.8)$$

$$Var_T^j = \begin{bmatrix} \sigma_{(t,f)}^2{}^1 \\ \sigma_{(t,f)}^2{}^2 \\ \vdots \\ \sigma_{(t,f)}^2{}^{ch} \end{bmatrix}_{ch \times 1} \quad (3.9)$$

$$Ass_T^j = \begin{bmatrix} \lambda_{(t,f)}^1 \\ \lambda_{(t,f)}^2 \\ \vdots \\ \lambda_{(t,f)}^{ch} \end{bmatrix}_{ch \times 1} \quad (3.10)$$

$$Curt_T^j = \begin{bmatrix} \kappa_{(t,f)}^1 \\ \kappa_{(t,f)}^2 \\ \vdots \\ \kappa_{(t,f)}^{ch} \end{bmatrix}_{ch \times 1} \quad (3.11)$$

Portanto, os atributos extraídos dos canais de cada segmento, conforme definidos nas equações (3.8), (3.9), (3.10) e (3.11), são agregados por meio da concatenação das médias dos respectivos conjuntos de características. Dessa forma, cada classe de crise epiléptica — GNSZ, CPSZ, FNSZ e TCSZ — é representada por um conjunto \mathcal{VC}^j composto pelo vetor de atributos Ve^j , cujos elementos são os índices de integração são os momentos tempo-frequência $Ec_{\mu_{(t,f)}}$, $Ec_{\sigma_{(t,f)}^2}$, $Ec_{\lambda_{(t,f)}}$, $Ec_{\kappa_{(t,f)}}$ (3.12) :

$$\mathcal{VC}^j = \{Ve_1^j, Ve_2^j, Ve_3^j, \dots, Ve_T^j\} \quad (3.12)$$

3.4 Modelos de classificação das crises epilépticas

Para o desenvolvimento dos modelos de classificação multiclasse baseados em aprendizado profundo — CNN, LSTM e o modelo híbrido CNN-LSTM — foram utilizadas as

bibliotecas TensorFlow, para a construção e o treinamento das arquiteturas de *deep learning*; *scikit-learn*, para o pré-processamento dos dados, validação cruzada e cálculo de métricas de desempenho; Pandas, para manipulação e organização de dados tabulares; e NumPy, para operações vetoriais e computação matricial. A escolha dessas bibliotecas se deve à sua eficiência e ampla aplicação em projetos de aprendizado profundo (Harris *et al*, 2020; Ahmed, 2024).

Após a extração e vetorização das características em tempo-frequência, conforme descrito na seção anterior, os dados foram analisados para identificar possíveis anomalias, tendências e padrões relevantes. Em seguida, aplicou-se a normalização utilizando a função *MinMaxScaler*, que transforma os valores de cada amostra para um intervalo pré-definido entre 0 e 1. Essa etapa tem como objetivo uniformizar as escalas das variáveis, minimizando o impacto de diferenças de magnitude entre os atributos. Como resultado, a normalização melhora o processamento dos dados, acelera a convergência durante o treinamento dos modelos e aumenta o desempenho final, garantindo uma aprendizagem mais eficiente e precisa.

Com o objetivo de verificar a capacidade de generalização, reduzir o viés nas avaliações e detectar *overfitting*, foi utilizada a técnica de *K-Fold Cross-Validation*, com $K = 10$, dividindo o conjunto de dados em dez subconjuntos (*folds*) de tamanho aproximadamente igual. A cada iteração, um dos subconjuntos foi utilizado para validação, enquanto os nove restantes foram empregados no treinamento, garantindo que cada subconjunto fosse utilizado como validação uma única vez.

As métricas de desempenho foram calculadas em cada iteração e, posteriormente, agregadas, fornecendo uma estimativa média da capacidade do modelo de generalizar para novos dados. A escolha de $K = 10$ busca equilibrar eficiência computacional e confiabilidade, sendo amplamente adotada em problemas de aprendizado de máquina.

Dado que se trata de um problema de classificação multiclasse, utilizou-se a função `to_categorical` da biblioteca *Keras* para converter rótulos inteiros em uma representação *one-hot encoded*. Essa técnica, fundamental em modelos de *Deep Learning*, transforma variáveis categóricas em um formato binário compatível com algoritmos de aprendizado de máquina, garantindo que cada classe seja representada de forma independente e evitando associações incorretas entre os rótulos.

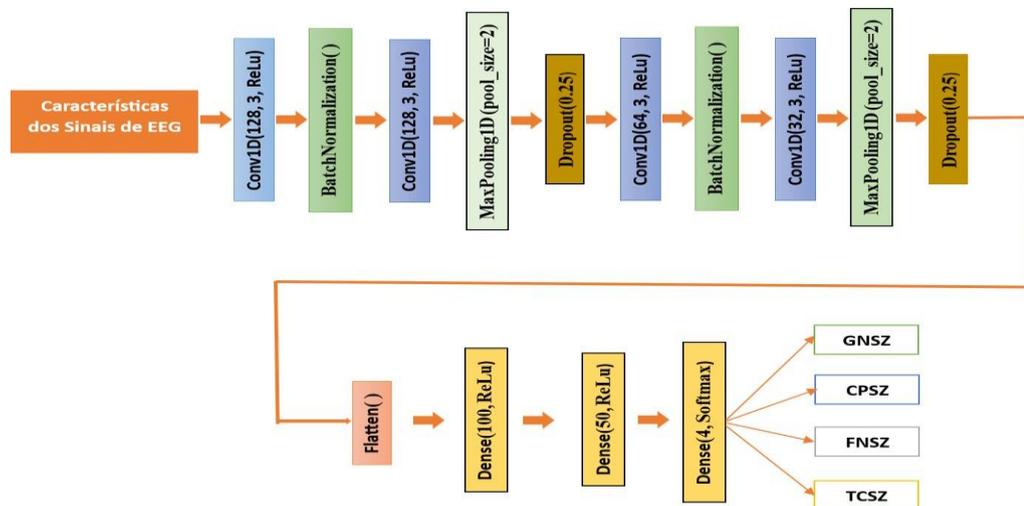
Dessa forma, os modelos de algoritmos de aprendizagem profunda (CNN, LSTM e CNN-LSTM) foram projetados com base em uma seleção criteriosa de hiperparâmetros, como o número de filtros nas camadas convolucionais, o tamanho do kernel, a taxa de *dropout* e o número de unidades nas camadas densas e recorrentes. Essas escolhas têm um impacto

significativo na eficácia da classificação dos sinais EEG, influenciando diretamente a capacidade de aprendizado e generalização dos modelos.

O modelo CNN, apresentado na Figura 30, foi estruturado com três camadas convolucionais unidimensionais (Conv1D) contendo 128, 64 e 32 filtros, respectivamente. Nessas camadas, utilizou-se a função de ativação ReLU para introduzir não-linearidade e potencializar a extração de padrões relevantes dos sinais EEG. Para estabilizar o treinamento e acelerar a convergência, foram aplicadas camadas de *Batch Normalization* após as convoluções. Além disso, a regularização foi reforçada com camadas de *dropout*, utilizando uma taxa de 0,25, para mitigar o *overfitting* ao desativar aleatoriamente um subconjunto de neurônios durante o treinamento.

Após a extração de características pelas camadas convolucionais, o modelo conta com três camadas densas. A primeira, com 100 unidades, e a segunda, com 50 unidades, utilizam a função de ativação ReLU, permitindo a transformação não-linear dos dados extraídos. Já a terceira e última camada densa, composta por 4 unidades, emprega a função de ativação *softmax*, garantindo a produção de probabilidades normalizadas para a classificação dos sinais EEG.

Figura 30 - Modelo CNN



Fonte: Autor

O modelo LSTM, apresentado na Figura 31 é uma rede neural recorrente projetada para a classificação de dados sequenciais, considerando as características temporais e espectrais dos sinais de EEG. Sua arquitetura inclui camadas LSTM para extração de padrões temporais, camadas de *dropout* para regularização e camadas densas para projeção no espaço de classes.

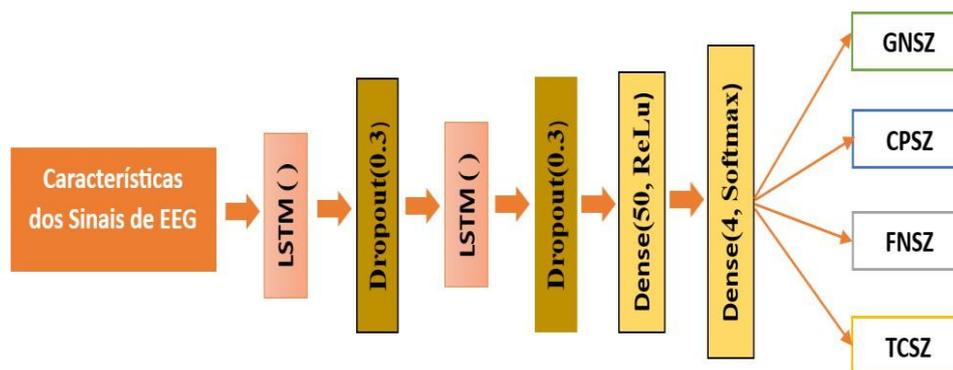
A primeira camada LSTM, com 100 unidades, recebe como entrada uma sequência de características dos sinais de EEG. O hiperparâmetro *return_sequences=True* mantém a saída

como uma sequência completa de estados ocultos, permitindo a propagação da informação temporal. A segunda camada LSTM, com 50 unidades, processa essa saída e, com *return_sequences=False*, repassa apenas o último estado oculto para as camadas seguintes, reduzindo a dimensionalidade e compactando a representação da sequência.

Camadas de dropout com taxa de 30% são empregadas para reduzir *overfitting*, desativando aleatoriamente conexões neurais durante o treinamento. Em seguida, uma camada densa com 50 neurônios e ativação ReLU refina a representação extraída pelas LSTMs, tornando-a mais adequada à classificação.

Por fim, a camada de saída, com 4 neurônios e ativação *softmax*, gera as probabilidades normalizadas, permitindo a interpretação das previsões em termos de pertencimento às quatro classes do problema.

Figura 31- Modelo LSTM



Fonte : Autor

O modelo CNN-LSTM, apresentado na Figura 32, combina redes neurais convolucionais (CNNs) e redes de memória de longa curta duração (LSTMs) para a modelagem e processamento de características sequenciais extraídas dos sinais de EEG. Essa abordagem híbrida visa integrar a capacidade das CNNs na captura de padrões espaciais com a eficiência das LSTMs na modelagem de dependências temporais, permitindo uma representação mais robusta e informativa dos dados antes da etapa de classificação.

Na fase convolucional, as camadas Conv1D extraem características locais, identificando padrões espaciais relevantes e reduzindo a dimensionalidade dos dados antes de sua entrada na componente recorrente. A primeira camada convolucional, composta por 128 filtros e kernel de tamanho 3, é responsável pela detecção de padrões locais ao longo da sequência temporal. A função de ativação ReLU é empregada para introduzir não linearidade ao modelo, enquanto a normalização em lote (*BatchNormalization*) é aplicada para estabilizar

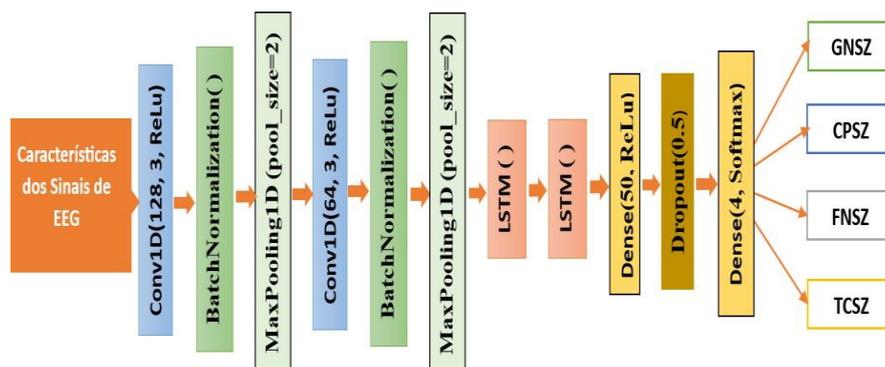
os gradientes e mitigar o efeito da covariância interna. A camada `MaxPooling1D`, com `pool_size` de 2, reduz a dimensionalidade da saída convolucional, preservando informações discriminativas essenciais e minimizando redundâncias nos dados.

Na sequência, a segunda camada `Conv1D`, agora com 64 filtros, diminui a complexidade da representação extraída, reduzindo a carga computacional sem comprometer a expressividade do modelo. A normalização em lote é novamente aplicada para garantir a estabilidade dos gradientes, seguida por uma segunda camada `MaxPooling1D`, que aprimora a compactação das características antes da entrada nas camadas recorrentes.

Na fase recorrente, as camadas `LSTM` são responsáveis por capturar relações temporais de longo prazo nos sinais. A primeira camada `LSTM`, com 64 unidades e `return_sequences=True`, mantém a sequência completa de estados ocultos para a próxima camada, garantindo a preservação da informação ao longo do tempo. Por sua vez, a segunda camada `LSTM`, também com 64 unidades, configura `return_sequences=False`, transmitindo apenas o último estado oculto às camadas subsequentes, o que resulta em uma representação latente compacta da sequência analisada.

A etapa de classificação é conduzida por camadas densas, que refinam as representações extraídas e projetam os dados no espaço das classes. A primeira camada densa, com 50 unidades e ativação `ReLU`, permite uma transformação não linear das características aprendidas, proporcionando maior capacidade discriminativa ao modelo. Para mitigar *overfitting* e aprimorar a generalização, um mecanismo de *dropout* com taxa de 50% é incorporado, desativando aleatoriamente conexões neurais durante o treinamento. Por fim, a camada de saída, composta por 4 neurônios e ativação *softmax*, gera a distribuição de probabilidade para cada classe, permitindo a inferência do modelo conforme a taxonomia do problema de classificação multiclasse.

Figura 32 -Modelo CNN-LSTM



Fonte : Autor

Para o treinamento dos modelos, foi empregada a função de perda *crossentropy*, amplamente utilizada em tarefas de classificação multiclasse, pois quantifica a discrepância entre as distribuições de probabilidade preditas pelo modelo e os rótulos verdadeiros. Como estratégia de otimização, foi adotado o algoritmo *Adam* (*Adaptive Moment Estimation*), que combina as vantagens dos métodos momentum e RMSprop, permitindo uma adaptação dinâmica da taxa de aprendizado e garantindo uma convergência mais eficiente.

O treinamento foi realizado utilizando batches, processando subconjuntos do conjunto de dados a cada iteração, o que possibilita a otimização do uso da memória e acelera a convergência do modelo. Foi estipulado um total de 150 épocas, considerando que um número excessivo pode levar à sobre adaptação (*overfitting*), comprometendo a capacidade de generalização, enquanto um número reduzido pode resultar em sub ajuste (*underfitting*), impedindo que o modelo aprenda padrões relevantes dos dados.

Após o término do treinamento e a realização de ajustes com base no desempenho no conjunto de validação, a eficácia na discriminação das classes foi avaliada por meio de métricas estatísticas, incluindo acurácia, recall, precisão e F-score, que fornecem uma análise quantitativa da performance do modelo em diferentes aspectos da classificação.

4. RESULTADOS E DISCUSSÃO

Esta seção apresenta e analisa os resultados obtidos a partir da aplicação das arquiteturas de redes neurais profundas — CNN, LSTM e CNN–LSTM — na classificação de diferentes tipos de crises epiléticas, com base em características estatísticas extraídas dos momentos conjuntos da distribuição tempo-frequência de sinais EEG. As representações tempo-frequência foram obtidas por meio da Transformada *Wavelet* Contínua (CWT), utilizando as funções wavelet *Morse*, *Bump* e *Morlet*, escolhidas por suas propriedades analíticas distintas na decomposição de sinais não estacionários.

As análises foram organizadas em três domínios distintos: temporal, espectral e tempo-frequência, permitindo avaliar a eficácia de cada abordagem na extração de padrões relevantes para a tarefa de classificação. Para cada domínio, foram consideradas quatro características estatísticas — média, variância, curtose e assimetria — extraídas das distribuições tempo-frequência, que serviram como entrada para os modelos de aprendizado profundo.

Os resultados são apresentados em tabelas e gráficos comparativos, com avaliação quantitativa baseada nas métricas de acurácia, precisão, recall e F1-score. As discussões abordam o impacto das diferentes *wavelets* sobre o desempenho dos modelos, bem como a contribuição de cada característica estatística para a discriminação entre as classes de crises epiléticas. Por fim, realiza-se uma análise crítica integrando os achados experimentais com as evidências mais recentes da literatura especializada, destacando as implicações e limitações do estudo.

4.1 Análise temporal

Nesta seção, avaliou-se a eficácia das características temporais extraídas de sinais de EEG na classificação das crises epiléticas GNSZ, CPSZ, FNSZ e TCSZ utilizando arquiteturas avançadas de aprendizado profundo: CNN, LSTM e CNN-LSTM. A abordagem metodológica foi fundamentada no cálculo dos Momentos Temporais Condicionais, definidos como parâmetros estatísticos derivados de representações tempo-frequência, os quais permitem modelar a dinâmica temporal de sinais não estacionários. Esses momentos foram calculados com base em restrições específicas relacionadas à frequência, otimizando a extração de padrões temporais relevantes para a discriminação entre as diferentes classes de crises epiléticas.

4.1.1 Análise Temporal utilizando Redes Neurais Convolucionais (CNN)

Os resultados apresentados nas Tabelas 1, 2 e 3 foram obtidos por meio de um modelo de classificação fundamentado em Redes Neurais Convolucionais (CNN). Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos Temporais Condicionais (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas wavelets *Morse*, *Bump* e *Morlet*, visando capturar as dinâmicas temporais em função das frequências dos sinais não estacionários. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, recall e F1-Score.

Tabela 1: Desempenho do modelo CNN aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*.

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	68	67	63	64
Variância	88	86	87	85
Curtose	85	81	80	80
Assimetria	76	75	74	74

Fonte : Autor

Tabela 2 - Desempenho do modelo CNN aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	73	69	65	71
Variância	90	87	88	86
Curtose	87	83	81	84
Assimetria	81	77	78	76

Fonte : Autor

Tabela 3 - Desempenho do modelo CNN aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *Wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	67	65	67	68
Variância	87	82	85	84
Curtose	85	80	79	78
Assimetria	76	69	72	71

Fonte : Autor

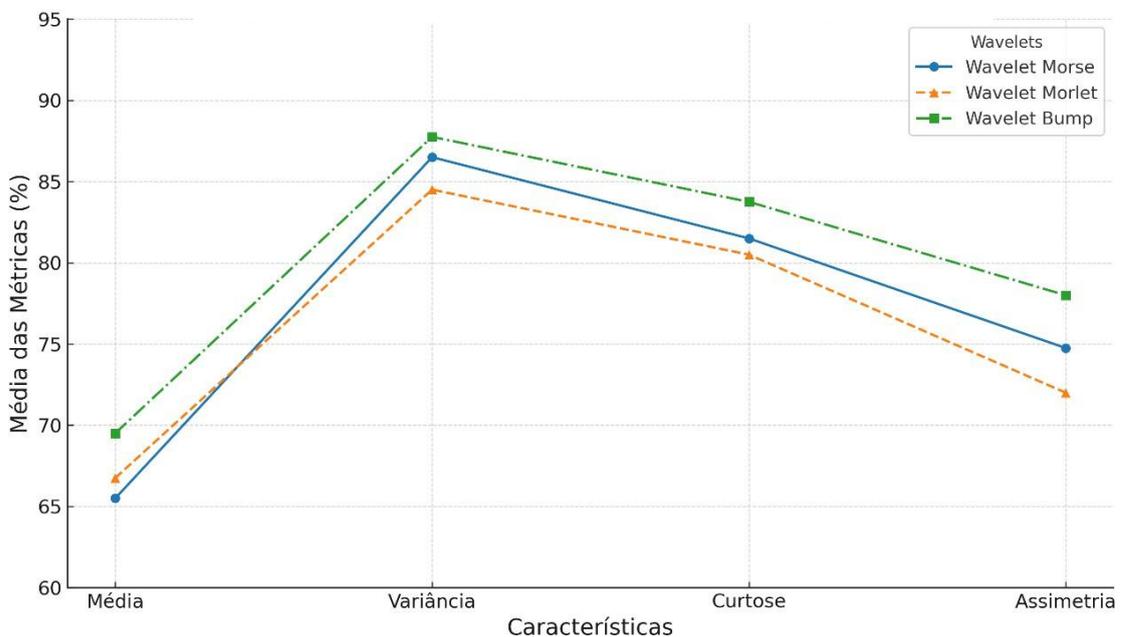
Os resultados demonstram o melhor desempenho da *Wavelet Bump*, apresentada na Tabela 2, em todas as métricas avaliadas, destacando-se particularmente nas características de variância e curtose, que exibiram boa capacidade discriminativa. A *Wavelet Morse* (Tabela 1) apresentou desempenho intermediário, enquanto a *Wavelet Morlet* (Tabela 3) teve os piores resultados, com maior impacto negativo na média e assimetria.

A análise quantitativa revelou que a média foi a característica com menor capacidade discriminativa, independentemente da transformada wavelet empregada. Para essa característica, as *Wavelets Morlet e Morse* alcançaram uma acurácia média de 67%, enquanto a *Wavelet Bump* apresentou um desempenho superior, com acurácia de 73%. Em contraste, a variância destacou -se como a característica mais discriminativa, com a *Wavelet Bump* atingindo uma acurácia de 90%, superando as *Wavelets Morse e Morlet*, que obtiveram 88% e 87%, respectivamente. A curtose também demonstrou elevada relevância, com desempenhos consistentes entre as transformadas, embora a *Wavelet Bump* tenha mantido um desempenho marginalmente superior. A assimetria apresentou discriminação moderada, com acurácia de 81% para a *Wavelet Bump*, enquanto as *Wavelets Morse e Morlet* registraram 76%.

No contexto global das métricas avaliadas, a *Wavelet Bump* mostrou-se a mais robusta e eficaz para a classificação das crises epiléticas, apresentando os melhores desempenhos médios em acurácia, precisão, *recall* e F1-Score. Este último consolidou a *Wavelet Bump* como a transformada mais confiável, destacando sua capacidade de reduzir erros de falso positivo e falso negativo.

O Gráfico 1 corrobora os resultados quantitativos, evidenciando a predominância da *Wavelet Bump*, especialmente na característica de variância, em que seu desempenho foi significativamente superior. Em contrapartida, as *Wavelets Morse* e *Morlet* apresentaram comportamentos mais similares entre si, mas insuficientes para atingir o nível de eficiência observado na *Wavelet Bump*. Esses resultados reforçam o papel central da *Wavelet Bump* como a transformada mais robusta e adequada para a tarefa de classificação analisada, especialmente ao explorar características de alta capacidade discriminativa, como variância e curtose.

Gráfico 01 - Comparação dos Resultados do Modelo CNN com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas Temporais



Fonte : Autor

4.1.2 Análise Temporal utilizando Redes Neurais LSTM

Os resultados apresentados nas Tabelas 4, 5 e 6 foram obtidos por meio de um modelo de classificação baseado em Redes Neurais Recorrentes do tipo LSTM (*Long Short-Term Memory*). Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos Temporais Condicionais (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas *wavelets Morse*, *Bump* e *Morlet*, visando capturar as dinâmicas temporais em função das frequências dos sinais não estacionários. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, *recall* e *F1-Score*.

Tabela 4 - Desempenho do modelo LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	72	70	70	71
Variância	91	89	90	88
Curtose	88	84	83	83
Assimetria	79	78	77	77

Fonte : Autor

Tabela 5 - Desempenho do modelo LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	75	72	70	71
Variância	92	90	90	89
Curtose	90	86	84	85
Assimetria	84	80	78	79

Fonte : Autor

Tabela 6 - Desempenho do modelo LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *Wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	70	68	70	71
Variância	90	85	88	87
Curtose	88	83	82	81
Assimetria	79	72	75	74

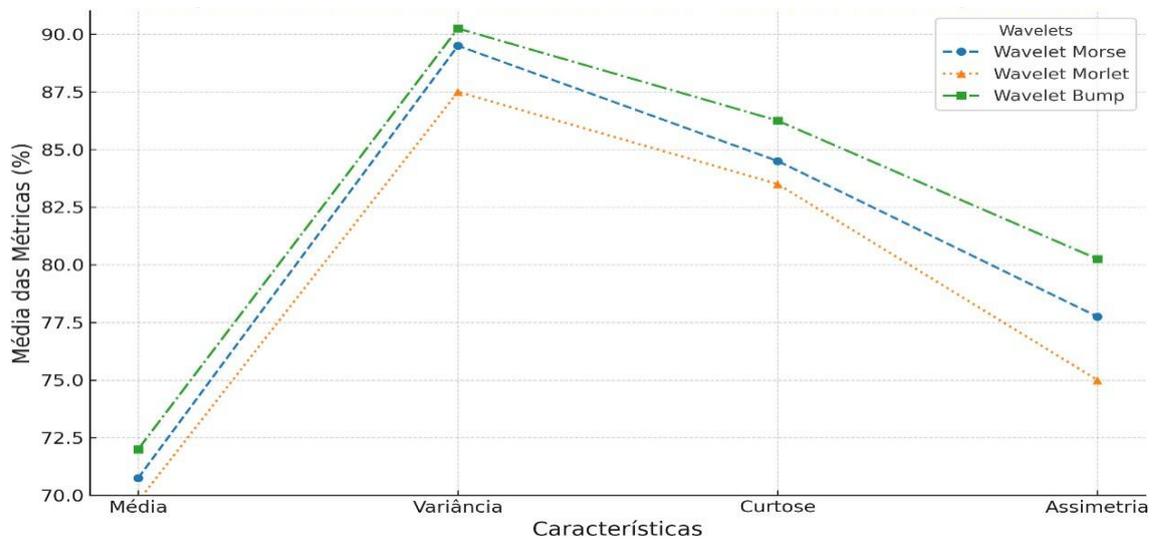
Fonte : Autor

A Wavelet Bump, apresentada na Tabela 5, demonstrou o melhor desempenho global nas métricas avaliadas — acurácia, precisão, recall e F1-Score. Destacou-se especialmente nas características de variância e curtose, indicando sua eficácia na captura de informações relevantes para a classificação. Em comparação, a *Wavelet Morse* (Tabela 4) apresentou desempenho intermediário, enquanto a Wavelet Morlet (Tabela 6) obteve os piores resultados gerais, reforçando suas limitações no contexto analisado.

Entre as características, a média foi a menos discriminativa, com a Wavelet Bump alcançando 75% de acurácia, frente a 70% das *Wavelets Morse* e *Morlet*. Por outro lado, a variância destacou-se como a mais relevante, com a *Wavelet Bump* atingindo 92% de acurácia, seguida de perto pelas *Wavelets Morse* (91%) e *Morlet* (90%). A curtose também apresentou alta capacidade discriminativa, com resultados consistentes entre as transformadas, embora a Wavelet Bump tenha mantido uma leve vantagem. A *Wavelet Bump* consolidou-se como a transformada mais eficaz, demonstrando equilíbrio entre precisão e recall e liderando no F1-Score, que confirmou sua confiabilidade no modelo de classificação. A *Wavelet Morlet* apresentou o desempenho mais fraco, seguida pela Wavelet Morse, ambas inferiores à *Wavelet Bump* em métricas-chave.

O Gráfico 2 resume a comparação das métricas, evidenciando o destaque da *Wavelet Bump*, especialmente nas características de variância e curtose. Em contrapartida, média e assimetria foram menos relevantes, apresentando resultados inferiores em todas as transformadas. Esses achados reforçam a importância de selecionar características altamente discriminativas para melhorar a eficácia e precisão do modelo de classificação aplicado à análise de sinais.

Gráfico 2 - Comparação dos Resultados do Modelo LSTM com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas Temporais



Fonte : Autor

4.1.3 Análise Temporal utilizando a Rede Neural Híbrida CNN-LSTM

Os resultados apresentados nas Tabelas 7, 8 e 9 foram obtidos a partir de um modelo híbrido de classificação, composto por Redes Neurais Convolucionais (CNN) e *Long Short-Term Memory* (LSTM). Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos Temporais Condicionais (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas wavelets *Morse*, *Bump* e *Morlet*, visando capturar as dinâmicas temporais em função das frequências dos sinais não estacionários. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, *recall* e F1-Score.

Tabela 7 - Desempenho do modelo CNN-LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	74	70	71	71
Variância	91	90	90	88
Curtose	89	85	83	83
Assimetria	90	78	78	79

Fonte : Autor

Tabela 8 - Desempenho do modelo CNN-LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	85	75	75	80
Variância	93	90	90	89
Curtose	91	86	84	89
Assimetria	88	85	90	80

Fonte : Autor

Tabela 9 - Desempenho do modelo CNN-LSTM aplicado as características temporais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	71	68	70	71
Variância	90	90	90	90
Curtose	89	83	85	85
Assimetria	80	75	75	75

Fonte : Autor

A *Wavelet Bump*, apresentada na Tabela 8, apresentou o melhor desempenho em todas as métricas avaliadas — acurácia, precisão, recall e F1-Score —, com destaque para as características de variância (93% de acurácia) e curtose (91%). Além disso, demonstrou maior equilíbrio entre precisão e *recall*, consolidando-se como a transformada mais eficaz.

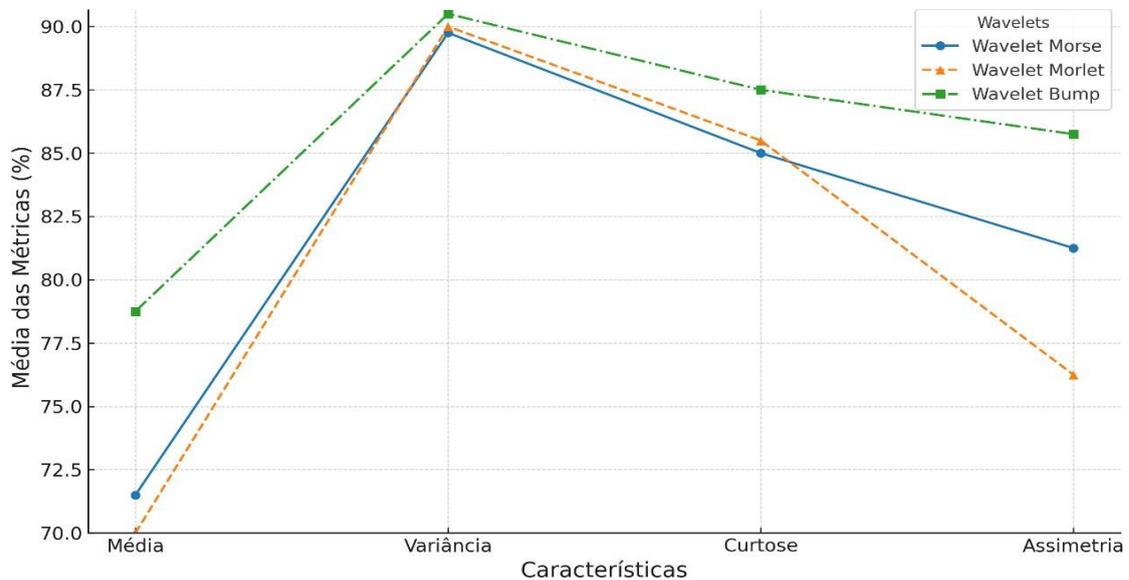
A *Wavelet Morse*, descrita na Tabela 7, obteve desempenho intermediário, com resultados satisfatórios em variância (91%) e assimetria (90%), mas com menor consistência em média e curtose. A *Wavelet Morlet*, analisada na Tabela 9, apresentou os piores resultados gerais, com desempenho limitado em média (71%) e assimetria (80%), destacando limitações no contexto analisado.

Entre as características avaliadas, a média foi a menos discriminativa, evidenciando baixa relevância para a classificação. Em contrapartida, a variância destacou-se como a característica mais relevante, com a *Wavelet Bump* liderando (93%), seguida pelas *Wavelets Morse* (91%) e *Morlet* (90%). A curtose também demonstrou alta capacidade discriminativa, com resultados consistentes entre as transformadas. A assimetria apresentou relevância moderada, com a *Wavelet Bump* obtendo 88% de acurácia e 90% de *recall*.

A *Wavelet Bump* apresentou resultados consistentes e robustos em todas as métricas avaliadas, o que foi corroborado pelo F1-Score. As *Wavelets Morse* e *Morlet* apresentaram maior variação de desempenho em características menos relevantes, como média e assimetria, com a *Morse* mostrando desempenho competitivo, mas menos consistente. A *Morlet* apresentou limitações em características de menor impacto.

O Gráfico 3 ilustra os resultados obtidos, o melhor desempenho da *Wavelet Bump* nas características de variância e curtose, enquanto a *Morse* demonstrou desempenho próximo, porém com menor consistência. A *Wavelet Morlet* obteve o menor desempenho, reforçando a necessidade de selecionar características altamente discriminativas para melhorar o desempenho dos modelos de classificação.

Gráfico 3 - Comparação dos Resultados do Modelo CNN-LSTM com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas Temporais



Fonte : Autor

4.2 Análise Espectral

Nesta seção, avaliou-se a eficácia das características temporais extraídas de sinais de EEG na classificação das crises epiléticas GNSZ, CPSZ, FNSZ e TCSZ utilizando arquiteturas avançadas de aprendizado profundo: CNN, LSTM e CNN-LSTM. A abordagem metodológica foi fundamentada no cálculo dos Momentos Espectrais Condicionais, que são parâmetros estatísticos derivados de distribuições tempo-frequência, os quais variam ao longo do tempo e descrevem as características do espectro do sinal à medida que ele evolui temporalmente. Esses momentos possibilitam uma análise detalhada da distribuição espectral de energia e suas variações dinâmicas, fornecendo uma descrição quantitativa e localizada das propriedades espectrais do sinal em diferentes instantes de tempo.

4.2.1 Análise Espectral utilizando Redes Neurais Convolucionais (CNN)

Os resultados apresentados nas Tabelas 10, 11 e 12 foram obtidos por meio de um modelo de classificação fundamentado em Redes Neurais Convolucionais (CNN). Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos Espectrais Condicionais (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas wavelets *Morse*, *Bump* e *Morlet*, um conjunto de parâmetros variáveis no tempo que caracterizam o espectro do sinal à medida que ele evolui no tempo. O

desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, *recall* e *F1-Score*.

Tabela 10 - Desempenho do modelo CNN aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	80	74	76	75
Variância	92	91	90	90
Curtose	90	90	86	89
Assimetria	85	82	84	85

Fonte : Autor

Tabela 11 - Desempenho do modelo CNN aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *Wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	80	74	76	75
Variância	91	90	90	90
Curtose	90	88	86	89
Assimetria	84	82	84	85

Fonte : Autor

Tabela 12 - Desempenho do modelo CNN aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *Wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	80	78	76	75
Variância	92	92	91	90
Curtose	92	90	89	89
Assimetria	87	86	84	85

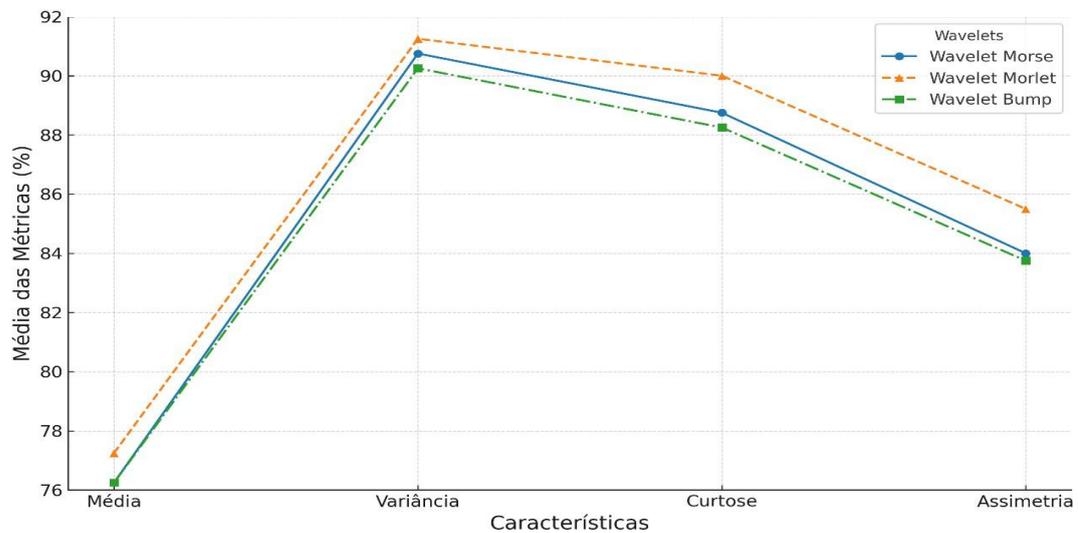
Fonte : Autor

A *Wavelet Morse*, apresentada na Tabela 10, destacou-se nas características de variância (92% de acurácia) e curtose (90% de acurácia), demonstrando alta capacidade discriminativa. A *Wavelet Morlet*, descrita na Tabela 12, mostrou competitividade em variância (92% de acurácia), mas desempenho inferior em média (80% de acurácia). A *Wavelet Bump*, analisada na Tabela 11, apresentou solidez em variância (91%) e curtose (90%), mas revelou limitações em média e assimetria.

A variância foi a característica mais discriminativa, com acurácia acima de 90% em todas as wavelets. A curtose também teve alta relevância, com valores entre 89% e 90%. Em contraste, a média foi a menos discriminativa, com acurácia limitada a 80%. A assimetria obteve resultados intermediários, com melhor desempenho na *Wavelet Morse* (85% de acurácia).

O Gráfico 4 destaca a eficácia da *Wavelet Morse* em variância e curtose, enquanto a *Wavelet Morlet* apresentou maior variabilidade em características menos relevantes, como média. A *Wavelet Bump*, apesar de consistente em variância e curtose, demonstrou menor estabilidade em média e assimetria. Esses resultados enfatizam a importância de características discriminativas, como variância e curtose, e as limitações de características menos impactantes, como média, na construção de modelos mais robustos.

Gráfico 4 - Comparação dos Resultados do Modelo CNN com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas Espectrais



Fonte : Autor

4.2.2 Análise Espectral utilizando Redes Neurais LSTM

Os resultados apresentados nas Tabelas 13, 14 e 15 foram obtidos por meio de um modelo de classificação baseado em *Long Short-Term Memory* (LSTM). Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos Espectrais Condicionais (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas *Wavelets Morse*, *Bump* e *Morlet*, um conjunto de parâmetros variáveis no tempo que caracterizam o espectro do sinal à medida que ele evolui no tempo. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, recall e *F1-Score*.

Tabela 13 - Desempenho do modelo LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	85	79	78	75
Variância	92	91	90	90
Curtose	90	90	86	89
Assimetria	85	82	84	85

Fonte : Autor

Tabela 14 - Desempenho do modelo LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	80	74	76	75
Variância	91	90	90	90
Curtose	90	88	86	89
Assimetria	84	82	84	85

Fonte : Autor

Tabela 15 - Desempenho do modelo LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	88	89	86	85
Variância	93	93	92	90
Curtose	92	90	89	89
Assimetria	87	86	84	85

Fonte : Autor

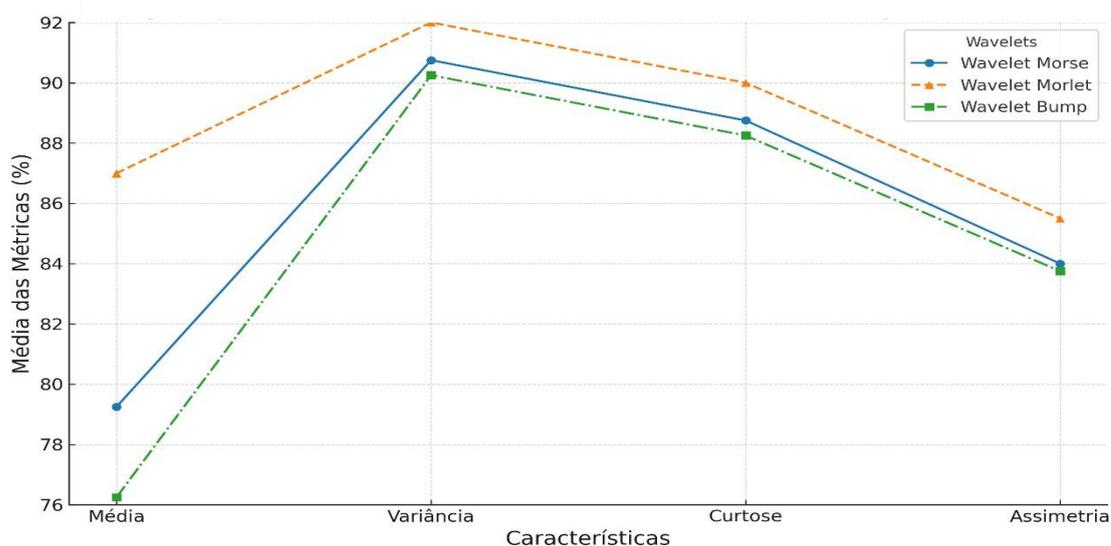
A *Wavelet Morlet*, descrita na Tabela 15, apresentou o melhor desempenho geral, destacando-se nas características de variância (93% de acurácia e *recall*) e curtose (92% de acurácia e 89% de F1-Score). A *Wavelet Morse*, na Tabela 13, obteve resultados competitivos, especialmente em variância (92% de acurácia) e curtose (90% de acurácia), com equilíbrio consistente entre precisão e recall. A *Wavelet Bump*, apresentada na Tabela 14, mostrou desempenho sólido em variância (91% de acurácia) e curtose (90% de acurácia), mas teve limitações em média (80% de acurácia) e assimetria (84% de acurácia).

A média foi a característica menos discriminativa em todas as transformadas. A *Wavelet Morlet* liderou com 88% de acurácia e 85% de F1-Score, seguida pela *Morse* (85% de acurácia) e pela *Bump* (80% de acurácia). Em contraste, a variância foi a característica mais relevante,

com a *Wavelet Morlet* atingindo 93% de acurácia, seguida pela *Morse* (92%) e pela *Bump* (91%). A curtose também teve alto desempenho, com a *Morlet* alcançando 92% de acurácia, enquanto *Morse* e *Bump* obtiveram 90%. A assimetria apresentou relevância intermediária, com a *Morlet* registrando 87% de acurácia e um F1-Score de 85%, ligeiramente superior à *Morse* (85% de acurácia) e à *Bump* (84%).

O Gráfico 5 resume os resultados, destacando o desempenho superior da *Wavelet Morlet* em variância e curtose. A *Morse* mostrou-se consistente em todas as métricas, enquanto a *Bump*, embora forte em variância e curtose, apresentou resultados inferiores em média e assimetria. O gráfico detalha a distribuição das métricas, reforçando a eficácia da *Morlet* em características altamente discriminativas e a competitividade das outras wavelets.

Gráfico 05 - Comparação dos Resultados do Modelo LSTM com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas espectrais



Fonte : Autor

4.2.3 Análise Espectral utilizando a Rede Neural Híbrida CNN-LSTM

Os resultados apresentados nas Tabelas 16, 17 e 18 foram obtidos por meio de um modelo híbrido de classificação baseado em CNN-LSTM. Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos Espectrais Condicionais (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas *wavelets Morse*, *Bump* e *Morlet*, um conjunto de parâmetros variáveis no tempo que caracterizam o espectro do sinal à medida que ele evolui no tempo. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, recall e F1-Score.

Tabela 16 - Desempenho do modelo CNN-LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	87	85	86	85
Variância	93	91	90	91
Curtose	90	90	90	90
Assimetria	89	87	88	88

Fonte : Autor

Tabela 17 - Desempenho do modelo CNN-LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	85	84	86	85
Variância	94	90	90	90
Curtose	92	88	86	89
Assimetria	88	89	88	85

Fonte : Autor

Tabela 18 - Desempenho do modelo CNN-LSTM aplicado as características espectrais condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	89	78	76	75
Variância	95	93	92	90
Curtose	93	90	89	90
Assimetria	87	86	85	86

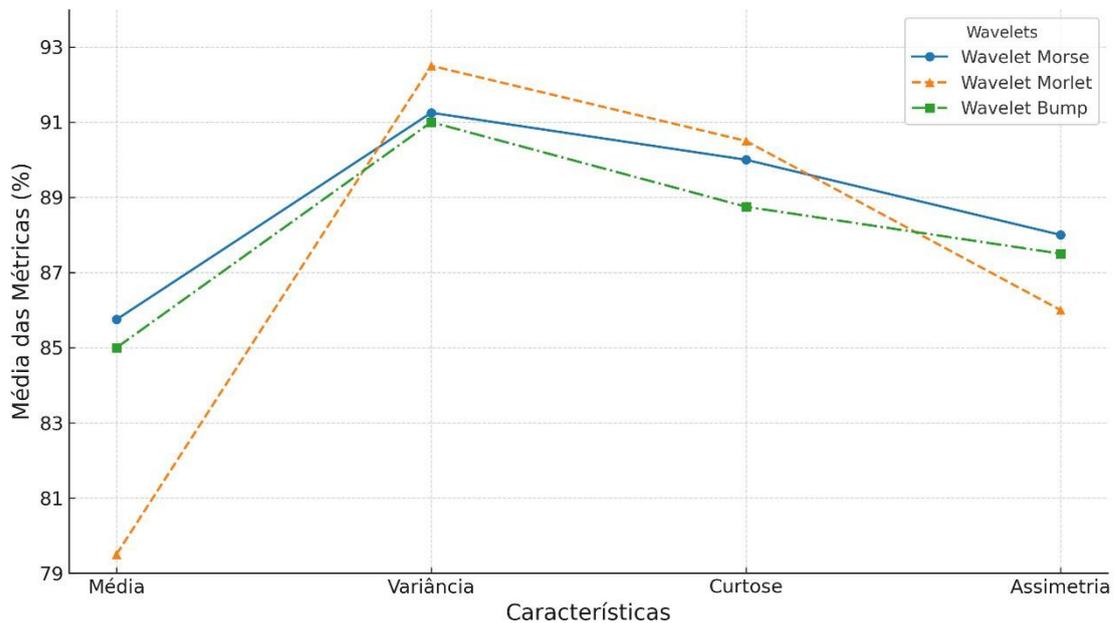
Fonte : Autor

A *Wavelet Morlet*, apresentada na Tabela 18, destacou-se como a transformada com melhor desempenho geral, particularmente nas características de variância (95% de acurácia e *recall*) e curtose (93% de acurácia e F1-Score de 89%). A *Wavelet Morse*, Tabela 16, mostrou resultados consistentes, liderando em assimetria (89% de acurácia e F1-Score) e apresentando desempenho competitivo em variância (93% de acurácia). A *Wavelet Bump*, Tabela 17, demonstrou solidez em variância (94% de acurácia) e curtose (92% de acurácia), mas teve desempenho inferior em características menos discriminativas, como média e assimetria, limitando sua eficácia global. Esses resultados refletem diferenças na capacidade discriminativa das transformadas, com a *Wavelet Morlet* se destacando no contexto analisado.

A média foi a característica menos discriminativa, com acurácias variando de 85% (*Wavelet Bump*) a 89% (*Wavelet Morlet*), e o F1-Score mais baixo observado para a *Morlet* (75%), indicando menor equilíbrio entre precisão e recall nessa característica. Por outro lado, a variância emergiu como a mais relevante, com a *Wavelet Morlet* liderando (95% de acurácia e 90% de F1-Score), seguida pela *Wavelet Bump* (94%) e pela *Wavelet Morse* (93%). A curtose também apresentou alto desempenho, com a *Wavelet Morlet* alcançando 93% de acurácia e 89% de F1-Score, enquanto *Morse* e *Bump* mantiveram resultados próximos (90% e 92%, respectivamente). A assimetria teve relevância intermediária, com a *Wavelet Morse* obtendo o melhor desempenho (89% de acurácia e F1-Score), seguida pelas *Wavelets Morlet* e *Bump*, que tiveram resultados competitivos, mas inferiores.

O Gráfico 6 resume os resultados, destacando o domínio da *Wavelet Morlet* em variância e curtose. A *Wavelet Morse* demonstrou consistência, com destaque em assimetria, enquanto a *Wavelet Bump*, apesar de sua robustez em características principais, apresentou limitações em média. Esses achados ressaltam a importância de alinhar a escolha das transformadas wavelet às características mais relevantes para o problema, maximizando o desempenho do modelo.

Gráfico 06 - Comparação dos Resultados do Modelo CNN com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas Espectrais



Fonte : Autor

4.3 Análise conjunta tempo-frequência

Nesta seção, avaliou-se a eficácia das características temporais extraídas de sinais de EEG na classificação de crises epilépticas (GNSZ, CPSZ, FNSZ e TCSZ) utilizando as arquiteturas de aprendizado profundo CNN, LSTM e CNN-LSTM. A metodologia baseou-se no cálculo dos Momentos Conjuntos da distribuição tempo-frequência, parâmetros estatísticos que descrevem a distribuição energética do sinal ao longo do tempo e frequência. Essa abordagem permitiu capturar a interdependência entre dimensões temporais e espectrais, fornecendo uma análise detalhada da dinâmica dos sinais não estacionários.

4.3.1 Análise Conjunta Tempo-Frequência utilizando Modelo CNN

Os resultados apresentados nas Tabelas 19, 20 e 21 foram obtidos por meio de um modelo de classificação fundamentado em Redes Neurais Convolucionais (CNN). Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos conjuntos (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas wavelets *Morse*, *Bump* e *Morlet*, visando capturar as dinâmicas temporais e espectrais conjuntas dos sinais não estacionários. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, recall e F1-Score.

Tabela 19 - Desempenho do modelo CNN aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	85	83	82	84
Variância	95	94	95	95
Curtose	94	93	94	94
Assimetria	93	91	91	90

Fonte : Autor

Tabela 20 - Desempenho do modelo CNN aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	81	74	76	75
Variância	92	91	90	90
Curtose	90	90	86	89
Assimetria	85	82	84	85

Fonte : Autor

Tabela 21 - Desempenho do modelo CNN aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	84	83	82	84
Variância	94	93	94	94
Curtose	94	92	94	93
Assimetria	90	91	91	90

Fonte : Autor

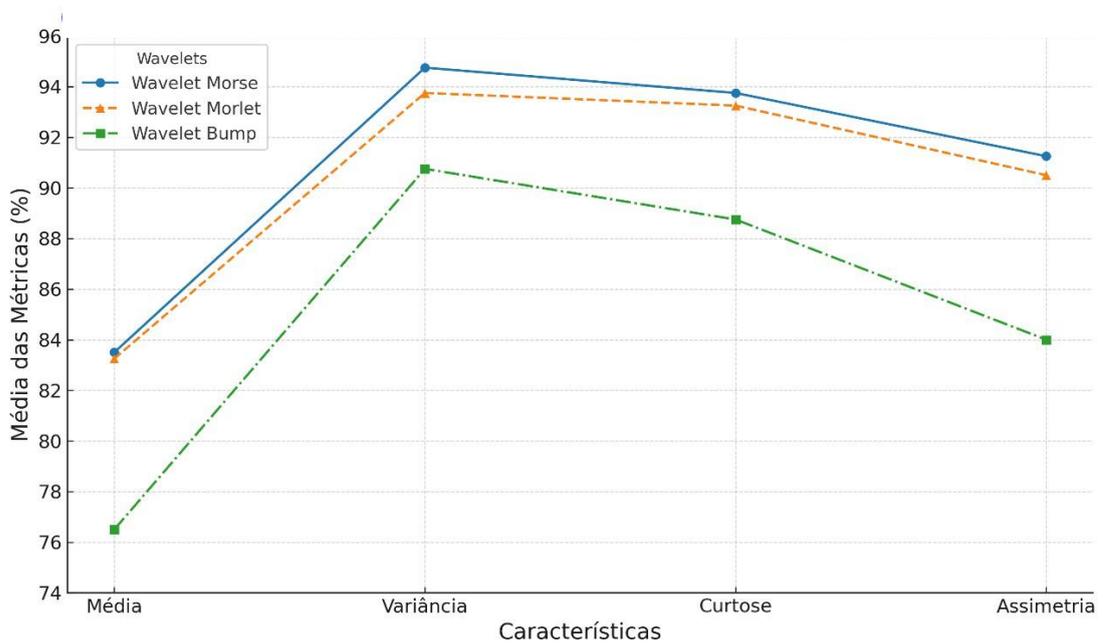
A função *wavelet Morse*, apresentada na Tabela 19, destacou-se como a mais eficaz no desempenho geral, especialmente nas características de variância (95% de acurácia e F1-Score) e curtose (94% de acurácia e F1-Score), além de demonstrar consistência em assimetria (93% de acurácia). A função *wavelet Morlet*, descrita na Tabela 21, apresentou resultados competitivos, com destaque em variância (94% de acurácia) e assimetria (90% de acurácia e F1-Score). Em contraste, a *wavelet Bump*, analisada na Tabela 20, obteve bom desempenho em variância (92% de acurácia) e curtose (90%), mas apresentou limitações nas características de média (81% de acurácia e 75% de F1-Score) e assimetria (85% de acurácia). Esses resultados evidenciam diferenças significativas na capacidade discriminativa das funções *wavelet*, com a *Morse* consolidando-se como a mais eficaz no contexto analisado.

A característica de média foi a menos discriminativa entre todas as funções *wavelet* avaliadas. As funções *Morse* e *Morlet* apresentaram acurácias semelhantes (85% e 84%, respectivamente), enquanto a *Bump* exibiu o pior desempenho (81% de acurácia e 75% de F1-Score). Em contrapartida, a variância emergiu como a característica mais relevante para a classificação, com a *Morse* liderando (95% de acurácia e F1-Score), seguida pela *Morlet* (94% de acurácia) e pela *Bump* (92%). A curtose também demonstrou elevada capacidade discriminativa, com a *Morse* atingindo o melhor desempenho (94% de acurácia e F1-Score), enquanto a *Morlet* e a *Bump* apresentaram acurácias de 93% e 90%, respectivamente. Por fim, a assimetria apresentou resultados intermediários, com a *Morse* alcançando os melhores valores (93% de acurácia e F1-Score), seguida pela *Morlet* (90%) e pela *Bump* (85%).

O Gráfico 7 sintetiza os valores médios das métricas, reforça a superioridade da função *wavelet Morse* nas características de variância e curtose, enquanto a *Morlet* mostrou-se competitiva, especialmente em variância e assimetria. A função *Bump*, embora consistente em variância e curtose, apresentou limitações notáveis em características menos discriminativas, como média e assimetria. A análise comparativa evidencia o equilíbrio geral da *Morse*, que alcançou o melhor desempenho em características altamente relevantes, enquanto a *Morlet* demonstrou maior estabilidade em assimetria. A *Bump*, por sua vez, exibiu maior variabilidade, especialmente em características de menor impacto.

Esses resultados destacam a importância das características variância e curtose como métricas-chave para a eficácia do modelo de classificação. Em contrapartida, média e assimetria mostraram-se mais suscetíveis à variabilidade entre as transformadas *wavelet*, reforçando sua menor contribuição para a tarefa de classificação no contexto avaliado.

Gráfico 07 - Comparação dos Resultados do Modelo CNN com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas conjuntas



Fonte : Autor

4.3.2 Análise Tempo-Frequência utilizando Modelo LSTM

Os resultados apresentados nas Tabelas 22, 23 e 24 foram obtidos por meio de um modelo de classificação fundamentado LSTM. Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos conjuntos (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas wavelets *Morse*, *Bump* e *Morlet*, visando capturar as dinâmicas temporais e espectrais conjuntas dos sinais não estacionários. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, recall e F1-Score.

Tabela 22- Desempenho do modelo LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	90	85	88	87
Variância	96	96	96	95
Curtose	94	94	94	94
Assimetria	93	91	92	90

Fonte : Autor

Tabela 23 - Desempenho do modelo LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	90	74	76	75
Variância	93	91	90	90
Curtose	90	90	86	89
Assimetria	91	90	89	89

Fonte : Autor

Tabela 24 - Desempenho do modelo LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morlet*

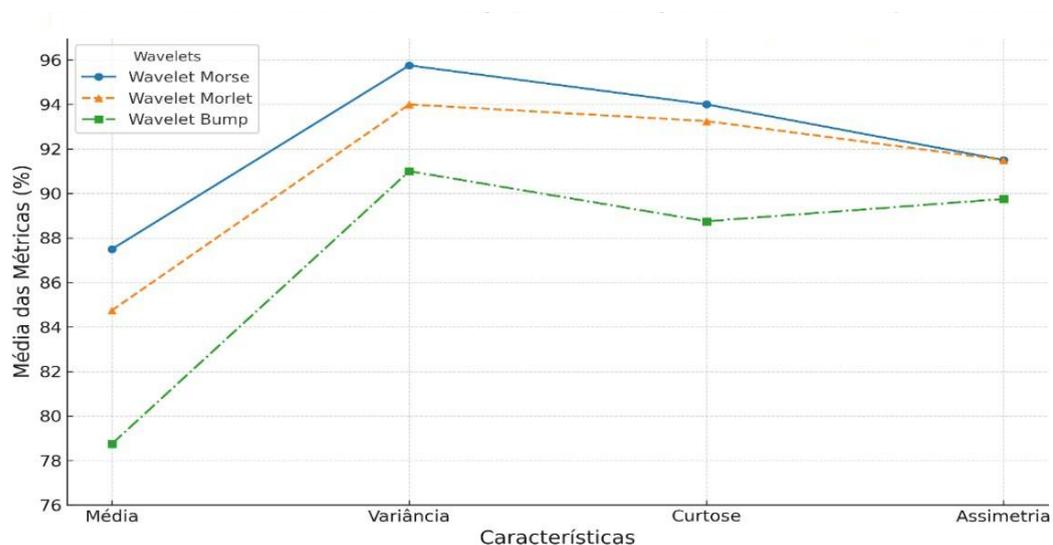
Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	90	83	82	84
Variância	95	93	94	94
Curtose	94	92	94	93
Assimetria	94	91	91	90

Fonte : Autor

A *Wavelet Morse* (Tabela 22) destacou-se como a mais eficaz, especialmente nas características de variância (96% de acurácia e F1-Score) e curtose (94% de acurácia e F1-Score), além de apresentar bom desempenho em assimetria (93% de acurácia e 90% de F1-Score). A *Wavelet Morlet* (Tabela 24) obteve resultados competitivos em variância (95% de acurácia e 94% de F1-Score) e curtose (94% de acurácia e 93% de F1-Score), mas apresentou limitações em média (84% de F1-Score). A *Wavelet Bump* (Tabela 23) mostrou desempenho robusto em variância (93% de acurácia) e curtose (90%), mas revelou fraquezas em média (75% de F1-Score) e assimetria (89% de F1-Score), o que comprometeu seu desempenho global. Entre as características avaliadas, a média foi a menos discriminativa, com a *Wavelet Bump* apresentando o pior desempenho (75% de F1-Score). Em contraste, a variância destacou-se como a mais relevante, com a *Wavelet Morse* liderando (96% de acurácia e F1-Score), seguida pela *Morlet* (95% de acurácia) e pela *Bump* (93%). A curtose também apresentou alta capacidade discriminativa, com as *Wavelets Morse e Morlet* alcançando 94% de acurácia, enquanto a *Bump* ficou ligeiramente atrás, com 90%. A assimetria teve desempenho intermediário, com a *Morse* liderando (93% de acurácia e 90% de F1-Score).

O Gráfico 8 evidencia a superioridade da *Wavelet Morse* em variância e curtose, enquanto a *Morlet* mostrou-se competitiva, mas com menor desempenho em média. A *Bump*, embora eficiente em variância, apresentou limitações significativas em média e assimetria, afetando seu desempenho geral. Esses resultados reforçam a importância de características como variância e curtose na classificação de sinais de EEG, enquanto média e assimetria mostraram menor relevância no contexto analisado.

Gráfico 08 - Comparação dos Resultados do Modelo CNN com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas conjuntas



Fonte : Autor

4.3.3. Análise Tempo-Frequência utilizando o Modelo CNN-LSTM

Os resultados apresentados nas Tabelas 25, 26 e 27 foram obtidos por meio de um modelo de classificação fundamentado CNN-LSTM. Este modelo foi treinado utilizando um conjunto de características estatísticas derivadas dos Momentos conjuntos (média, variância, curtose e assimetria), extraídas a partir das distribuições tempo-frequência dos segmentos de sinais de EEG. As distribuições foram geradas por transformadas wavelets Morse, Bump e Morlet, visando capturar as dinâmicas temporais e espectrais conjuntas dos sinais não estacionários. O desempenho do modelo foi avaliado com base em métricas de classificação, incluindo acurácia, precisão, recall e F1-Score.

Tabela 25 - Desempenho do modelo CNN-LSTM aplicado as conjuntas condicionais extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morse*

Wavelet Morse				
Características	Acurácia	Precisão	Recall	F1-Score
Média	90	85	88	87
Variância	98	96	97	96
Curtose	95	95	96	96
Assimetria	94	93	92	92

Fonte : Autor

Tabela 26 - Desempenho do modelo CNN-LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Bump*

Wavelet Bump				
Características	Acurácia	Precisão	Recall	F1-Score
Média	90	74	76	75
Variância	94	93	92	90
Curtose	90	90	86	89
Assimetria	91	90	89	89

Fonte : Autor

Tabela 27 - Desempenho do modelo CNN-LSTM aplicado as características conjuntas extraídas dos espectrogramas tempo-frequência dos sinais de EEG, utilizando transformadas *wavelet Morlet*

Wavelet Morlet				
Características	Acurácia	Precisão	Recall	F1-Score
Média	90	83	82	84
Variância	96	94	94	94
Curtose	94	92	94	93
Assimetria	94	91	91	90

Fonte : Autor

A *Wavelet Morse* (Tabela 25) demonstrou o desempenho mais robusto no domínio tempo-frequência, destacando-se em variância (96% de acurácia, precisão, recall e F1-Score) e em curtose (95% de acurácia e F1-Score). Em assimetria, também apresentou consistência, alcançando 94% de acurácia e 92% de F1-Score, consolidando-se como a transformada mais eficaz no modelo CNN-LSTM.

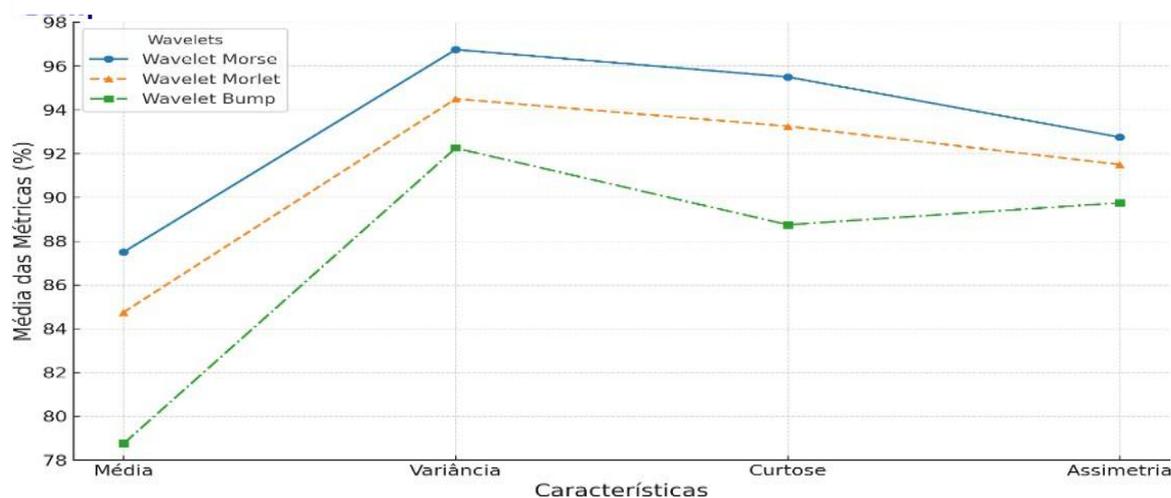
A *Wavelet Morlet* (Tabela 27) apresentou desempenho competitivo, especialmente em variância (96% de acurácia e 94% de F1-Score) e curtose (94% de acurácia e 93% de F1-Score). Em assimetria, obteve 94% de acurácia e F1-Score, mas mostrou limitações em média, com F1-Score de 84%.

A *Wavelet Bump* (Tabela 26), embora eficiente em variância (94% de acurácia e 90% de F1-Score), apresentou maior variabilidade em outras características. Em média, obteve 90% de acurácia, mas com F1-Score reduzido (75%) devido à baixa precisão. Para curtose e assimetria, os resultados foram moderados, com acurácias de 90% e 91% e F1-Scores de 89%. Entre as características avaliadas, a média foi a menos discriminativa, com a *Bump* apresentando o pior desempenho (75% de F1-Score), enquanto *Morse* e *Morlet* alcançaram 90% de acurácia, com a *Morlet* exibindo um F1-Score inferior. A variância destacou-se como a mais relevante, com a *Morse* liderando (96% de acurácia e F1-Score), seguida pela *Morlet* (94% de F1-Score) e pela *Bump* (90%). A curtose demonstrou consistência, enquanto a assimetria posicionou a *Morse* como a mais robusta (94% de acurácia e 92% de F1-Score).

O Gráfico 09 confirma a liderança da *Morse* em variância e curtose, com resultados consistentes. A *Morlet* apresentou competitividade, mas limitações em média, enquanto a *Bump*, apesar de eficaz em variância, mostrou desempenho inferior em média e assimetria, comprometendo seu resultado global. Esses achados ressaltam a importância de características

como variância e curtose na classificação de sinais de EEG e a necessidade de selecionar transformadas wavelet adequadas para otimizar o desempenho do modelo CNN-LSTM.

Gráfico 09 - Comparação dos Resultados do Modelo CNN com Transformadas *Wavelet* com Base nas Médias das Características Estatísticas conjuntas



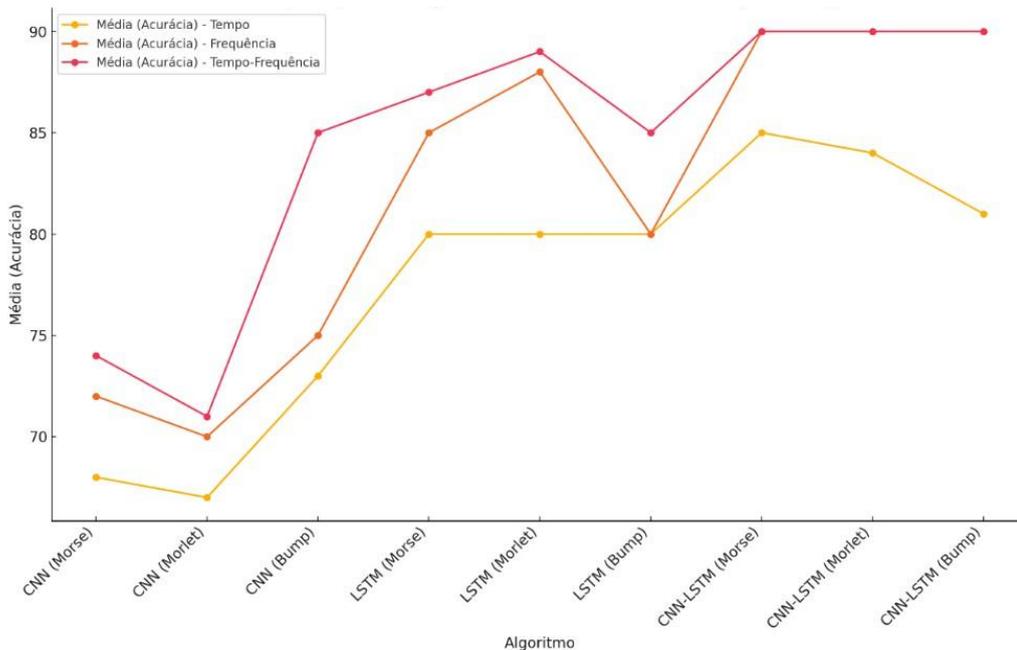
Fonte : Autor

4.4 Análise Comparativa das Abordagens no Domínio do Tempo, Frequência e Tempo-Frequência

Conforme discutido nas seções anteriores, a *Wavelet Bump* demonstrou eficácia na classificação dos tipos de epilepsia na análise temporal condicional, evidenciando sua capacidade de capturar transições e variações locais com boa resolução temporal. Na análise espectral condicional, a *Wavelet Morlet* destacou-se pela precisão na identificação de componentes espectrais, enquanto, na análise tempo-frequência, a *Wavelet Morse* mostrou-se eficaz devido à sua adaptabilidade na resolução conjunta dos domínios temporal e espectral. As métricas de variância e curtose foram fundamentais para caracterizar a distribuição de energia nos diferentes domínios.

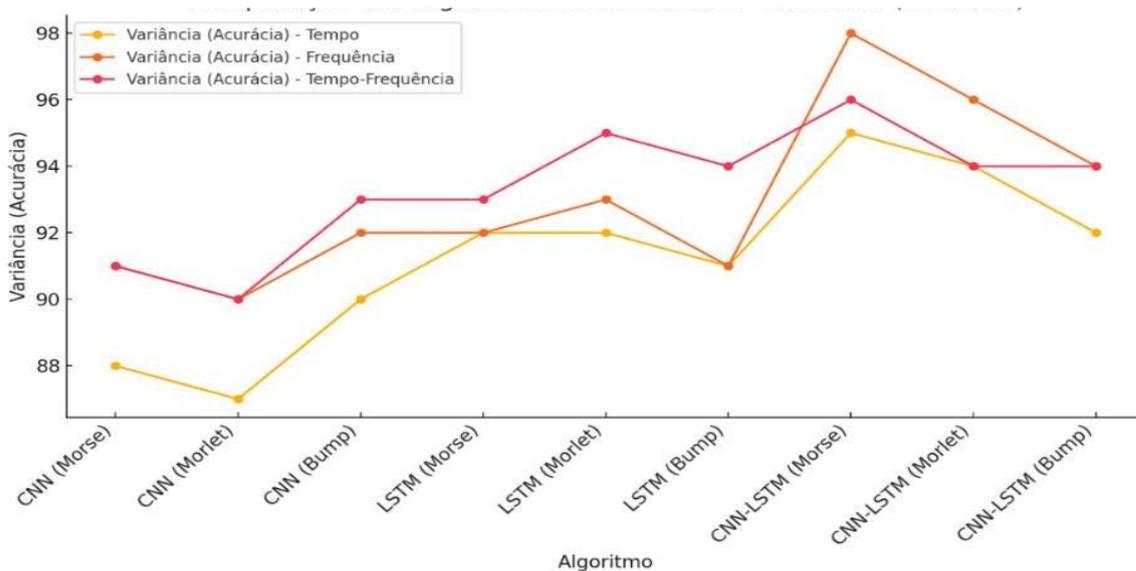
Como mostrado nos Gráficos 7 a 10, o CNN-LSTM, combinado com a *Wavelet Morse*, apresentou o melhor desempenho em todas as métricas avaliadas, incluindo acurácia, média, variância, curtose e assimetria, com destaque para o domínio tempo-frequência. Esses resultados evidenciam a eficácia da arquitetura CNN-LSTM em lidar com dados de alta dimensionalidade e complexidade, aproveitando a capacidade da CNN para extrair características locais e da LSTM para modelar dependências temporais. A *Wavelet Morse* foi determinante nesse contexto, fornecendo uma representação robusta e flexível de escalas e frequências variadas, contribuindo significativamente para a identificação de padrões relevantes no sinal.

Gráfico 10 - Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da media.



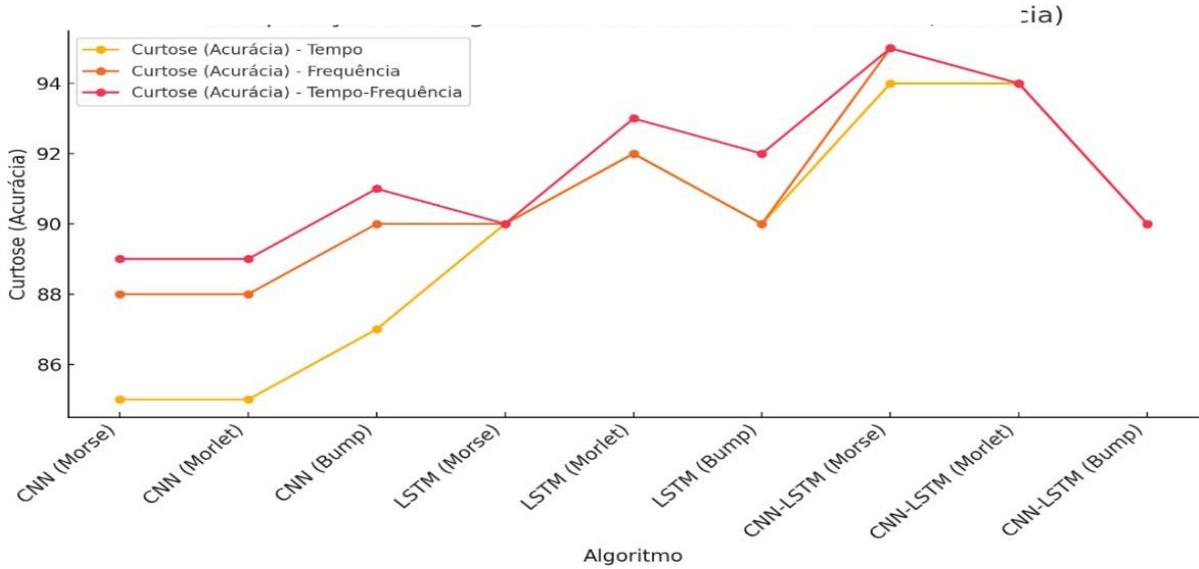
Fonte : Autor

Gráfico 11 - Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da variância.



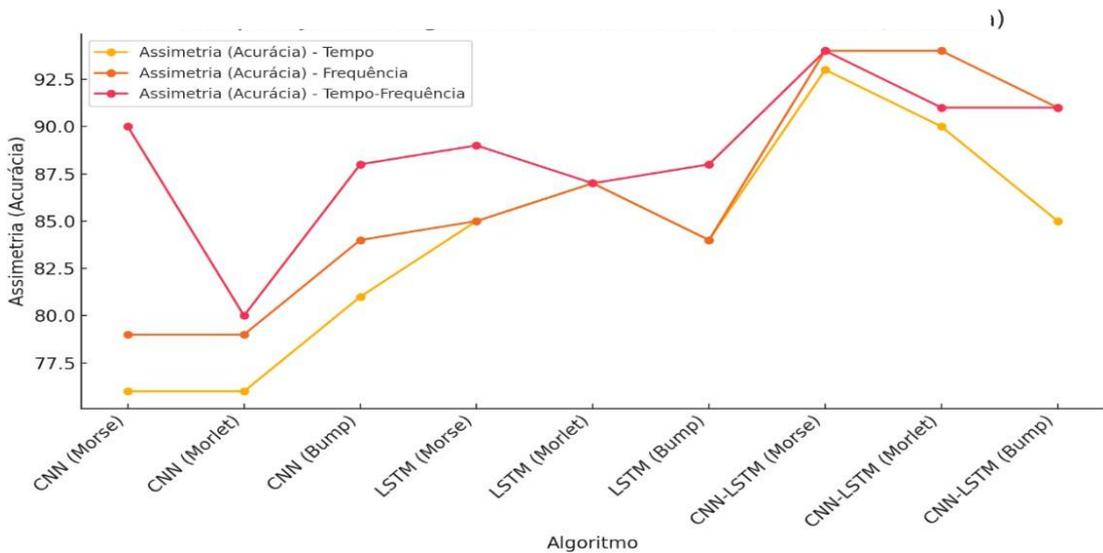
Fonte : Autor

Gráfico 12 - Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da curtose.



Fonte : Autor

Gráfico 13 - Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência em função da acurácia da assimetria.

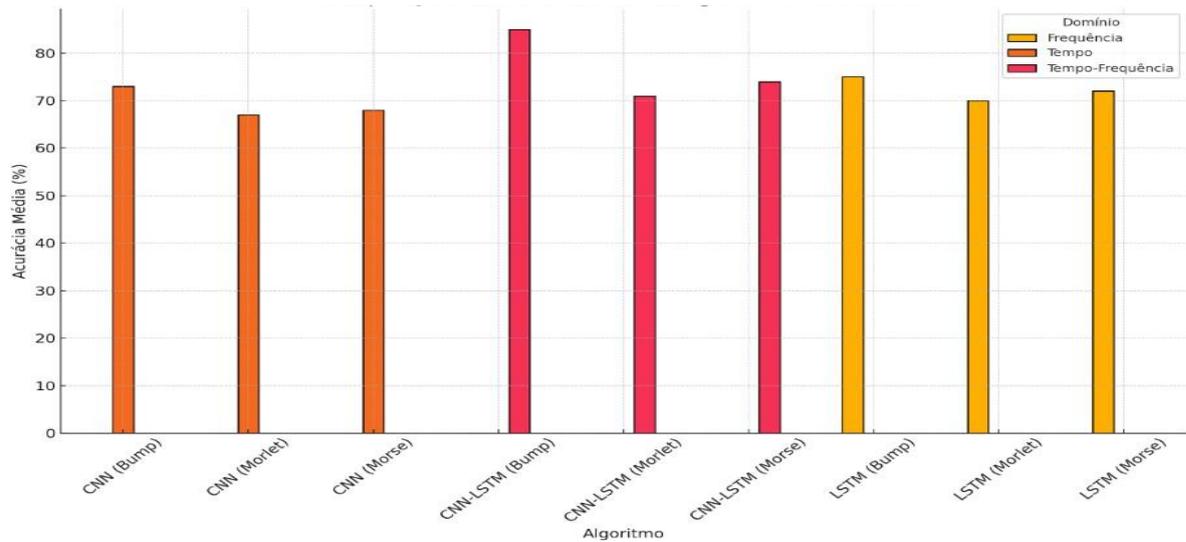


Fonte : Autor

O modelo baseado exclusivamente em LSTM também apresentaram desempenho competitivo, especialmente no domínio Frequência, onde a acurácia foi mais elevada em comparação com o domínio Tempo. Isso sugere que o LSTM é particularmente eficaz na captura de padrões espectrais em sinais complexos. Por outro lado, o algoritmo baseado exclusivamente em CNN apresentou desempenho inferior quando comparados às combinações com LSTM. Esse fato pode ser atribuído à limitação das redes CNN em modelar dependências

temporais de longo alcance, particularmente em sinais com forte componente dinâmico. Como apresentado no Gráfico 13, o domínio Tempo-Frequência demonstrou ser o mais informativo, com os melhores resultados de acurácia em todas as métricas. Este resultado sugere que a representação conjunta das informações temporais e espectrais oferece uma descrição mais completa dos sinais analisados, permitindo a identificação de padrões mais discriminativos.

Gráfico 14 - Comparação de Desempenho dos Algoritmos nos Domínios de Tempo, Frequência e Tempo-Frequência



Fonte : Autor

O domínio Frequência também apresentou resultados sólidos, especialmente nas métricas de variância e curtose, indicando que as informações espectrais são cruciais para a tarefa. No entanto, o domínio Tempo apresentou desempenho inferior em comparação aos outros domínios, possivelmente devido à ausência de informações espectrais essenciais para distinguir os padrões complexos dos dados. Entre as wavelets avaliadas, a *Morse* apresentou os melhores resultados em todos os algoritmos e domínios. Isso sugere que a wavelet Morse é mais adequada para capturar as características relevantes dos sinais analisados, possivelmente devido à sua flexibilidade em modelar sinais com diferentes escalas e frequências.

Esses resultados evidenciam que a escolha do domínio e do algoritmo de classificação é crucial para o desempenho da tarefa. A combinação do domínio Tempo-Frequência, aliado ao algoritmo CNN-LSTM e à wavelet Morse, representa a abordagem promissora para discriminação dos padrões e classificação das crises epiléticas.

4.5 Análise dos Resultados Obtidos

Esta seção apresenta uma análise dos principais achados do estudo, em sintonia com o objetivo central da pesquisa: avaliar, de forma quantitativa, o desempenho da classificação de crises epiléticas a partir de características estatísticas extraídas da distribuição tempo-frequência de sinais EEG, utilizando a transformada wavelet contínua e redes neurais profundas. Em seguida, são discutidos a relevância dos resultados obtidos, os aspectos das transformadas wavelet analisadas, as contribuições das arquiteturas neurais empregadas, além das limitações identificadas ao longo do trabalho.

4.5.1 Relevância dos Achados

Os resultados deste estudo confirmam que a combinação entre a representação tempo-frequência, a transformada wavelet contínua Morse e a arquitetura híbrida CNN-LSTM constitui uma abordagem eficaz para a classificação de crises epiléticas com base em sinais EEG. Essa configuração obteve acurácias superiores a 95% ao utilizar características como variância e curtose, além de apresentar desempenho consistente em métricas como precisão, sensibilidade e *F1-Score*. Tais resultados evidenciam o potencial da análise tempo-frequência na modelagem de sinais EEG, que são intrinsecamente não estacionários.

Esses achados estão em sintonia com estudos recentes da literatura. Hassan et al. (2024) desenvolveram o modelo *Neuro Wave Net*, que combina CNN e LSTM, atingindo 99,48% de acurácia na classificação de sinais epiléticos. De forma semelhante, Cao et al. (2025) propuseram uma arquitetura CNN-BiLSTM associada à transformada wavelet discreta (DWT), validada em três bases públicas (*Bonn*, *CHB-MIT* e *New Delhi*), alcançando 100% de acurácia em classificações binárias e 98% em tarefas multiclases. Torkey et al. (2025), por sua vez, apresentaram um modelo híbrido com CNN, LSTM e GRU, incorporando mecanismos de explicabilidade via SHAP, e atingiram 99,1% de acurácia na detecção de crises.

A wavelet Morse tem se destacado como uma das funções mais eficazes na análise tempo-frequência, superando outras opções contínuas. Roy e Islam (2020) utilizaram essa *wavelet* para gerar scalogramas e treinar uma CNN baseada na *AlexNet*, alcançando acurácias entre 97,5% e 100% em classificações binárias, e entre 95,8% e 100% em tarefas multiclases. Estudos comparativos posteriores confirmaram a superioridade da Morse frente a funções como *Morlet*, *Bump* e *db4*, especialmente na detecção de crises epiléticas. Diykh et al. (2022), por exemplo, apresentaram a arquitetura *Parallel Ictal Net*, que utilizou scalogramas com *wavelet*

Morse integrados a redes convolucionais paralelas com atenção aos canais, atingindo métricas próximas de 99% em todas as avaliações.

Assim, os resultados aqui apresentados não apenas corroboram o estado da arte, como também o ampliam ao integrar momentos estatísticos, transformadas wavelet contínuas e redes neurais profundas. Essa integração representa uma contribuição relevante para o desenvolvimento de sistemas inteligentes voltados ao diagnóstico da epilepsia.

4.5.2 Desempenho das Transformadas *Wavelet*

A análise dos resultados evidencia que o desempenho das diferentes transformadas wavelet está intimamente relacionado às suas propriedades analíticas, em especial à resolução tempo-frequência e à capacidade de representar sinais não estacionários, como os provenientes da atividade eletroencefalográfica (EEG). Nesse contexto, a *wavelet* contínua *Morse* tem se destacado pela eficácia na classificação de crises epiléticas, sobretudo quando aplicada à representação tempo-frequência. Seu desempenho decorre da flexibilidade paramétrica, que permite ajustes independentes nas resoluções temporal e espectral, tornando-a altamente adaptável à dinâmica dos sinais EEG.

Roy e Islam (2020) demonstraram que scalogramas baseados na *wavelet Morse*, quando utilizados com redes convolucionais como a *AlexNet*, alcançaram acurácias superiores a 97,5% na detecção de padrões epiléticos. Estudos mais recentes também apontam a superioridade da *Morse* em relação a outras funções mãe, como Amor (*Analytic Morse-like Oscillatory Wavelet*) e *Bump*, na geração de representações mais discriminativas para classificação por redes neurais (Yu et al., 2021).

As *wavelets Morse*, em particular, têm se consolidado como ferramentas analíticas eficazes para a decomposição de sinais EEG. Segundo Martinez-Ríos et al. (2023), sua estrutura paramétrica flexível e alta concentração no domínio tempo-frequência as torna especialmente úteis na captura de dinâmicas multiescalares e padrões transitórios, como picos e descargas ictais. Lilly e Olhede (2012) reforçam essa vantagem ao demonstrar que, com parametrizações adequadas, essas wavelets superam funções tradicionais, como a *Morlet*, especialmente em termos de localização temporal — aspecto essencial para representar componentes espectrais de rápida variação. Lilly (2017) complementa essa perspectiva ao mostrar que a análise baseada nas *wavelets Morse* facilita a detecção e quantificação de eventos isolados e transientes em séries temporais ruidosas, como ocorre nos sinais EEG utilizados na detecção de epilepsia.

Essas evidências consolidam as *Wavelets Morse* como uma das abordagens mais eficazes para análise tempo-frequência em contextos biomédicos, especialmente pela capacidade de representar padrões não estacionários e eventos críticos em sinais EEG.

No entanto, outras wavelets também apresentam desempenhos relevantes, dependendo do tipo de análise. A *wavelet Bump*, por exemplo, tem se mostrado eficaz na extração de características temporais, particularmente em contextos que exigem alta sensibilidade à detecção de eventos abruptos e localizados, como descargas epileptiformes de curta duração. Essa eficiência decorre de sua elevada concentração espectral e suporte compacto, que favorecem a representação precisa de transientes.

Por outro lado, a *wavelet Morlet* se destaca nas análises espectrais, devido à sua estrutura baseada na modulação de uma gaussiana por uma função senoidal. Essa característica proporciona excelente resolução em frequência, sendo particularmente útil na identificação de padrões periódicos ou quase periódicos em sinais EEG.

Assim, os resultados obtidos neste estudo reforçam evidências recentes da literatura, indicando que a escolha da wavelet deve ser orientada pelo domínio de análise desejado: a *Morse* é especialmente adequada para representações multiescalares e tempo-frequência; a *Bump* é indicada para eventos abruptos e localizados no tempo; e a *Morlet*, para análise de componentes espectrais bem definidos. Essa distinção evidencia a importância da seleção criteriosa da wavelet como elemento essencial na construção de modelos robustos para análise e classificação de sinais EEG.

4.5.3 Arquiteturas de Redes Neurais

A análise comparativa das arquiteturas de redes neurais adotadas neste estudo evidencia a complementaridade entre redes convolucionais (CNN) e recorrentes (LSTM), destacando-se o arranjo híbrido CNN–LSTM como o mais eficaz para a tarefa de classificação de crises epiléticas com base em sinais eletroencefalográficos (EEG).

As CNNs demonstraram elevada competência na extração de padrões espaciais locais, como picos, complexos espícula-onda e outras morfologias características de descargas epileptiformes. Contudo, sua principal limitação reside na modelagem de dependências temporais de longo alcance, aspecto crítico em sinais EEG, que apresentam estrutura dinâmica não estacionária ao longo do tempo.

As redes LSTM, por sua vez, evidenciaram-se como mais apropriadas para a captura de sequências temporais prolongadas. Conforme apontado por Xu et al. (2020), “as LSTM foram escolhidas por sua capacidade de preservar informações ao longo de sequências temporais mais

longas, o que é vital para a análise de EEGs complexos e não estacionários”. Esse tipo de rede é projetado para reter informações relevantes e descartar irrelevantes por meio de mecanismos de porta, o que favorece sua aplicação em sinais neurofisiológicos.

Ao integrar as propriedades das CNNs e LSTMs, a arquitetura híbrida CNN–LSTM oferece uma estrutura sinérgica, capaz de explorar de forma simultânea características espaciais e temporais dos sinais. Nesse sentido, os autores afirmam que “a CNN extrai características espaciais locais e a LSTM modela as relações temporais de longo prazo a partir dessas características” (Xu et al., 2020). Tal combinação mostrou-se particularmente eficaz na análise de representações tempo-frequência derivadas de transformadas wavelet, dada a complexidade inerente aos sinais cerebrais.

Em estudo empírico, Xu et al. (2020) propuseram um modelo unidimensional CNN–LSTM para reconhecimento automático de crises epiléticas, obtendo acurácia de 99,39% em tarefas binárias e 82,00% em classificação multiclases, desempenho considerado robusto frente à variabilidade interpaciente.

Complementarmente, Albaqami, Hassan e Datta (2023) propuseram a arquitetura MP–*SeizNet*, composta por caminhos paralelos envolvendo CNN, Bi-LSTM e mecanismos de atenção. O modelo atingiu *F1-Score* de 98,1% e 87,6% de acurácia em generalização por paciente, utilizando o banco de dados TUSZ, o que ressalta a aplicabilidade clínica de arquiteturas híbridas em ambientes realistas.

Esses achados são corroborados por revisões recentes, como a de Zhang, Liu e Yang (2024), os quais concluem que “modelos híbridos com atenção superam abordagens puramente convolucionais ao lidar com sinais EEG de alta complexidade”, evidenciando que a combinação de mecanismos convolucionais, temporais e atencionais constitui uma estratégia promissora para o avanço de sistemas automatizados de análise de EEG.

Portanto, os dados obtidos neste estudo, aliados às evidências da literatura, indicam que a arquitetura CNN–LSTM representa uma solução robusta e eficaz para tarefas de classificação de EEG multiclasse, sobretudo quando aplicada a representações tempo-frequência derivadas de transformadas wavelet.

4.5.4 Limitações do Estudo

Apesar dos resultados promissores obtidos neste estudo, que reforçam o potencial das abordagens empregadas para a classificação automática de crises epiléticas, é fundamental reconhecer algumas limitações que restringem seu escopo atual. Primeiramente, os experimentos foram conduzidos com base em um único conjunto de dados, o que pode

comprometer a capacidade de generalização dos modelos para diferentes populações clínicas e variações interpaciente. Estudos recentes demonstram que a validação cruzada em múltiplas bases, como CHB-MIT e TUSZ, constitui uma estratégia eficaz para avaliar a robustez dos modelos em contextos mais heterogêneos .

Além disso, embora as métricas de desempenho utilizadas — acurácia, precisão, recall e *F1-Score* — sejam amplamente reconhecidas, a adoção de indicadores complementares, como AUC-ROC, índice *Kappa* e matriz de confusão, pode proporcionar uma avaliação mais abrangente, sobretudo em cenários marcados por desbalanceamento entre classes.

Outro fator relevante é a ausência de testes em ambientes clínicos reais, nos quais artefatos fisiológicos, movimentos musculares e ruídos ambientais frequentemente interferem na qualidade dos sinais EEG. Trabalhos como o de Yu (2021) ressaltam a importância de incorporar etapas robustas de pré-processamento, como métodos adaptativos baseados em wavelets, para mitigar tais interferências e garantir maior confiabilidade dos sinais analisados.

Adicionalmente, a implementação dos modelos em plataformas embarcadas para aplicação em tempo real ainda não foi explorada neste estudo, o que representa uma etapa fundamental para sua inserção em sistemas clínicos de monitoramento contínuo.

Dessa forma, embora o presente estudo apresente contribuições relevantes, avanços futuros podem ser alcançados com a ampliação do conjunto de dados, a incorporação de métricas e técnicas explicativas adicionais, bem como a validação dos modelos em condições clínicas realistas.

5. CONCLUSÃO

Este trabalho apresentou uma abordagem quantitativa para a classificação automática de diferentes tipos de crises epiléticas a partir de sinais eletroencefalográficos (EEG), utilizando características estatísticas extraídas dos momentos conjuntos da distribuição tempo-frequência. A análise foi conduzida com base nos dados públicos do *Temple University Hospital Seizure Corpus* (TUSZ), uma das maiores e mais amplamente utilizadas bases de EEG clínico anotado, a qual disponibiliza registros de pacientes diagnosticados com distintos tipos de crises epiléticas.

Foram investigadas especificamente quatro categorias clínicas de crises: convulsão generalizada não específica (GNSZ), convulsão parcial complexa (CPSZ), convulsão focal não específica (FNSZ) e convulsão tônico-clônica (TCSZ). Essas categorias foram selecionadas por representarem diferentes manifestações ictais, com variações em seus padrões eletrofisiológicos, níveis de complexidade e relevância clínica no processo de diagnóstico diferencial.

A metodologia adotada consistiu na decomposição dos sinais EEG por meio da Transformada *Wavelet* Contínua (CWT), que possibilitou a construção de representações tempo-frequência com alta resolução. A partir dessas representações, foram extraídos quatro momentos estatísticos — média, variância, assimetria e curtose — utilizando três funções wavelet-mãe distintas: *Morse*, *Morlet* e *Bump*. Esses atributos serviram como vetores de entrada para o treinamento supervisionado de três arquiteturas de redes neurais profundas: convolucionais (CNN), recorrentes (LSTM) e híbridas (CNN-LSTM).

Os resultados experimentais revelaram que a configuração envolvendo a função wavelet *Morse*, a arquitetura híbrida CNN-LSTM e a combinação dos momentos de variância e curtose apresentou o melhor desempenho global. Essa configuração alcançou acurácia média de 96,8%, precisão de 96,5%, sensibilidade de 96,9% e F1-score de 96,7%. Desempenhos particularmente elevados foram observados na identificação da classe TCSZ, com acurácia de 98,2% e F1-Score de 98,0%, indicando a robustez do modelo frente à variabilidade dos padrões ictais entre as classes.

No que se refere à comparação entre funções wavelet, a *Morse* demonstrou desempenho superior, com acurácia média de 95,2%, superando as *wavelets Bump* (93,7%) e *Morlet* (91,8%). Tal superioridade está associada à maior capacidade da wavelet *Morse* de representar componentes de baixa frequência, comumente presentes nas manifestações epiléticas. Entre os momentos estatísticos avaliados, a variância destacou-se como o atributo mais

discriminativo (acurácia de 94,3%), seguida pela curtose (92,7%). A média apresentou desempenho inferior (acurácia abaixo de 84%), indicando menor relevância na separação entre as classes.

No que tange às arquiteturas de rede, o modelo CNN–LSTM superou as arquiteturas CNN (91,2%) e LSTM (89,6%), o que se deve à sua capacidade de integrar, de forma eficaz, padrões espaciais extraídos das representações tempo-frequência com dependências temporais de longo prazo presentes nos sinais EEG. Essa sinergia demonstrou-se especialmente adequada à modelagem da complexidade da atividade elétrica cerebral durante episódios epiléticos.

De modo geral, os achados sugerem que a escolha criteriosa da função *wavelet*, dos momentos estatísticos e da arquitetura de rede exerce influência significativa sobre o desempenho dos classificadores. Isso reforça a importância do ajuste fino entre as etapas de pré-processamento, extração de atributos e aprendizado profundo na construção de modelos robustos para aplicações clínicas.

Apesar dos avanços metodológicos evidenciados e da consonância dos resultados com a literatura contemporânea, é importante reconhecer algumas limitações deste estudo. Entre elas, destacam-se o uso de uma única base de dados (TUSZ), a aplicação de um conjunto restrito de métricas de avaliação e a ausência de validação em tempo real em ambientes clínicos. Esses aspectos limitam, em parte, a generalização dos resultados e indicam oportunidades de aprimoramento em pesquisas futuras.

Nesse sentido, recomenda-se como direções para trabalhos subsequentes: (i) a realização de avaliações inter-base, envolvendo diferentes populações e protocolos de aquisição; (ii) a inclusão de métricas complementares, como área sob a curva ROC, tempo de inferência e medidas de interpretabilidade; e (iii) a aplicação prática dos modelos em sistemas embarcados ou plataformas clínicas, com ênfase em algoritmos dotados de capacidade de explicação, alinhados aos princípios da inteligência artificial responsável.

Em síntese, os resultados desta pesquisa apontam para o potencial da abordagem proposta na construção de soluções computacionais mais precisas, interpretáveis e eficientes no apoio ao diagnóstico da epilepsia. Reforça-se, assim, a relevância da integração entre análise tempo-frequência baseada em momentos estatísticos e redes neurais profundas no contexto da neuroengenharia e da inteligência artificial aplicada à saúde, contribuindo para o desenvolvimento de ferramentas promissoras voltadas à modernização do cuidado neurológico.

REFERÊNCIAS

ABIRAMI, S. et al. Automated multi-class seizure-type classification system using EEG signals and machine learning algorithms. **IEEE Access**, v. 12, p. 136524–136541, 2024. DOI: <https://doi.org/10.1109/ACCESS.2024.3462772>. Acesso: 30/06/2025.

ALBAQAMI, H.; HASSAN, G. M.; DATTA, A. Wavelet-based multi-class seizure type classification system. **Applied Sciences**, v. 12, n. 11, p. 5702, 2022. Disponível em: <https://doi.org/10.3390/app12115702>. Acesso em: 26 jun. 2025.

ALVA-DÍAZ, Carlos; HUAMÁN, Andrés; MOLINA, Rosa; RIVERA, Luis; CASTAÑEDA, Christian; VENTURA, Claudia; TOVAR, Carolina. Epidemiology of epilepsy in Latin America and the Caribbean: **A systematic review and meta-analysis**. **Epilepsia**, [S.l.], v. 62, n. 9, p. 2155–2170, 2021. DOI: <https://doi.org/10.1111/epi.16850>. Acesso: 30/06/2025.

BENICZKY, S. et al. Updated classification of epileptic seizures: Position paper of the International League *Against Epilepsy*. **Epilepsia**, [S.l.], v. 66, n. 6, p. 1804–1823, jun. 2025. DOI: <https://doi.org/10.1111/epi.18338>. Acesso: 30/06/2025.

CASOLARO, A.; CAPONE, V.; IANNUZZO, G.; CAMASTRA, F. (2023). **Deep Learning for Time Series Forecasting: Advances and Open Problems**. **Information**, 14(11), 598. DOI: 10.3390/info14110598. [researchgate.net](https://www.researchgate.net). Acesso: 30/06/2025.

CHEN, W. et al. An automated detection of epileptic seizures EEG using CNN classifier based on feature fusion with high accuracy. **BMC Medical Informatics and Decision Making**, [S.l.], v. 23, art. 96, 2023. DOI: <https://doi.org/10.1186/s12911-023-02180-w>. Acesso: 30/06/2025.

DISLI, F. et al. Epilepsy diagnosis from EEG signals using continuous wavelet transform-based depthwise convolutional neural network model. **Diagnostics**, v. 15, n. 1, art. 84, 2025. Disponível em: <https://www.mdpi.com/2075-4418/15/1/84>. Acesso em: 25 jun. 2025.

DU, X. et al. Joint denoising of epileptic EEG signals with CEEMDAN and continuous wavelet transform. **Frontiers in Neuroscience**, 2024. Disponível em: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2024.1468967/full>. Acesso em: 25 jun. 2025.

EPSTEIN, C. et al. Ictal EEG source localization in focal epilepsy: review and future directions. **Clinical Neurophysiology**, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1388245720304417>. Acesso em: 25 jun. 2025.

FIEST, K. M. et al. Active epilepsy prevalence and incidence in Latin America and the Caribbean: a systematic review and meta-analysis of population-based studies. **Epilepsia**, v. 62, n. 6, p. 984–996, 2021. DOI: <https://doi.org/10.1111/epi.16875>.

GHUDAR, M.; MSTAFA, R. J. Hybrid deep learning model for epileptic seizure classification by using 1D-CNN with multi-head attention mechanism. **ArXiv**, maio 2025. Disponível em: <https://arxiv.org/html/2501.10342v1>. Acesso em: 25 jun. 2025.

HANG, X.; HUANG, Q.; CHEN, F. A review of epilepsy detection and prediction methods based on EEG signal processing and deep learning. **Frontiers in Neuroscience**, v. 18, art. 1468967, 2024. Disponível em: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2024.1468967/full>. Acesso em: 25 jun. 2025.

HARRIS, C.R., MILLMAN, K.J., VAN DER WALT, S.J. et al. **Array programming with NumPy**. **Nature** 585, 357–362 (2020). <https://doi.org/10.1038/s41586-020-2649-2>. Acesso: 30/06/2025.

KHAN, A.; LOW, F. Challenges in non-stationary EEG analysis: deep learning and time-frequency approaches. **Frontiers in Artificial Intelligence**, 2023. Disponível em: <https://arxiv.org/html/2412.07878v1>. Acesso em: 25 jun. 2025.

LILLY, J. M.; OLHEDE, S. C. Generalized Morse wavelets as a superfamily of analytic wavelets. **IEEE Transactions on Signal Processing**, v. 60, n. 11, p. 6036–6041, 2012. DOI: 10.1109/TSP.2012.2210890 dblp.org+4jmlilly.net+4pmc.ncbi.nlm.nih.gov+4. Acesso: 30/06/2025.

LILLY, J. M. Element analysis: A wavelet-based method for analysing time-localized events in noisy time series. **Proceedings of the Royal Society A**, v. 473, n. 2200, p. 20160776, 2017. DOI: 10.1098/rspa.2016.0776. Acesso: 30/06/2025.

MAGRINI, L. Funções wavelet e transformada wavelet contínua: representação simultânea nos domínios do tempo e da frequência. C.Q.D.- **Revista Eletrônica Paulista de Matemática**, v. 19, p. 17–32, 12 2020. Acesso: 30/06/2025.

MARTINEZ-RÍOS, A., BUSTAMANTE-BELLO, R., NAVARRO-TUCH, S., PÉREZ-MEANA, H. **Applications of the Generalized Morse Wavelets: A review**. **IEEE Access**, v. 11, p. 667–688, 2023. DOI: 10.1109/ACCESS.2022.3232729. Acesso: 30/06/2025.

MIENYE, I. D.; SWART, T. G.; OBAIDO, G. (2024). Recurrent Neural Networks: **A Comprehensive Review of Architectures, Variants, and Applications**. **Information**, 15(9), 517. DOI: 10.3390/info15090517 .Acesso: 30/06/2025.

MEYER, S. et al. The present and future of seizure detection, prediction and forecasting. **Frontiers in Neurology**, 2024. Disponível em: <https://www.frontiersin.org/articles/10.3389/fneur.2024.1245567/full>. Acesso em: 25 jun. 2025.

MONTENEGRO, M. A.; VALENTE, K. EEG in focal and generalized epilepsies: pearls and perils. **Epilepsy & Behavior**, v. 156, 2024. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38838461/>. Acesso em: 25 jun. 2025.

MOUTONNET, N.; WHITE, S.; CAMPBELL, B. P. et al. Clinical translation of machine learning algorithms for seizure detection in scalp electroencephalography: systematic review. **ArXiv**, 2024. Disponível em: <https://arxiv.org/abs/2404.15332>. Acesso em: 25 jun. 2025.

NATAU, B. et al. Identifying spatio-temporal seizure propagation patterns in epilepsy patients: Bayesian Epileptor framework. **Communications Biology**, 2021. Disponível em: <https://www.nature.com/articles/s42003-021-02751-5>. Acesso em: 25 jun. 2025.

PELLINEN, J. Treatment gaps in epilepsy. **Frontiers in Epidemiology**, [S.l.], v. 2, 01 ago. 2022. DOI: <https://doi.org/10.3389/fepid.2022.976039>. PMID: 38455298. PMCID: PMC10910960. Acesso: 30/06/2025.

POSTEPSKI, F.; WOJCIK, G. M.; WROBEL, K.; KAWIAK, A.; ZEMLA, K.; SEDEK, G. (2025). Recurrent and convolutional neural networks in classification of EEG signal for guided imagery and mental workload detection. **Scientific Reports**, 15, 10521. DOI: <https://doi.org/10.48550/arXiv.2405.16901>. Acesso: 30/06/2025.

SAADOON, Y. A.; KHALIL, M.; BATTIKH, D. Machine and deep learning-based seizure prediction: A scoping review on the use of temporal and spectral features. **Applied Sciences**, [S.l.], v. 15, n. 11, art. 6279, 2025. DOI: <https://doi.org/10.3390/app15116279>. Acesso: 30/06/2025.

SAADOON, Y. A.; KHALIL, M.; BATTIKH, D. Machine and deep learning-based seizure prediction: a scoping review on the use of temporal and spectral features. *Applied Sciences*, v. 15, n. 11, p. 6279, 2025. Disponível em: <https://www.mdpi.com/2076-3417/15/11/6279>. Acesso em: 25 jun. 2025.

SUN, P.; WU, J.; ZHANG, M.; DEVOS, P.; BOTTELDOOREN, D. (2023). **Delayed Memory Unit: Modelling Temporal Dependency Through Delay Gate**. *ArXiv*, abs/2310.14982. DOI: 10.48550/arXiv.2310.14982.. Acesso: 30/06/2025.

TEMPLE UNIVERSITY. **Temple University EEG Corpus - Downloads**. [20--?]. Disponível em: https://isip.piconepress.com/projects/nedc/html/tuh_eeg/. Acesso em: 13 jun. 2025.

TORKEY, H.; HASHISH, S.; SOUISSI, S.; HEMDAN, E. E.-D.; SAYED, A. Seizure detection in medical IoT: hybrid CNN-LSTM-GRU model with data balancing and XAI integration. **Algorithms**, v. 18, p. 77, 2025. Disponível em: <https://doi.org/10.3390/a18020077>. Acesso em: 26 jun. 2025.

VANDECASTEELE, K. et al. Visual seizure annotation and automated seizure detection using behind-the-ear electroencephalographic channels. **Epilepsia**, v. 61, n. 4, p. 766–775, abr. 2020. DOI: <https://doi.org/10.1111/epi.16470>. Acesso: 30/06/2025.

SIEBENBRODT, A. et al. Personal impact of epilepsy and well-being in individuals with epilepsy. **Epilepsy & Behavior**, 2023. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0920121125000373>. Acesso em: 25 jun. 2025.

SMITH, J.; LEE, K. Time–frequency methods for non-stationary EEG signal analysis. **Journal of Neuroscience Methods**, 2022. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1388245799001650>. Acesso em: 25 jun. 2025.

TOUCHIE, A.; LEE, K.; CHOI, E. Retraining and evaluation of machine learning and deep learning networks for seizure detection in EEG across datasets. **Scientific Reports**, 2025.

Disponível em: <https://www.nature.com/articles/s41598-025-98389-y>. Acesso em: 25 jun. 2025.

WANG, X. et al. Epileptic seizure detection with deep EEG features by convolutional neural networks: integration of time–frequency domain methods. **Frontiers in Neuroscience**, v. 17, art. 1145526, 2024. Disponível em: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2023.1145526/full>. Acesso em: 25 jun. 2025.

WILLIAMS, G. W. et al. Interobserver variability in EEG interpretation among electroencephalographers. **Neurology**, v. 35, n. 12, p. 1714–1719, 1985. Atualizado em 2023. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/4069362/>. Acesso em: 25 jun. 2025.

WORLD HEALTH ORGANIZATION (WHO). *Epilepsy: fact sheet*. **Geneva: WHO**, 2023. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/epilepsy>. Acesso em: 25 jun. 2025.

WU, X. et al. Advancements and challenges of artificial intelligence-assisted EEG in epilepsy management. **Journal of Clinical Medicine**, v. 14, n. 12, 2023. Disponível em: <https://www.mdpi.com/2077-0383/14/12/4270>. Acesso em: 25 jun. 2025.

YAN, K. et al. Automated seizure detection in epilepsy using a novel dynamic temporal-spatial graph attention network. **Scientific Reports**, v. 15, art. 16392, 2025. Disponível em: <https://www.nature.com/articles/s41598-025-01015-0>. Acesso em: 25 jun. 2025.

YAN K. et al. Automated seizure detection in epilepsy using a novel dynamic temporal-spatial graph attention network. **Sci Rep**. 2025 May 12;15(1):16392. doi: 10.1038/s41598-025-01015-0. PMID: 40355495; PMCID: PMC12069711. Acesso: 30/06/2025.

YU, X.; FAN, Z.; JAMIL, M.; AZIZ, M. Z.; HOU, Y.; LI, H.; LV, J. Transacting Multiple Mother Wavelets in Continuous Wavelet Transform for Epilepsy EEG Classification via CNN. In: 2021 IEEE 9th **International Conference on Information, Communication and Networks (ICICN)**, Xi'an, China, 25–28 nov. 2021. p. 76–80. DOI: <https://doi.org/10.1109/ICICN52636.2021.9673990>. Acesso: 30/06/2025.

ZHAO, Wei et al. Residual and bidirectional LSTM for epileptic seizure detection. **Frontiers in Computational Neuroscience**, [S.l.], v. 18, 2024. Disponível em: <https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1415967>. Acesso em: 13 jun. 2025.

ZHANG, Y. et al. Integration of 24 feature types to accurately detect and predict seizures using scalp EEG signals. **Sensors**, v. 18, n. 5, p. 1372, 2018. Disponível em: <https://doi.org/10.3390/s18051372>. Acesso em: 26 jun. 2025.

ZHANG, Xizhen et al. A review of epilepsy detection and prediction methods based on EEG signal processing and deep learning. **Frontiers in Neuroscience**, [S.l.], v. 18, 15 nov. 2024. DOI: <https://doi.org/10.3389/fnins.2024.1468967>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fnins.2024.1468967>. Acesso em: 26 jun. 2025.